



HAL
open science

Contributions à l'étude de détection des bandes libres dans le contexte de la radio intelligente.

Ziad Khalaf

► **To cite this version:**

Ziad Khalaf. Contributions à l'étude de détection des bandes libres dans le contexte de la radio intelligente.. Autre. Supélec, 2013. Français. NNT : 2013SUPL0005 . tel-00812666

HAL Id: tel-00812666

<https://theses.hal.science/tel-00812666>

Submitted on 12 Apr 2013

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



N° d'ordre : 2013-05-TH

THÈSE DE DOCTORAT

DOMAINE : STIC

SPECIALITE : Télécommunications

Ecole Doctorale « Mathématiques, Télécommunications, Informatique, Signal, Systèmes Electroniques »

Présentée par :

Ziad KHALAF

Sujet :

Contributions à l'étude de détection des bandes libres dans le contexte de la radio intelligente

Soutenue le 8 février 2013

devant les membres du jury :

M. Carlos Faouzi BADER	Senior Research Associate au CTTC, Barcelone	Examineur
M. Jean-Yves BAUDAIS	Chargé de recherche CNRS à l'IETR, Rennes	Examineur
M. Jean-Marie GORCE	Professeur à l'INSA de Lyon	Rapporteur
Mme. Aawatif HAYAR	Professeur à l'UH2C, Casablanca	Présidente
M. Didier LE RUYET	Professeur au CNAM de Paris	Rapporteur
M. Amor NAFKHA	Enseignant-chercheur à Supélec	Co-encadrant
M. Jacques PALICOT	Professeur à Supélec	Directeur de thèse

“Do not go where the path may lead, go instead where there is no path and leave a trail.”

- Ralph Waldo Emerson

Remerciements

Ce mémoire de thèse est le résultat d'un travail effectué pendant trois ans dans les locaux de l'École Supérieure d'Électricité (Supélec) au sein de l'équipe Signal, Communication et Électronique Embarquée (SCEE) qui est une équipe de recherche membre de l'Institut d'Électronique et de Télécommunications de Rennes (IETR)- UMR CNRS 6164, groupe Automatique et Communications.

Je tiens à saluer ici les personnes qui, de près ou de loin, ont contribué à la concrétisation de ce travail de thèse de doctorat. Ces remerciements sont rédigés dans un moment de doux relâchement intellectuel, sans véritable rigueur.

Je ne saurais commencer sans remercier M. *Philippe MARTIN* Directeur du campus de Rennes de Supélec, et M. *Bernard JOUGA* délégué à la recherche et aux relations industrielles à Supélec campus de Rennes, pour leur accueil au sein de cette école. Je tiens à remercier M. *Bernard JOUGA* pour son support continu durant ces trois ans de thèse et pour ses conseils précieux notamment ceux qui m'ont aidé à faire des choix et de fixer mes objectifs concernant l'orientation de ma future carrière.

Je remercie grandement mon directeur de thèse *Jacques PALICOT* qui m'a encadré de très près durant ces trois ans en plus de ses autres charges de direction dans l'équipe SCEE. Sans lui mon travail et l'aboutissement de ce mémoire n'auraient pas vu le jour. Je le remercie bien évidemment pour la pertinence de ses conseils scientifiques, sa confiance, sa disponibilité, son humour et ses encouragements mais je le remercie surtout pour la belle leçon d'humanité qu'il m'a montrée durant ces trois ans. Je ne peux que lui témoigner ma gratitude et ma reconnaissance.

Je remercie aussi M. *Amor NAFKHA* pour la très grande autonomie qu'il m'a confiée pour mener mes travaux de thèse et pour ses encouragements continus. Je lui souhaite tout le succès dans sa carrière.

Naturellement, j'exprime mes gratitudes à l'ensemble des personnes qui m'ont fait l'honneur d'être membres de mon jury. Pour cela, je remercie très sincèrement Mme. *Aawatif HAYAR* pour avoir accepté de présider mon jury de thèse ainsi que pour sa sympathie. Je remercie également M. *Jean-Marie GORCE* et M. *Didier LE RUYET* qui ont accepté de participer à ce jury en tant que rapporteurs et bien sûr, je remercie sincèrement

M. *Carlos Faouzi BADER* et M. *Jean-Yves BAUDAIS*, pour leurs participations dans mon jury en tant qu'examineurs. Je tiens à remercier en particulier *Jean-Yves BAUDAIS*, de m'avoir consacré une demie journée, afin de m'aider à corriger les erreurs L^AT_EX et pour sa grande gentillesse. Les commentaires et les questions de ces personnalités scientifiques, tant sur la forme du mémoire que sur son fond, ont contribué à l'amélioration de ce dernier. L'intérêt qu'ils ont manifesté pour mes travaux a permis d'apporter un regard extérieur critique et intéressant sur le sujet.

Je remercie sincèrement mon ancien collègue à SCEE et mon ami *Wassim JOUINI*, avec qui j'ai pu souvent discuter et échanger des idées scientifiques et autres. Ces discussions ont joué un rôle important sur l'avancement de mes travaux surtout dans le chapitre deux de ce mémoire. Ses qualités de chercheur, ainsi que ses qualités humaines m'ont beaucoup impressionné.

J'adresse toute ma sympathie à *Daniel LE GUENNEC* professeur à Supélec, *Yves LOUET* professeur à Supélec, *Christophe MOY* professeur à Supélec et à *Honggang ZHANG* professeur invité à Supélec pour leur bonne humeur.

J'adresse ma sincère reconnaissance à mes amis : *Ghaïs EL ZEIN*, professeur à l'INSA de Rennes, *Loutfi NUAYMI*, professeur à Télécom Bretagne, *Gisèle EL DIB*, maître de conférences à l'Université de Rennes 1 et à *Samer LAHOUD*, maître de conférences à l'Université de Rennes 1 pour leurs conseils précieux et leurs soutiens permanent durant toute cette période.

Je tiens à souligner le soutien et l'amitié de ceux qui m'ont aidé à travers ce voyage, au sein de l'équipe SCEE et au-delà : *Abel, Ayman, Babar, Bachir, Camil, Caroline, Catherine, Dany, Hanan, Hanna, Hongzi, Hussein, Jérôme, Lama, Mohamad, Oussama, Samba, Tony, Vincent* et tous les autres que j'ai oubliés.

J'adresse un grand merci à tous les permanents, doctorants, stagiaires et secrétaires que j'ai pu côtoyer durant ces trois ans et qui contribuent à la joyeuse atmosphère qui règne à Supélec.

Je voudrais remercier professeur *Joël BOISSOLE* de m'avoir permis de rejoindre l'équipe d'enseignement à la faculté de médecine de l'université de Rennes 1 pendant les années 2009 à 2011.

J'adresse également tous mes remerciements à l'ensemble des *ami(e)s* (que je n'oserai pas commencer à nommer par peur d'en oublier quelqu'un) que j'ai pu rencontrer durant ces années de thèse pour leurs soutiens, leurs bonnes humeurs, et surtout leurs encouragements. En particulier je remercie mes amis à *Rennes* pour avoir rendu mon séjour très agréable.

Pour finir, je ne pourrais clore ces remerciements sans remercier du fond du cœur mon père *Ibrahim*, ma mère *Leila* et mon frère *Joe* pour leurs soutiens inconditionnels et leurs encouragements.

À vous tous et pour ceux que j'ai omis, je dédie ce travail.

Ziad KHALAF
Rennes, France

Table des matières

Remerciements	v
Table des matières	ix
Résumé	1
Abstract	3
Introduction générale	5
1 État de l'art sur les techniques de détections du spectre	9
1.1 Introduction	9
1.2 Test d'hypothèse	10
1.3 Performance d'un détecteur et courbe de ROC	13
1.4 Méthodes de détections non collaboratives	13
1.4.1 Méthodes de présence du signal	14
1.4.1.1 Méthodes de détections d'un trou	14
1.4.1.2 Méthodes de détections larges bandes	26
1.4.2 Méthodes de reconnaissance du signal	34
1.4.2.1 La reconnaissance de bande passante du canal	34
1.4.2.2 Identification du système présent en utilisant les symboles pilotes	35
1.4.2.3 Détecteur de signature cyclostationnaire	36
1.4.2.4 D'autres détecteurs	37
1.5 Les détections collaboratives	38
1.5.1 Détection centralisée	39
1.5.1.1 Détection en utilisant les valeurs propres	39
1.5.2 Détection distribuée	43
1.5.2.1 La règle ET	44
1.5.2.2 La règle OU	44
1.5.2.3 La règle de VOTE	44
1.5.2.4 L'efficacité en énergie	44
1.5.3 Détection externe	45
1.6 Conclusion	45

2	Architecture hybride de détection de bandes libres	47
2.1	Introduction	47
2.2	Détection des signaux aléatoires	47
2.2.1	Radiomètre	48
2.2.1.1	Performance du radiomètre	49
2.2.1.2	Limite de la détection d'énergie	49
2.2.2	Détection Cyclostationnaire	54
2.2.2.1	Tests de présence de la cyclostationarité sur une fréquence	54
2.2.2.2	Autres tests de cyclostationarité	58
2.3	Détecteur Hybride	61
2.3.1	Généralités	61
2.3.2	Architecture du détecteur	61
2.4	Règle de décision de l'algorithme HSD	62
2.4.1	Étude analytique de l'algorithme HSD en utilisant l'outil statistique d'ordre	64
2.4.2	Limites de l'algorithme HSD	65
2.4.3	Résultats de simulation de l'HSD	67
2.5	Version améliorée de l'algorithme HSD (EHSD)	69
2.5.1	Performances de l'EHSD	70
2.5.2	Résultats de simulations, discussions et comparaisons	73
2.5.2.1	L'influence de l'environnement γ sur les performances des algorithmes HSD et EHSD	75
2.5.2.2	Comparaison des performances en utilisant les courbes de ROC	77
2.6	Conclusion	77
3	Nouvel estimateur du cyclopectre utilisant le compressed sensing	79
3.1	Introduction	79
3.2	Parcimonie et compressed sensing	79
3.2.1	Parcimonie	79
3.2.2	Compressed sensing	80
3.2.2.1	La propriété d'isométrie restreinte	83
3.3	Cyclopectre et parcimonie	83
3.4	Estimation classique du vecteur d'autocorrelation cyclique	85
3.5	Estimation aveugle du vecteur de l'autocorrelation cyclique en utilisant le compressed sensing	86
3.5.1	Vérification du modèle	87
3.6	Analyse des performances de l'estimateur proposé	88
3.6.1	Erreur quadratique moyenne (premier critère)	88
3.6.1.1	EQM à l'émission sans filtrage	89
3.6.1.2	EQM à l'émission avec filtrage	90
3.6.1.3	EQM à la réception	93
3.6.1.4	L'EQM à la réception avec canal de propagation	93
3.6.2	Analyse de l'erreur sur l'estimation de la position de la fréquence cyclique : l' EQM_{α_f}	95
3.6.2.1	Paramètre d'évaluation	96
3.6.2.2	Comparaison des différents estimateurs avec l' EQM_{α_f}	97

3.6.2.3	Sans filtrage à l'émission	99
3.6.2.4	Avec filtrage à l'émission	100
3.7	Conclusion	102
4	Détection aveugle en utilisant la parcimonie	103
4.1	Introduction	103
4.2	Méthodes de détections	103
4.2.1	Méthodes de comparaisons des slots	104
4.2.1.1	Performance de détection de la MCS	105
4.2.2	Méthode de comparaisons des slots version soft	107
4.2.2.1	Performance de détection de la MCSS	108
4.2.2.2	Effet du filtrage sur la détection	108
4.2.2.3	Effet du Canal de Propagation	116
4.2.2.4	Analyse de complexité et temps d'observation	116
4.2.2.5	Conclusion sur la MCSS	118
4.2.3	Méthodes de symétrie	119
4.2.3.1	Propriété de symétrie	119
4.2.3.2	La nouvelle méthode de symétrie MS	120
4.2.3.3	Le choix du nombre d'itération	121
4.2.3.4	Résultats de simulations	123
4.2.3.5	Influence du filtrage	125
4.2.3.6	Influence du canal de transmission	126
4.2.3.7	Analyse de la complexité et du temps d'observation	127
4.2.3.8	Conclusion sur la MS	132
4.3	Conclusion	133
	Conclusion et perspectives	135
	Annexe	139
A	Annexe relative au chapitre 1	141
A.1	Le Standard IEEE 802.22	141
B	Annexe relative au chapitre 2	143
B.1	Test statistique de présence de la cyclostationarité de Dandawaté-Giannakis	143
B.2	Démonstration que l'estimateur (3.13) est non biaisé	145
C	Annexe relative au chapitre 3	147
C.1	Modèle du canal de propagation	147
	Notations et abréviations	151
	Table des figures	157
	Liste des tableaux	163
	Publications de l'auteur au cours de la thèse	165

Bibliographie

167

Résumé

Les systèmes de communications sans fil ne cessent de se multiplier pour devenir incontournables de nos jours. Cette croissance cause une augmentation de la demande des ressources spectrales, qui sont devenues de plus en plus rares. Afin de résoudre ce problème de pénurie de fréquences, Joseph Mitola III, en 2000, a introduit l'idée de l'allocation dynamique du spectre. Il définit ainsi le terme *Cognitive Radio* (Radio Intelligente), qui est largement pressenti pour être le prochain *Big Bang* dans les futures communications sans fil [1]. Dans le cadre de ce travail on s'intéresse à la problématique du *spectrum sensing* qui est la détection de présence des Utilisateurs Primaires dans un spectre sous licence, dans le contexte de la radio intelligente. L'objectif de ce travail est de proposer des méthodes de détection efficaces à faible complexité et/ou à faible temps d'observation et ceci en utilisant le minimum d'information *a priori* sur le signal à détecter. Dans la première partie on traite le problème de détection d'un signal aléatoire dans le bruit. Deux grandes méthodes de détection sont utilisées : la détection d'énergie ou radiomètre et la détection cyclostationnaire. Dans notre contexte, ces méthodes sont plus complémentaires que concurrentes. Nous proposons une architecture hybride de détection des bandes libres, qui combine la simplicité du radiomètre et la robustesse des détecteurs cyclostationnaires. Deux méthodes de détection sont proposées qui se basent sur cette même architecture. Grâce au caractère adaptatif de l'architecture, la détection évolue au cours du temps pour tendre vers la complexité du détecteur d'énergie avec des performances proches du détecteur cyclostationnaire ou du radiomètre selon la méthode utilisée et l'environnement de travail. Dans un second temps on exploite la propriété parcimonieuse de la Fonction d'Autocorrelation Cyclique (FAC) pour proposer un nouvel estimateur aveugle qui se base sur le *compressed sensing* afin d'estimer le Vecteur d'Autocorrelation Cyclique (VAC), qui est un vecteur particulier de la Fonction d'Autocorrelation Cyclique pour un délai fixe. On montre par simulation que ce nouvel estimateur donne de meilleures performances que celles obtenues avec l'estimateur classique, qui est non aveugle et ceci dans les mêmes conditions et en utilisant le même nombre d'échantillons. On utilise l'estimateur proposé, pour proposer deux détecteurs aveugles utilisant moins d'échantillons que nécessite le détecteur temporel de second ordre de [2] qui se base sur l'estimateur classique de la FAC. Le premier détecteur exploite uniquement la propriété de parcimonie du VAC tandis que le second détecteur exploite en plus de la parcimonie la propriété de symétrie du VAC, lui permettant ainsi d'obtenir de meilleures performances. Ces deux détecteurs outre qu'ils sont aveugles sont plus performants que le détecteur non aveugle de [2] dans le cas d'un faible nombre d'échantillons.

Abstract

The wireless communications systems continue to grow and has become very essential nowadays. This growth causes an increase in the demand of spectrum resources, which have become more and more scarce. To solve this problem of spectrum scarcity, Joseph Mitola III, in the year 2000, introduced the idea of dynamic spectrum allocation. Mitola defines the term “Cognitive Radio”, which is widely expected to be the next Big Bang in wireless communications [1]. In this work we focus on the problem of spectrum sensing which is the detection of the presence of primary users in licensed spectrum, in the context of cognitive radio. The objective of this work is to propose effective detection methods at low-complexity and/or using short observation time, using minimal *a priori* information about the signal to be detected. In the first part of this work we deal with the problem of detecting a random signal in noise. Two main methods of detection are used: energy detection or radiometer and cyclostationary detection. In our context, these methods are more complementary than competitive. We propose a hybrid architecture for detecting free bands, which combines the simplicity of the radiometer and the robustness of the cyclostationary detection. Two detection methods are proposed that are based on this same hybrid architecture. Thanks to the adaptive nature of the architecture, the complexity of the detector decreases over time to tend to the one of an energy detector with close performance to the cyclostationary detector or to the performance of a radiometer, depending on the used method and on the working environment. In the second part of this work we exploit the sparse property of the Cyclic Autocorrelation Function (CAF) to propose a new blind estimator based on compressed sensing that estimates the Cyclic Autocorrelation Vector (CAV) which is a particular vector of the CAF for a given lag. It is shown by simulation that this new estimator gives better performances than those obtained with the classical estimator, which is non-blind, under the same conditions and using the same number of samples. Using the new estimator, we propose two blind detectors that require fewer samples than the second order time domain detector of [2] which is based on the classical estimator of the CAF. The first detector uses only the sparse property of the CAV while the second detector exploits the symmetry property of the CAV in addition to its sparse property, resulting in better performances. Both detectors, although they are blind, are more efficient than the non-blind detector of [2] in the case of a small number of samples.

Introduction générale

Les systèmes de communications sans fil ne cessent de se multiplier [3] pour devenir incontournables de nos jours. Cette croissance s'est accompagnée d'une augmentation de la demande des ressources spectrales accessibles par la technologie sans fil, qui sont devenues de plus en plus rares ne leur permettant plus de répondre à la demande. Afin de résoudre ce problème de pénurie de fréquences, Joseph Mitola III [4], en 2000 a introduit l'idée de l'allocation dynamique du spectre. Il définit ainsi le terme *Cognitive Radio*, (radio intelligente) qui est largement pressenti pour être le prochain *Big Bang* dans les futures communications sans fil [1].

En 2002, la FCC (Federal Communications Commission), organisme de régulation et de gestion du spectre aux Etats-Unis, publie un rapport [5] sur l'utilisation des fréquences dans lequel il est noté que, dans plus de 70% des cas, le spectre est sous-utilisé suivant le temps ou l'espace. Le problème de pénurie des fréquences n'est donc qu'artificiel et la politique actuelle de gestion statique du spectre en est responsable. Cette politique de gestion du spectre est gérée par la conférence administrative mondiale des radiocommunications, en anglais *the World Administrative Radio Conference (WARC)*, qui met à jour les règlements des radiocommunications qui attribuent l'utilisation du spectre radioélectrique sur une base mondiale. Afin donc de résoudre le problème actuel de gestion du spectre, de nouvelles approches d'accès dynamique au spectre radio se sont développées, où l'accès opportuniste est le plus répandu car il s'attaque à la cause de la pénurie de fréquences. En effet, cette approche propose une nouvelle catégorie d'utilisateurs dits utilisateurs secondaires (US) pouvant accéder aux ressources fréquentielles allouées aux utilisateurs primaires (UP) lorsque ces derniers ne les utilisent pas. Ainsi, l'efficacité spectrale est augmentée en permettant la transmission par les US sur les bandes de fréquences détectées libres. Ces systèmes sont qualifiés de radio intelligente ou radio opportuniste car, en plus de la détection autonome des bandes libres, ils doivent aussi être capables de changer leurs paramètres de transmissions afin de répondre, d'une part, aux attentes de l'utilisateur et, d'autre part, aux contraintes de disponibilités des fréquences et de la ressource disponible (bande, rapport signal à bruit (RSB)...).

Cognitive Radios (CR) et leurs résultants *Cognitive Wireless Networks* (CWN), réseaux sans fil intelligents, sont devenus l'un des paradigmes les plus étudiés dans les communications sans fil. La « radio intelligente » telle qu'elle est définie initialement dans le travail de Mitola [4] est une radio qui peut connaître, percevoir et apprendre de son environnement puis agir pour simplifier la vie de l'utilisateur et optimiser les ressources. Une application importante spécifique, souvent associée à la radio intelligente est l'accès dynamique au spectre « *Dynamic Spectrum Access* » (DSA). L'accès dynamique au spectre est

la (re)-utilisation des fréquences radio « licencié » pour les utilisateurs « primaires » par les utilisateurs « secondaires », à condition que le titulaire de la licence n'utilise pas ces fréquences à un moment donné ou dans une région donnée de l'espace [6], laissant ainsi la partie du spectre temporairement vide et disponible pour les utilisateurs secondaires. Les travaux sur l'accès dynamique au spectre sont devenus si importants que le DSA est souvent considéré comme la caractéristique essentielle de la radio intelligente.

Dans le cadre de ce travail on s'intéresse à la problématique du *spectrum sensing* qui est la détection de présence des UP dans un spectre sous licence, dans le contexte de la radio intelligente. On ne s'intéresse pas à une bande particulière (GSM ou TV par exemple), ni à un système particulier. L'objectif de cette thèse est de proposer des méthodes de détection efficaces à faible complexité et/ou à faible temps d'observation et ceci en utilisant le minimum d'information *a priori* sur le signal à détecter.

Le premier chapitre présente un état de l'art sur les techniques les plus connues utilisées dans le *spectrum sensing*. Il aborde les avantages et les inconvénients de chacune de ces méthodes, en précisant l'information *a priori* que nécessite chacune d'elles.

Le deuxième chapitre traite le problème de détection d'un signal aléatoire dans le bruit. Deux grandes méthodes de détection sont utilisées : la détection d'énergie ou radiomètre et la détection cyclostationnaire. Dans notre contexte, ces méthodes sont plus complémentaires que concurrentes. Par la suite, nous proposons une architecture hybride de détection des bandes libres, qui combine la simplicité du radiomètre et la robustesse des détecteurs cyclostationnaires. C'est une architecture composée d'un étage d'adaptation et deux étages de détection : un étage de détection d'énergie et un étage secondaire de détection cyclostationnaire. Deux méthodes de détection sont proposées qui se basent sur cette même architecture. Dans ces deux méthodes à chaque fois que le détecteur d'énergie échoue, le détecteur cyclostationnaire prend la relève et son résultat de détection permet également à calibrer le(s) seuil(s) du radiomètre. Le premier algorithme corrige itérativement les seuils d'un radiomètre à double seuil, qui finalement converge vers les performances du détecteur cyclostationnaire. Le second algorithme utilise le détecteur de cyclostationnarité afin d'estimer directement le niveau de bruit, qui est ensuite utilisé pour fixer le seuil du radiomètre. Les performances de détections de ce deuxième algorithme dépassent celles du détecteur de cyclostationnarité utilisé. Grâce au caractère adaptatif de l'architecture, la détection évolue au cours du temps pour tendre vers la complexité du détecteur d'énergie avec des performances proches du détecteur cyclostationnaire ou du radiomètre selon la méthode utilisée et l'environnement de travail.

Dans le troisième chapitre on exploite la propriété parcimonieuse de la fonction d'autocorrelation cyclique (FAC) pour proposer un nouvel estimateur aveugle qui se base sur le *compressed sensing* afin d'estimer le vecteur d'autocorrelation cyclique (VAC), qui est un vecteur particulier de la FAC pour un délai τ fixe. Deux métriques vont être utilisées afin d'évaluer cette estimation. La première, l'erreur quadratique moyenne (EQM) compare le VAC estimé avec la référence théorique obtenue en utilisant la FAC. La deuxième métrique, notée EQM_{α_f} , compare la fréquence cyclique estimée à la valeur de la fréquence cyclique théorique. On montre par simulation que ce nouvel estimateur donne de meilleures per-

performances que celles obtenues avec l'estimateur classique (non biaisé), qui est non aveugle et utilisé dans [2], et ceci dans les mêmes conditions et en utilisant le même nombre d'échantillons. Plusieurs cas vont être analysés : avec et sans filtrage à l'émission, à la réception et enfin avec l'ajout d'un canal de propagation.

Dans le dernier chapitre on utilise l'estimateur proposé dans le chapitre 3, pour proposer deux détecteurs aveugles utilisant moins d'échantillons que nécessite le détecteur temporel de second ordre de [2] qui se base sur l'estimateur classique de la FAC. Le premier détecteur exploite uniquement la propriété de parcimonie du VAC tandis que le second détecteur exploite en plus de la parcimonie la propriété de symétrie du VAC, lui permettant ainsi d'obtenir de meilleures performances. Ces deux détecteurs, outre qu'ils sont aveugles, sont plus performants que le détecteur non aveugle de [2] dans le cas d'un faible nombre d'échantillons. On évalue la performance de ces détecteurs dans plusieurs environnements de simulations en les comparant au détecteur cyclostationnaire. Enfin on étudie la complexité de ces deux nouveaux détecteurs en les comparant à celle du détecteur non aveugle de [2].

Chapitre 1

État de l’art sur les techniques de détections du spectre

1.1 Introduction

La radio intelligente (RI) est souvent réduite à l’optimisation de la ressource spectrale. Cependant notre vision dans l’équipe SCEE à Supélec Rennes est une vision plus générale de la RI, qui reste compatible avec la « vision de Mitola » [4], mais qui est dans un contexte plus large. Par exemple, dans [6] sont présentés des capteurs liés au traitement d’image ; loin du capteur de détection de trous dans le spectre auquel se limite souvent la RI. Pour expliquer ce contexte plus large on propose dans [6, 7] une vision multicouches de la RI. Le modèle est découpé volontairement en 3 couches comportant :

- une couche de *haut niveau*, qui regroupe essentiellement la couche application, ainsi que les interfaces de type homme-machine, appelée *couche supérieure* ;
- une *couche intermédiaire* dans laquelle on retrouve les couches transport et réseau ;
- une couche de *bas niveau* dans laquelle on retrouve les couches MAC et physique, appelée *couche inférieure*.

Pour plus de détails sur cette vision le lecteur est invité à consulter [6, 7] . Dans le cadre de ce travail on se concentre sur la couche physique de la couche *bas niveau*. En particulier sur le *spectrum sensing*, qui est la détection de présence des utilisateurs primaires dans un spectre sous licence, et qui est un problème fondamental pour la RI. En conséquence, le *spectrum sensing* est redevenu un sujet de recherche très actif ces dernières années en dépit de sa longue histoire.

Il y a une littérature abondante traitant du *spectrum sensing*, il est impossible d’en faire une liste exhaustive, nous proposons dans ce chapitre un état de l’art qui mentionne les techniques de détection les plus célèbres classées dans deux grandes catégories : « détecteurs non collaboratifs » et « détecteurs collaboratifs ». Dans la catégorie « détecteurs non collaboratifs » on classe les détecteurs dans deux sous catégories qui sont : « détecteurs de présence du signal » et « détecteurs de reconnaissance du signal ». Finalement dans la sous catégorie « détecteurs de présence du signal » on classe les méthodes selon les types « détecteur d’un seul trou » et « détecteur de plusieurs trous simultanément » (connue aussi sous le nom de détecteur large bande). La figure 1.1 récapitule

le plan du classement des méthodes de détections utilisées dans ce chapitre. On note que cette classification est susceptible à caution et à interprétation.




FIGURE 1.1 – La classification des méthodes de détections utilisée dans l'état de l'art de ce chapitre

1.2 Test d'hypothèse

Le problème qui se pose est de savoir s'il y a un signal présent ou pas, c.-à-d. choisir l'hypothèse H_0 ou bien H_1 :

$$\begin{aligned} H_0 & : y(t) = b(t) \\ H_1 & : y(t) = x(t) + b(t) \end{aligned} \quad (1.1)$$

en utilisant un temps discret l'équation (1.1) s'écrit :

$$\begin{aligned} H_0 & : y(k) = b(k) \\ H_1 & : y(k) = x(k) + b(k) \end{aligned} \quad (1.2)$$

avec $y(t)$ le signal reçu, $x(t)$ le signal à l'émission qui peut être aléatoire, ou déterministe, mais totalement inconnu, et $b(t)$ le bruit qui est supposé être blanc gaussien (sauf indication contraire) et de moyenne nulle avec une variance connue ou non. La détection est basée sur une certaine fonction Π qui est fonction des échantillons reçus et qui est ensuite comparée à un seuil ξ . Si le seuil est dépassé, il est décidé que H_1 est vraie, sinon on décide H_0 . Soit \mathbf{y} un vecteur colonne qui contient les échantillons reçus. La probabilité de fausse

alarme P_{fa} est la probabilité que H_1 soit sélectionné, lorsque H_0 est effectivement vraie, c'est-à-dire :

$$P_{fa} = P(\Pi(\mathbf{y}) > \xi | H_0) \quad (1.3)$$

Par exemple dans le domaine du radar une fausse alarme se produit quand on décide qu'il y a une cible alors qu'il n'y a rien. Selon la sensibilité de l'application, une fausse alarme peut avoir des conséquences graves ou non. On note la probabilité de non détection P_m (*missing probability* en anglais) la probabilité que H_0 soit sélectionnée lorsque H_1 est vraie. La probabilité de détection est donc $P_d = 1 - P_m$ qui est la probabilité que H_1 soit sélectionné, quand elle est vraie, c'est-à-dire :

$$P_d = P(\Pi(\mathbf{y}) > \xi | H_1) \quad (1.4)$$

Supposons que les densités de probabilité sont connues sous les deux hypothèses. Selon le critère de Neyman-Pearson le meilleur système de détection est celui qui a la plus forte probabilité de détection sous la contrainte d'une fausse alarme donnée. Le théorème de Neyman-Pearson [8, 9, 10] stipule que, pour une probabilité de fausse alarme donnée, la statistique de test qui maximise la probabilité de détection (détecteur optimal) est le rapport de vraisemblance, en anglais connu sous le nom de *likelihood ratio test* (LRT), qui est donné par :

$$\Pi = \Theta(\mathbf{y}) = \frac{p(\mathbf{y}|H_1)}{p(\mathbf{y}|H_0)} \underset{\xi_{P_{fa}}}{\overset{H_0}{\leq}} \underset{H_1}{\geq} \quad (1.5)$$

Où $p(\mathbf{y}|H_j)$ est la densité de probabilité de \mathbf{y} sous l'hypothèse H_j ; $j \in \{0, 1\}$, $\Theta(\mathbf{y})$ est le rapport de vraisemblance et $\xi_{P_{fa}}$ est le seuil choisi de façon à ce que $P(\Theta(\mathbf{y}) > \xi_{P_{fa}} | H_0) = P_{fa}$.

Dans la pratique, les fonctions de densité de probabilité sous les hypothèses H_0 ou H_1 sont souvent dépendantes de plusieurs paramètres inconnus. Le LRT peut être réduit à un simple test si et seulement si les paramètres sont aléatoires et leurs densités de probabilités sont connues. Ensuite, le vecteur des paramètres inconnus peut être intégré et le test optimal de Neyman-Pearson s'obtient en calculant le rapport de vraisemblance moyenné :

$$\Theta_{moy}(\mathbf{y}) = \frac{\int_{\{\theta_1\}} p_{\theta_1}(\mathbf{y}|H_1)p(\theta_1|H_1)d\theta_1}{\int_{\{\theta_0\}} p_{\theta_0}(\mathbf{y}|H_0)p(\theta_0|H_0)d\theta_0} \quad (1.6)$$

avec $\{\theta_1\}$ et $\{\theta_0\}$ les paramètres inconnus ou aléatoires selon H_1 et H_0 , $p(\theta_1|H_1)$ et $p(\theta_0|H_0)$ leurs probabilités respectives. Dans la pratique il est souvent impossible de connaître la densité de probabilité des paramètres inconnus, une alternative est d'estimer les paramètres inconnus en utilisant l'approche du maximum de vraisemblance. Qui consiste à calculer le rapport de vraisemblance généralisé connu en anglais sous le nom de *generalized likelihood ratio test* (GLRT) [8, 10, 11] :

$$\Theta_{moy}(\mathbf{y}) = \frac{\max_{\theta_1} \{p_{\theta_1}(\mathbf{y}|H_1)\}_{\theta_1}}{\max_{\theta_0} \{p_{\theta_0}(\mathbf{y}|H_0)\}_{\theta_0}} \quad (1.7)$$

Le détecteur GLRT est donc un détecteur sous-optimal qui a souvent une performance satisfaisante. Maintenant, pour être en mesure de définir un seuil pour garantir une certaine fausse alarme il est nécessaire d'avoir une connaissance de la densité de probabilité

de l'hypothèse H_0 c.-à-d. du bruit. Si cette dernière densité est inconnue, il est préférable d'avoir des observations de référence du processus de bruit. Toutefois, la densité de probabilité du bruit est généralement connue, à l'échelle près. Par exemple, si le bruit est un processus blanc gaussien de moyenne nulle, uniquement la variance du bruit est inconnue. Ces détecteurs sont généralement appelés détecteurs avec un taux de fausse alarme constant.

Voici un exemple pour fixer les idées : on considère un signal déterministe \mathbf{x} (constitué de n observations discrètes) noyé dans un bruit aléatoire gaussien de moyenne zéro et de variance unité. Le problème est donc d'identifier les hypothèses suivantes :

$$\begin{aligned} H_0 &: \mathbf{y} = \mathbf{b} \\ H_1 &: \mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{b} \end{aligned} \quad (1.8)$$

\mathbf{b} est un vecteur colonne de n variables aléatoires gaussiennes de moyennes nulles et de covariance Σ_b . \mathbf{x} est un vecteur dont les éléments sont déterministes mais non connus et \mathbf{H} , la matrice qui représente le canal. La distribution de \mathbf{y} sous H_0 et H_1 ne diffère donc que par la moyenne, et s'énonce comme suit :

$$p(\mathbf{y}|H_0) = \frac{1}{(2\pi)^{\frac{n}{2}} \sqrt{|\Sigma_b|}} e^{-\frac{\mathbf{y}^T \Sigma_b^{-1} \mathbf{y}}{2}} \quad (1.9)$$

Et

$$p(\mathbf{y}|H_1) = \frac{1}{(2\pi)^{\frac{n}{2}} \sqrt{|\Sigma_b|}} e^{-\frac{(\mathbf{y}-\mathbf{H}\mathbf{x})^T \Sigma_b^{-1} (\mathbf{y}-\mathbf{H}\mathbf{x})}{2}} \quad (1.10)$$

Si on suppose que \mathbf{x} est connu, le log de vraisemblance s'écrit :

$$\ln(\Theta_{\text{moy}}(\mathbf{y})) = \ln\left(\frac{p(\mathbf{y}|H_1)}{p(\mathbf{y}|H_0)}\right) = \mathbf{y}^T \Sigma_b^{-1} \mathbf{H}\mathbf{x} - \frac{1}{2} \mathbf{x}^T \mathbf{H}^T \Sigma_b^{-1} \mathbf{H}\mathbf{x} \quad (1.11)$$

Comme le deuxième terme est non variable alors seulement le premier terme est comparé à un seuil afin de choisir entre H_0 et H_1 . Ce premier terme est appelé la statistique de test. Or, si \mathbf{x} est inconnu (c.-à-d. la distribution $p(\mathbf{y}|H_1)$ aussi inconnue) on applique donc le principe de maximum de vraisemblance (GLRT). Pour calculer le rapport de vraisemblance, \mathbf{x} est donc remplacé par son estimateur de maximum de vraisemblance $\tilde{\mathbf{x}}$, qui est donné par [12] :

$$\tilde{\mathbf{x}} = (\mathbf{H}^T \Sigma_b^{-1} \mathbf{H})^{-1} \mathbf{H}^T \Sigma_b^{-1} \mathbf{y} \quad (1.12)$$

à condition que $\mathbf{H}^T \Sigma_b^{-1} \mathbf{H}$ soit non singulière, ce qui permet de déterminer le rapport de vraisemblance généralisé :

$$\mathcal{T}_{GLRT} = \mathbf{y}^T \Sigma_b^{-1} \mathbf{y} \quad (1.13)$$

Dans le cas où \mathbf{b} est non corrélé, Σ_b est diagonale et la statistique de test devient :

$$\mathcal{T}_{GLRT} = \sum_{i=1}^n y_i^2 \quad (1.14)$$

qui n'est rien d'autre que l'énergie du signal \mathbf{y} .

1.3 Performance d'un détecteur et courbe de ROC

Afin d'évaluer les performances d'un détecteur donné, dans des conditions données, il est souvent utile de tracer la courbe qui lie la probabilité de détection à la probabilité de fausse alarme. Cette courbe est appelée courbe de ROC, *receiver operating characteristic* [10]. Une caractéristique importante liée à ces courbes est qu'elles passent par le point d'origine et par le point (1,1) indépendamment des performances du détecteur. Si la courbe de ROC est en dessus de la première bissectrice alors on dit que le détecteur est efficace (cf. figure 1.2) puisque en moyenne il fait plus de bonnes décisions que de mauvaises ($P_d > P_{fa}$). Si la courbe de ROC est en dessous de la ligne de chance dans ce cas le détecteur est dit *stupide* puisque un simple tirage au sort donne de meilleures performances. À noter que la première bissectrice est appelée la ligne de chance puisqu'elle correspond au hasard pur ($P_{fa} = P_d$). Enfin pour comparer les performances de deux détecteurs pour une plage de fausse alarme donnée il suffit de voir lequel des détecteurs a une courbe de ROC supérieure sur cette plage. D'autres critères de comparaisons existent comme par exemple la comparaison de la surface entre la courbe de ROC et la ligne de chance [13].




FIGURE 1.2 – Exemple de courbe ROC montrant la probabilité de détection P_d en fonction de la probabilité de fausse alarme P_{fa}

1.4 Méthodes de détections non collaboratives

Dans cette section on expose les méthodes de détections non collaboratives c.-à-d. les méthodes utilisées uniquement par un seul US sans avoir recours à d'autre US ou bien à une source d'information extérieure sur l'état du canal (libre ou non). Cette section est divisée en deux sous sections, la première expose les méthodes de présence du signal et la deuxième les méthodes de reconnaissance des signaux à partir de leurs propriétés particulières.

1.4.1 Méthodes de présence du signal

Cette partie est à son tour divisée en deux parties, la première se focalise sur les méthodes de détections de trou dans le spectre. La deuxième partie se focalise sur les méthodes de détections de plusieurs trous simultanément dans le spectre large bande.

1.4.1.1 Méthodes de détections d'un trou

A. Filtre adapté

Il est bien connu que le filtre adapté réalise la performance de détection optimale dans le canal AWGN, comme le montre Tandra et Sahai dans [14], car il maximise le RSB. Les filtres adaptés exigent une connaissance parfaite de la forme d'onde émise, par exemple : la bande passante, l'ordre et le type de modulation, la fréquence porteuse, la forme des impulsions [15, 16]. Une telle détection cohérente nécessite un temps d'observation relativement court pour atteindre une performance donnée [15] par rapport à d'autres techniques dans cette section. Le filtrage adapté peut être utilisé dans diverses applications, comme dans [17] où les auteurs exploitent la partie commune des séquences AIS (*automatic identification system*) afin d'estimer la position des sources émettrices depuis un satellite.

A.1 Mise en œuvre

La plupart des technologies sans fil incluent dans la transmission une sorte de séquence pilote, afin de permettre l'estimation du canal, et donner une référence de synchronisation pour les messages suivants. Les systèmes secondaires peuvent exploiter les signaux pilotes en vue de détecter la présence de transmissions des systèmes primaires dans leur proximité en utilisant un filtre adapté. Si on suppose que :

- le détecteur de signal connaît la séquence pilote $x(k)$, la bande passante et la fréquence centrale du signal reçu,
- la séquence pilote est toujours introduite à chaque système de transmission primaire (liaison montante ou descendante),
- le détecteur de signal peut toujours recevoir de manière cohérente,

alors, si $y(k)$ est une séquence d'échantillons reçus à l'instant $k \in 1, 2, \dots, N$, la règle de décision peut être énoncée de la façon suivante [18] :

$$\begin{aligned} H_0 & : \mathcal{T}_{FA} < \xi \\ H_1 & : \mathcal{T}_{FA} > \xi \end{aligned} \quad (1.15)$$

avec

$$\mathcal{T}_{FA} = \sum_{k=1}^N y(k)x^*(k) \quad (1.16)$$

le critère de décision, ξ est le seuil de comparaison et $x^*(k)$ est le complexe conjugué de $x(k)$. La décision est simplifiée comme le filtre adapté maximise la puissance de \mathcal{T}_{FA} , cela signifie qu'il fonctionne bien, même dans un régime à faible RSB. Le filtre adapté a quelques inconvénients. Il faut se rappeler que si le filtre adapté essaie de faire correspondre une porteuse pilote incorrecte, il détecte un milieu vide et conclue à tort que la bande est libre. Deuxièmement, le filtre adapté exige que tous les accès au médium soient

« signés » par une transmission du pilote, mais ce n'est pas le cas en général. En outre, les séquences pilotes sont généralement transmises uniquement dans le sens descendant. Cela laisse les transmissions de liaison montante indétectables. Troisièmement, le filtre de réception adapté exige une cohérence, qui est généralement très difficile à réaliser dans la pratique.

A.2 Caractérisation du filtre adapté

La détection des signaux en utilisant le filtre adapté a été étudiée par Cabric, et al. [18] en se basant sur le modèle (1.2). Ils montrent que \mathcal{T}_{FA} est gaussienne :

$$\begin{aligned} H_0 & : \mathcal{T}_{FA} \sim \mathcal{N}(0, \sigma^2 \mathcal{E}) \\ H_1 & : \mathcal{T}_{FA} \sim \mathcal{N}(\mathcal{E}, \sigma^2 \mathcal{E}) \end{aligned} \quad (1.17)$$

où σ^2 est la variance du bruit et \mathcal{E} définit comme suit :

$$\mathcal{E} = \sum_{k=1}^N x(k)^2 \quad (1.18)$$

Sur la base de ces informations, les probabilités de fausse alarme P_{fa} et de détection P_d sont données par [19] :

$$P_{fa} = Q\left(\frac{\mathcal{T}_{FA}}{\sqrt{\mathcal{E}\sigma^2}}\right) \quad (1.19)$$

et

$$P_d = Q\left(\frac{\mathcal{T}_{FA} - \mathcal{E}}{\sqrt{\mathcal{E}\sigma^2}}\right) \quad (1.20)$$

avec $Q(\cdot)$ la fonction Marcum définie comme suit :

$$Q(u) \triangleq \frac{1}{\sqrt{2\pi}} \int_u^\infty e^{-v^2/2} dv = \frac{1}{2} \operatorname{erfc}(u/\sqrt{2}) \quad (1.21)$$

A.3 Remarque sur le filtre adapté

Malgré les avantages du filtre adapté, il est toutefois important de noter que, dans le cadre de la radio opportuniste, le signal transmis et ses caractéristiques sont généralement inconnus ou les connaissances disponibles ne sont pas précises. Dans ce cas, les performances du filtre adapté se dégradent rapidement, conduisant à des détections manquées [20]. En outre, cette approche ne convient pas pour les applications de la radio opportuniste, où différentes normes de transmissions peuvent être adoptées par les principaux utilisateurs [16]. En effet, dans ces cas, l'US exigerait un filtre adapté dédié pour chaque signal qui pourrait être présent dans l'environnement considéré, conduisant à des coûts prohibitifs et une grande complexité de mise en œuvre [16], de plus ce genre d'architecture n'est pas évolutif.

B. Radiomètre

Dans le passé, l'approche la plus couramment utilisée pour détecter la présence du signal était basée sur le détecteur d'énergie [21], aussi connu sous le nom de radiomètre,

qui effectue une mesure de l'énergie reçue dans un temps limité et sur une bande de fréquences donnée [21]. Cette mesure est comparée à un seuil qui dépend du niveau du bruit N_0 . La présence d'un signal est donc détectée lorsque l'énergie reçue est supérieure à ce seuil établi. Le radiomètre représente une méthode sous-optimale puisque la distribution probabiliste du signal à détecter est inconnue rendant impossible l'utilisation du rapport de vraisemblance classique (LRT) [22]. La détection d'énergie est largement utilisée en raison de sa faible complexité d'implémentation et de calcul. Le radiomètre ne nécessite aucune connaissance en ce qui concerne le signal à détecter lui permettant d'intervenir dans de nombreuses applications. Cependant, cette méthode présente plusieurs inconvénients [15, 23], qui peuvent limiter sa mise en œuvre dans le cadre de la radio opportuniste. En fait, le calcul du seuil utilisé pour la détection du signal est très sensible au niveau du bruit N_0 qui est inconnu et dans certains cas variables, par conséquent une petite erreur d'estimation sur le niveau du bruit cause une perte significative de performance [24] puisque une sous estimation du niveau du bruit (donc du seuil de détection) peut générer de fausses alarmes donc des opportunités manquées pour l'utilisateur secondaire, d'autre part une surestimation du niveau du bruit a pour conséquence de diminuer la probabilité de détection. Dans ce cas, si on est sous H_1 , l'utilisateur secondaire peut penser que le canal est libre tandis qu'il est occupé, il peut donc transmettre sur ce canal et causer de l'interférence pour l'utilisateur primaire. Ce dernier point sera mieux détaillé dans le chapitre suivant. Comme une solution à ce problème, le niveau de bruit peut être estimé dynamiquement en séparant les sous-espaces bruit et signal en utilisant la classification de signaux multiples comme par exemple en utilisant l'algorithme MUSIC [25]. La variance du bruit, qui est liée directement au niveau du bruit (cf. chapitre 2), est obtenue comme la plus petite valeur propre du signal d'entrée de l'autocorrelation. Ensuite, la valeur estimée est utilisée pour choisir le seuil pour satisfaire un taux de fausse alarme constant. Un algorithme itératif est proposé pour trouver le seuil de décision dans [26]. Un autre inconvénient pour la détection avec le radiomètre est qu'il n'est pas possible de distinguer entre les différents utilisateurs primaires en utilisant un détecteur d'énergie [16]. Enfin, un radiomètre ne peut fournir aucune information supplémentaire concernant le signal émis par les principaux utilisateurs [15, 27] (par exemple le standard de transmission, type de modulation, la bande passante, la fréquence porteuse) qui peut être utile afin de prévoir l'utilisation du spectre par les utilisateurs primaires [27], permettant d'éviter les interférences nuisibles tout en augmentant la capacité des réseaux RI [22]. De plus le radiomètre ne fonctionne pas d'une manière efficace pour détecter les signaux étalés [15]. Dans le chapitre 2 on exposera les équations du radiomètre avec ses performances d'une manière détaillée, sachant qu'on va l'utiliser afin de proposer de nouvelles architectures de détections.

C. Test de cyclostationarité

Comme écrit dans [6], *dans le cas le plus réaliste où les séquences transmises par le réseau primaire ne sont pas connues a priori du réseau secondaire, il est toujours possible d'isoler des propriétés intrinsèques aux signaux transmis de sorte à les identifier. En particulier, tout caractère de redondance dans un signal informatif permet de le différencier d'un signal purement gaussien non coloré. Ceci est toujours vérifié, par principe, pour un signal de télécommunications [28]. Notons en particulier le cas de l'OFDM qui utilise conventionnellement de larges préfixes cycliques, générant ainsi une redondance temporelle du signal émis.*

Ces signaux ont une particularité statistique appelée cyclostationarité qui est observée à travers leurs paramètres statistiques qui varient périodiquement dans le temps avec une période appelée période cyclique. Cette cyclostationnarité peut être extraite par l'exploitation des statistiques d'ordre supérieur du signal. Pour un signal cyclostationnaire, la fonction d'autocorrélation cyclique (resp. fonction de corrélation spectrale) prend des valeurs non nulles à certaines fréquences cycliques non nulles. Comme le bruit est supposé blanc et stationnaire (donc il n'est pas cyclostationnaire), sa fonction d'autocorrélation cyclique (resp. fonction de corrélation spectrale) prend des valeurs nulles sur toutes les fréquences cycliques non nulles. Par conséquent, il est possible de distinguer le signal du bruit en analysant leurs paramètres statistiques. Avant de parler des tests de détections qui se basent sur la cyclostationarité, on introduit dans la section 1.4.1.1.C.1 noté C.1 les notions mathématiques fondamentales et indispensables à savoir afin d'introduire la notion de cyclostationarité. Dans la section 1.4.1.1.C.2 noté C.2 on détaille un exemple de mise en évidence de la cyclostationarité des signaux télécom. Dans le chapitre 2 un état de l'art sera présenté sur les techniques de détection qui se basent sur la cyclostationarité vu que la détection cyclostationnaire sera employée dans les nouvelles architectures de détection proposées dans le chapitre considéré.

C.1 Rappel mathématique

La majorité des travaux qui relie la cyclostationnarité au domaine des communications a été établie par W.A. Gardner [29]. On rappelle dans cette section les notions mathématiques fondamentales et indispensables à savoir pour introduire la notion de cyclostationnarité. Dans la sous-section C.1.1 on commence par la définition de la moyenne et de l'autocorrélation. Dans la sous-section C.1.2 on rappelle la définition d'un processus stationnaire au sens large. Le processus stationnaire au sens strict et le processus cyclostationnaire au sens large sont définis dans les sous sections C.1.3 et C.1.4 respectivement. Enfin les fonctions d'autocorrélation cyclique et de corrélation spectrale sont présentées dans C.1.5 et C.1.6 respectivement.

C.1.1 Définition de la moyenne et de l'autocorrélation

L'autocorrélation temporelle à deux variables $r(t, \tau)$ est le point de départ pour introduire la cyclostationnarité, sa périodicité en fonction du temps provoque une redondance dans le domaine fréquentiel qui peut être détectée avec des méthodes avancées de traitement du signal et qui donnent une forte immunité à la détection du signal contre les

interférences. L'autocorrélation est la relation qui existe entre un signal donné et une version décalée d'un retard temporel τ de ce signal lui-même. Dans le cas général cette autocorrélation est fonction des deux variables : le temps t et le retard τ . Dans le cas particulier où le processus est stationnaire cette autocorrélation ne dépend que du retard τ . Dans le cas où $x(t)$ est un signal aléatoire (processus stochastique) une définition probabiliste s'énonce comme suit :

$$r_{xx}(t, \tau) = E[(x(t) \cdot x^*(t - \tau))] \quad (1.22)$$

ou bien

$$r_{xx}(t, \tau) = E[(x(t + \frac{\tau}{2}) \cdot x^*(t - \frac{\tau}{2}))] \quad (1.23)$$

où l'opérateur $E(\cdot)$ représente l'espérance mathématique.

De même, la définition de la moyenne probabiliste correspondante à la réalisation $x(t)$ s'énonce :

$$\mu_x(t) = E[x(t)] \quad (1.24)$$

C.1.2 Processus stationnaire au sens large

Un processus stationnaire au sens large est un processus qui vérifie les relations suivantes indépendamment de t :

$$E[x(t)] = \text{constante} \quad (1.25)$$

$$r_{xx}(t, \tau) = r_{xx}(\tau) \quad (1.26)$$

Cette propriété veut dire que les statistiques d'ordre 1 (moyenne) et d'ordre 2 (autocorrélation) ne dépendent pas de l'instant choisi t .

C.1.3 Processus stationnaire au sens strict

Un processus stationnaire au sens strict est un processus dont toutes les statistiques sont toujours invariantes, dans toute translation sur l'axe des temps. Dans le cadre de cette thèse la définition au sens large est suffisante et donc pour toute utilisation du terme stationnaire veut dire implicitement stationnaire au sens large (cette remarque sera valable aussi pour le cas cyclostationnaire).

C.1.4 Processus cyclostationnaire au sens large

Un processus cyclostationnaire au sens large est un processus dont la moyenne et la fonction d'autocorrélation sont périodiques au cours du temps, en d'autres termes les moments d'ordre 1 et 2 sont périodiques en fonction du temps, on a donc :

$$E[x(t)] = E[x(t + mT_0)] \quad (1.27)$$

$$r_{xx}(t, \tau) = r_{xx}(t + mT_0, \tau) \quad (1.28)$$

avec $m \in \mathbb{Z}$; T_0 est appelé la période cyclique fondamentale, ou bien la « période cachée ». Les harmoniques de T_0 sont aussi des périodes cycliques de $x(t)$.

C.1.5 Fonction d'Autocorrélation Cyclique

Comme $r_{xx}(t, \tau)$ est périodique et de période fondamentale T_0 elle admet donc selon la variable t une décomposition en série de Fourier :

$$r_{xx}(t, \tau) = \sum_{\alpha \in A_\alpha} R_{xx}(\alpha, \tau) e^{j2\pi\alpha t} \quad (1.29)$$

avec A_α l'ensemble défini comme suit : $A_\alpha = \{\alpha; \alpha = \frac{k}{T_0}, k \in \mathbb{Z}\}$ qui représente l'ensemble des fréquences cycliques. Pour $k = 1$ on a $\alpha = \alpha_f = \frac{1}{T_0}$ qui est la fréquence cyclique fondamentale du signal $x(t)$. À noter que les harmoniques de la fréquence cyclique fondamentale sont aussi des fréquences cycliques du signal $x(t)$. À noter aussi que le coefficient de Fourier $R_{xx}(\alpha, \tau)$ est nul si α n'est pas une fréquence cyclique quel que soit la valeur de τ . $R_{xx}(\alpha, \tau)$, appelée fonction d'autocorrélation cyclique (FAC) (d'autres auteurs notent la FAC simplement AC par exemple [30]), est définie comme n'importe quel coefficient de Fourier comme suit :

$$R_{xx}(\alpha, \tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} r_{xx}(t, \tau) e^{-j2\pi\alpha t} dt \quad (1.30)$$

ou bien d'une façon probabiliste (cf.[29]) :

$$R_{xx}(\alpha, \tau) = E[r_{xx}(t, \tau) e^{-j2\pi\alpha t}] \quad (1.31)$$

$$R_{xx}(\alpha, \tau) = E[x(t + \frac{\tau}{2}) \cdot x^*(t - \frac{\tau}{2}) e^{-j2\pi\alpha t}] \quad (1.32)$$

On peut interpréter cette dernière formule de la manière suivante, le terme $x^*(t - \frac{\tau}{2}) e^{-j2\pi\alpha t}$ est le conjugué de $x(t - \frac{\tau}{2}) e^{j2\pi\alpha t}$ qui n'est autre que le signal $x(t - \frac{\tau}{2})$ décalé en fréquence par la fréquence α . Cela veut dire qu'il existe une corrélation non nulle entre le signal $x(t)$ et le même signal décalé d'une fréquence α . Ce phénomène est connu sous le nom de « corrélation spectrale » et il est mis en évidence par la présence de la cyclostationnarité dans le domaine fréquentiel.

La FAC est une fonction continue de la variable τ et discrète de la variable α . Elle est non nulle pour quelques $\alpha \neq 0$ et pour $x(t)$ réel elle présente par rapport à α et τ les propriétés de symétries suivantes :

$$\begin{aligned} R_{xx}(\alpha, -\tau) &= R_{xx}(\alpha, \tau) \\ R_{xx}(-\alpha, \tau) &= R_{xx}^*(\alpha, \tau) \end{aligned} \quad (1.33)$$

Il faut noter que dans le cas stationnaire, cette FAC est nulle pour toutes les fréquences $\alpha \neq 0$. Pour $\alpha = 0$, la FAC devient exactement la fonction d'autocorrélation classique. Cette propriété du modèle cyclostationnaire fait de lui un modèle attractif dans beaucoup d'applications notamment en détection des signaux de télécommunications qui sont bien appropriés à ce modèle.

En pratique dans les modulations numériques la fréquence cyclique est liée à la période symbole et à la fréquence porteuse. Les signaux CDMA peuvent avoir encore des fréquences

cycliques liées à la période chip du code CDMA. A titre d'exemple un signal MDP2 Avec une mise en forme des symboles de type rectangulaire et de période symbole T_s , et une fréquence porteuse f_c possède les fréquences cycliques suivantes : $\pm 2f_c, \pm 1/T_s, \pm 2/T_s, \pm 3/T_s \dots \pm 2f_c \pm 1/T_s, \pm 2f_c \pm 2/T_s, \pm 2f_c \pm 3/T_s \dots$ [29, 31].

C.1.6 Fonction de Corrélation Spectrale

La densité spectrale de puissance (DSP) d'un processus est définie dans le cas stationnaire comme étant la transformée de Fourier par rapport à la variable τ de sa fonction d'autocorrélation. Dans le cas des processus cyclostationnaires cette définition reste toujours vraie [32] et nous donne la DSP instantanée définie donc par :

$$S_{xx}(t, f) = F_{/\tau} (r_{xx}(t, \tau)) \quad (1.34)$$

avec $F_{/\tau}$ désigne la transformée de Fourier par rapport à la variable τ . $S_{xx}(t, f)$ est donc la DSP instantanée. Cette DSP est aussi périodique en fonction du temps, et donc elle admet une décomposition en série de Fourier définie par :

$$S_{xx}(t, f) = \sum_{\alpha \in A_\alpha} \tilde{S}_{xx}(\alpha, f) e^{j2\pi\alpha t} \quad (1.35)$$

De même, l'ensemble A_α est l'ensemble des multiples entiers de la fréquence cyclique fondamentale α_f . Le coefficient de Fourier $\tilde{S}_{xx}(\alpha, f)$ est appelé la fonction de corrélation spectrale (FCS) (d'autres auteurs notent la FCS simplement CS par exemple [30]) et elle est donnée par :

$$\tilde{S}_{xx}(\alpha, f) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} S_{xx}(t, f) e^{-j2\pi\alpha t} dt \quad (1.36)$$

En remplaçant la fonction d'autocorrélation $r_{xx}(t, \tau)$ dans l'équation (1.34) par son développement en série de Fourier donnée par l'équation (1.29) et en identifiant le résultat obtenu au développement de l'équation (1.35) on obtient la relation suivante dans le domaine cyclique :

$$\tilde{S}_{xx}(\alpha, f) = F_{/\tau} (R_{xx}(\alpha, \tau)) \quad (1.37)$$

La FCS est donc la transformée de Fourier de la FAC, elle présente les mêmes propriétés que cette dernière (continue par rapport à la variable f et discrète par rapport à la variable α). Elle est non nulle pour quelques $\alpha \neq 0$ et pour $x(t)$ réel elle présente par rapport à α et f les propriétés de symétries suivantes :

$$\tilde{S}_{xx}(\alpha, -f) = \tilde{S}_{xx}(\alpha, f) \quad (1.38)$$

$$\tilde{S}_{xx}(-\alpha, f) = \tilde{S}_{xx}^*(\alpha, f)$$

À noter que pour $\alpha = 0$, la FCS se réduit au spectre classique comme définie dans le cas des processus stationnaires.

Entre les différentes fonctions définies jusqu'ici, l'application d'une ou plusieurs transformées de Fourier permet le passage d'une fonction à l'autre ou d'un domaine à un autre. La figure 1.3 montre ces relations de transformées de Fourier liant ces différentes fonctions.




FIGURE 1.3 – Les relations de transformées de Fourier entre les différentes fonctions de corrélations et de spectres en temporel et fréquentiel

C.2 Mise en évidence de la cyclostationnarité

Afin de mettre en évidence la cyclostationnarité des signaux télécom, on considère un des exemples très connu dans la littérature [32] qui met en évidence cette propriété. On prend une modulation linéaire, c.-à-d. le signal peut être écrit sous la forme :

$$x(t) = \sum_{n=-\infty}^{\infty} d(n)g(t - nT_s - \epsilon) \quad (1.39)$$

où $d(n)$ est une suite de symboles (réels ou complexes) de données indépendants et identiquement distribués i.i.d. (*i.e.*, tous les symboles suivent la même loi de probabilité et deux symboles successifs sont indépendants), $g(t)$ est la fonction de transfert du filtre de mise en forme, T_s est la période symbole et ϵ un retard temporel supposé inconnu. En appliquant la définition donnée dans l'équation (1.23) le calcul de la fonction d'autocorrélation donne :

$$r_{xx}(t, \tau) = E \left\{ \sum_{n=-\infty}^{\infty} \sum_{m=-\infty}^{\infty} d(m)d^*(n)g(t - mT_s - \frac{\tau}{2} - \epsilon)g^*(t - nT_s + \frac{\tau}{2} - \epsilon) \right\} \quad (1.40)$$

Comme les symboles sont i.i.d., alors $E\{d(m)d^*(n)\} = \sigma_d^2\delta(n - m)$ avec $\sigma_d^2 = E|d(n)|^2$. Après remplacement dans (1.40), $r_{xx}(t, \tau)$ s'écrit :

$$r_{xx}(t, \tau) = \sum_{n=-\infty}^{\infty} \sigma_d^2 g(t - nT_s - \frac{\tau}{2} - \epsilon)g^*(t - nT_s + \frac{\tau}{2} - \epsilon) \quad (1.41)$$

En observant l'équation (1.41) il est clair que la corrélation temporelle $r_{xx}(t, \tau)$ est une fonction périodique de période T_s , et donc le signal $x(t)$ est un signal cyclostationnaire de fréquence cyclique $\alpha_f = \frac{1}{T_s}$. La transformée de Fourier selon la variable t de cette fonction d'autocorrélation permet d'obtenir la FAC suivante :

$$R_{xx}(\alpha, \tau) = \begin{cases} \frac{\sigma_d^2}{T_s} e^{-j2\pi\alpha\epsilon} \int_{-\infty}^{\infty} g(t - \frac{\tau}{2})g^*(t + \frac{\tau}{2})e^{-j2\pi\alpha t} dt & \alpha = \frac{k}{T_s}, k \in \mathbb{Z} \\ 0 & \text{ailleurs} \end{cases} \quad (1.42)$$

Aussi on montre dans [29] que la fonction FCS s'écrit :

$$\tilde{S}_{xx}(\alpha, f) = \begin{cases} \frac{\sigma_d^2}{T_s} e^{-j2\pi\alpha\epsilon} G(f - \frac{\alpha}{2}) G^*(f + \frac{\alpha}{2}) & \alpha = \frac{k}{T_s}, k \in \mathbb{Z} \\ 0 & \text{ailleurs} \end{cases} \quad (1.43)$$

avec $G(f) = F_{/t}\{g(t)\}$.

Dans le cas particulier d'un filtre de mise en forme rectangulaire défini par :

$$g(t) = \begin{cases} 1 & |t| \leq \frac{T_s}{2} \\ 0 & \text{ailleurs} \end{cases} \quad (1.44)$$

les figures 1.4 et 1.5 montrent les modules théoriques de la FCS et de la FAC respectivement. Pour les fréquences cycliques α non nulles, on observe sur la figure 1.5 que $|R_{xx}(\alpha, \tau)|$ est maximum pour $\alpha = \pm \frac{1}{T_s}$ et $\tau = \pm \frac{T_s}{2}$.




FIGURE 1.4 – Module théorique de la FCS d'un signal linéairement modulé définie en (1.39) avec une mise en forme des symboles de types rectangulaires




FIGURE 1.5 – Module théorique de la FAC d’un signal linéairement modulé définie en (1.39) avec une mise en forme de symboles de types rectangulaires

D. Détection aveugle par l’utilisation de critères d’informations théoriques

La détection aveugle du spectre fondée sur des critères d’informations théoriques (*information theoretic criteria* (ITC)), qui ont été introduits par Akaike [33], Schwartz [34] et Rissanen [35], a été premièrement suggérée par [36, 37, 38]. Il ya deux ITC bien connus qui ont été largement utilisés : le critère d’information d’Akaike, *Akaike information criterion* (AIC) et le critère de longueur de description minimale, *minimum description length* (MDL). L’une des plus importantes applications de l’ITC est d’estimer le nombre de signaux sources dans l’*array signal processing* [39]. Considérons un modèle de système décrit comme :

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{b} \quad (1.45)$$

où \mathbf{y} est un vecteur d’observation complexe de dimensions $(p, 1)$, \mathbf{H} est une matrice complexe de dimensions (p, q) avec $(p > q)$, \mathbf{x} désigne le vecteur source des signaux modulés de dimensions $(q, 1)$. \mathbf{b} est un bruit complexe, additif blanc gaussien de moyenne nulle et de matrice de covariance $\mathbf{E}\{\mathbf{b}\mathbf{b}^H\} = \sigma^2\mathbf{I}$. Il est à noter que les paramètres q et \mathbf{H} sont inconnus. Les fonctions de coût résultantes de AIC et MDL ont les formes suivantes [39] :

$$AIC(k) = -2 \log \left(\frac{\prod_{i=k+1}^p \lambda_i^{1/(p-k)}}{\frac{1}{p-k} \sum_{i=k+1}^p \lambda_i} \right)^{N_{obs}(p-k)} + 2k(2p - k) + 2 \quad (1.46)$$

$$MDL(k) = -\log \left(\frac{\prod_{i=k+1}^p \lambda_i^{1/(p-k)}}{\frac{1}{p-k} \sum_{i=k+1}^p \lambda_i} \right)^{N_{obs}(p-k)} + \left(\frac{1}{2}k(2p - k) + \frac{1}{2} \right) \log N_{obs} \quad (1.47)$$

où N_{obs} désigne le nombre d’observations, et λ_i désigne la i -e valeur propre (dans l’ordre décroissant) de la matrice de covariance échantillonnée.

Dans [38] le critère utilisé est le AIC, le but est de trouver la valeur de q , à partir de N_{obs} observations de \mathbf{y} , puisque le bruit est de moyenne nulle et indépendant des signaux, il en résulte que la matrice de covariance de \mathbf{y} est donnée par :

$$\mathbf{R}_{ITC} = \Psi_{ITC} + \sigma_{inc}^2 \mathbf{I} \quad (1.48)$$

avec

$$\Psi_{ITC} = \mathbf{H}\Sigma_x\mathbf{H}^H \quad (1.49)$$

avec Σ_x désignant la matrice de covariance de \mathbf{x} , i.e., $\Sigma_x = E\{\mathbf{x}\mathbf{x}^H\}$, et σ_{inc}^2 est un scalaire inconnu. En outre, si q signaux non corrélés sont présents, les $p - q$ plus petites valeurs propres de \mathbf{R}_{ITC} sont égales à la puissance de bruit σ^2 . A partir du modèle de matrice de covariance donnée par l'équation (1.51), la famille de matrice de covariance considérée dans [38] est :

$$\mathbf{R}_{ITC}^{(k)} = \Psi_{ITC}^{(k)} + \sigma_{inc}^2 \mathbf{I} \quad (1.50)$$

où $\Psi_{ITC}^{(k)}$ désigne une matrice semi-positive de rang k . À noter que k varie sur l'ensemble de tous les nombres possibles de degré de liberté, i.e., $k = 0, 1, \dots, p - 1$. En utilisant l'algèbre linéaire, $\mathbf{R}_{ITC}^{(k)}$ peut être exprimée comme : $\mathbf{R}_{ITC}^{(k)} = \sum_{i=1}^k (\lambda_i - \sigma_{inc}^2) \mathbf{V}_i \mathbf{V}_i^H \sigma_{inc}^2$, où les \mathbf{V}_i sont les vecteurs propres correspondants aux valeurs propres λ_i de $\mathbf{R}_{ITC}^{(k)}$. Le nombre de signaux est déterminé à partir de l'estimation de la matrice de covariance $\hat{\mathbf{R}}_{ITC}$ définie par :

$$\hat{\mathbf{R}}_{ITC} = \frac{1}{N_{obs}} \sum_{i=1}^{N_{obs}} \mathbf{y}(t_i) \mathbf{y}(t_i)^H \quad (1.51)$$

Si $\lambda_1, \lambda_2, \dots, \lambda_p$ sont les valeurs propres de $\hat{\mathbf{R}}_{ITC}$ dans l'ordre décroissant alors le nombre des valeurs propres significatives, est déterminé à partir de la valeur de $k \in \{0, 1, \dots, p - 1\}$, qui minimise la valeur de l'AIC. Le nombre des valeurs propres significatives est égal à p (p est la dimension de la matrice $\hat{\mathbf{R}}_{ITC}$) sous H_0 et q sous H_1 , [36, 37]. Figure 1.6 et figure 1.7 représentent le comportement du critère AIC fonction de l'indice k des valeurs propres pour une bande occupée, (avec des slots UMTS) et libre, la dimension de la matrice de covariance est égale à 1000 (p). Le minimum de AIC est déterminé (AIC_{min}) afin d'obtenir le nombre de valeurs propres significatives. Il est clair que la position de AIC_{min} est situé à $k = 300$ pour les slots occupés (cf. figure 1.6) et à $k = 0$ pour les slots vacants (cf. figure 1.7). Selon [36, 37], le nombre des valeurs propres significatives dans le premier cas est égal à $q = 300$ et à $p = 1000$ pour le second cas.

A partir du critère AIC qui différencie d'une manière aveugle un signal d'un bruit les auteurs de [38] proposent un algorithme qui utilise ce critère et qui exploite la relation entre la pente de la courbe AIC et la présence/absence du signal. La validation de cette nouvelle technique a été faite d'une manière expérimentale en utilisant la plateforme « Eurécom Agile RF ». La comparaison avec le détecteur d'énergie (dans une situation réelle) montre de meilleures performances que cette nouvelle méthode en termes de probabilité de détection. Dans [40] les auteurs ont introduit un nouveau modèle de canal construit pour l'utilisation de plusieurs antennes de réception afin d'appliquer l'ITC. Puis, un algorithme simplifié de détection est présenté, qui a besoin de calculer et de comparer seulement deux valeurs d'AIC/MDL, l'algorithme simplifié réduit de façon significative la complexité de calcul sans perdre de performance. Les résultats de simulations ont montré




FIGURE 1.6 – AIC d'un slot temporelle UMTS occupé : $q = 300$. Figure extraite de [38].

que l'algorithme de détection aveugle proposé avec le critère AIC atteint une plus grande probabilité de détection comparée aux algorithmes de détection à base de valeurs propres tout en ayant la même probabilité de fausse alarme. D'autre part comparée au radiomètre idéal cette méthode reste toujours moins bonne, mais le dépasse dans le cas où il y a une incertitude sur la variance du bruit σ^2 [40].




FIGURE 1.7 – AIC d'un slot temporelle UMTS vacant : $p = 1000$. Figure extraite de [38].

1.4.1.2 Méthodes de détections larges bandes

A. Banc de filtres pour la détection large bande

Dans de nombreuses applications de la radio intelligente, un spectre de large bande doit être détecté, ce qui nécessite un taux d'échantillonnage élevé et donc une consommation d'énergie élevée dans les convertisseurs analogiques/numériques (A/N) [41, 3]. Une solution consiste à utiliser plusieurs filtres passe-bandes à bandes étroites *narrowband band pass filters* pour former un banc de filtres pour la détection large bande [42].

Dans [43], les auteurs étudient une architecture de détection multi-bandes basée sur les bancs de filtres polyphasés (PFB). Les expressions de la probabilité de détection et de fausse alarme des détecteurs basés sur la FFT et le PFB ont été obtenues théoriquement. Les résultats expérimentaux sont aussi présentés pour vérifier l'analyse théorique et démontrer que la détection basée sur le PFB a une meilleure performance que la détection basée sur la FFT conventionnelle.

Le concept de base de la détection multi-bande est d'estimer la densité spectrale de puissance (DSP) puis d'appliquer la détection de puissance dans le domaine des fréquences à partir des DSP estimés. Le PFB est proposé comme un outil efficace pour l'analyse spectrale, puisque chaque utilisateur secondaire pourrait être équipé de PFB. Cela signifie que la structure PFB utilisée pour les communications offrira une nouvelle opportunité pour

la détection.

Dans la littérature, les performances de la détection multi-bande sont en général comparées avec un estimateur basé sur le périodogramme (PSE). Les résultats de la simulation montrent un avantage significatif du PFB par rapport aux PSE. Néanmoins, la plupart de ces travaux utilise le *prolate sequence window* (PSW) comme filtre prototype du PFB. Cependant, ce filtre ne peut pas être réutilisé pour la communication.

Dans [43], les auteurs considèrent pour la détection multi-bandes un PFB basé sur un filtre prototype qui peut être utilisé pour la transmission. Les expressions théoriques des probabilités de détection et de fausse alarme des détecteurs à base de PFB et PSE sont obtenues, respectivement. Ainsi, les niveaux des seuils appropriés pour les différents détecteurs peuvent être choisis pour assurer une comparaison équitable. Les résultats expérimentaux vérifient l'analyse théorique et révèlent que le PFB est un meilleur analyseur de spectre que le PSE.

Les auteurs de [43] considèrent un système primaire à base de FBMC *filter bank based multicarrier* sur une large bande avec N_{all} sous-porteuses. La bande de fréquences utilisée par les UP est divisée en M_{sb} sous-bandes avec N_{sp} sous-porteuses par sous-bande. Les auteurs prennent en compte la détection des UP en utilisant des sous bandes de fréquences multiples au lieu de considérer une seule bande à la fois. L'architecture de base de détection multi-bande est donnée dans la figure 1.8. Il est à noter que la réalisation de la détection multi-bandes est composée de deux parties principales : l'une pour l'estimation de la puissance et l'autre pour sa détection. Chaque nœud secondaire dans le réseau de la radio intelligente est équipé avec une FFT ou un analyseur de spectre PFB pour l'estimation de puissance sur la bande d'intérêt. A partir de la densité spectrale de puissance estimée, le simple détecteur d'énergie est ensuite appliqué sur les différentes sous-bandes. Pour plus de détails sur cette méthode, les lecteurs sont invités à consulter le travail [43].

B. Transformée d'ondelette pour la détection du spectre large bande

L'inconvénient de l'utilisation d'un banc de filtres pour la détection large bande est qu'elle nécessite un nombre accru de composants et la bande de chaque filtre passe-bande étroite est pré-réglée. Dans [44], Giannakis. et. al. proposent une méthode de détection du spectre large bande utilisant la transformée d'ondelette sans avoir recours à de multiples filtres à bandes étroites. Cette méthode de détection sera exposée en détails dans cette section. Son objectif est d'identifier les endroits des fréquences qui délimitent les sous-bandes qui ne se chevauchent pas et de catégoriser les sous-bandes en noir, grise ou blanche [45], correspondantes à la DSP si elle est élevée, moyenne ou faible.

B.1 Rappel mathématique sur la transformée en ondelette

Avant d'exposer la méthode proposée dans [44] on commence par un rappel sur les transformées en ondelette. La transformée en ondelette a été jugée particulièrement utile pour analyser les signaux qui peuvent être décrits comme apériodiques, bruités, ou transitoires. L'analyse par ondelettes utilise une fonction connue sous le nom d'une ondelette

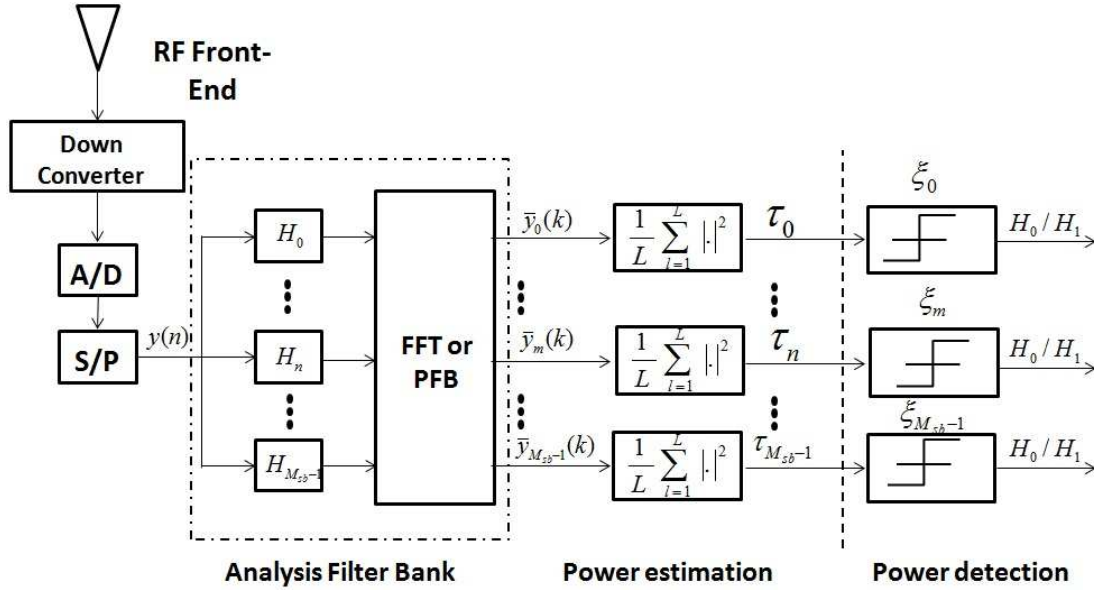


FIGURE 1.8 – L'architecture de base de détection multi-bandes

principale ψ à énergie finie. Les ondelettes sont utilisées pour transformer un signal donné dans une autre représentation qui présente les informations concernant le signal en forme plus utile. Une ondelette ψ est une fonction de moyenne nulle [46] :

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0, \quad (1.52)$$

qui est dilatée par un paramètre d'échelle s , et translatée de u :

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right) \quad (1.53)$$

La transformée en ondelettes de f à l'échelle s et à la position u se calcule en corrélant f avec l'ondelette correspondante :

$$Wf(u, s) = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \psi^*\left(\frac{t-u}{s}\right) dt \quad (1.54)$$

La transformée en ondelettes se réécrit dans le domaine fréquentiel en appliquant la formule de Parseval [46] :

$$Wf(u, s) = \int_{-\infty}^{+\infty} f(t) \psi_{u,s}^*(t) dt = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \bar{f}(w) \bar{\psi}_{u,s}^*(w) dw \quad (1.55)$$

Ainsi $Wf(u, s)$ ne dépend que des valeurs $f(t)$ et $\bar{f}(w)$ dans les voisinages temporels et fréquentiels où sont concentrées les énergies de $\psi_{u,s}$ et $\bar{\psi}_{u,s}^*$. Quelques ondelettes couramment utilisées sont montrées dans la figure 1.9. Les ondelettes peuvent être manipulées de deux façons : elles peuvent être déplacées le long de l'axe des fréquences (où temps) à divers endroits (paramètre de translation u) et aussi elles peuvent être étirées ou écrasées, concentrant ainsi l'énergie (facteur d'échelle s).




FIGURE 1.9 – Quelques ondelettes courantes : (a) l’ondelette de Coiflet (b) l’ondelette de Daubechies (c) l’ondelette de Morlet et (d) Mexican hat ou l’ondelette de Paul. Figure extraite de [47].

La transformée en ondelettes est calculée à divers endroits du signal et pour différents facteurs d’échelle de l’ondelette, remplissant ainsi le plan de transformation : ceci est fait d’une façon continue pour la transformée en ondelettes continues ou bien d’une manière discrète pour les transformées en ondelettes discrètes. Il est important de créer une ondelette mère qui fournit une description efficace et utile du signal d’intérêt. Il n’est pas facile de le faire, mais en se basant sur plusieurs principes généraux et des caractéristiques des fonctions d’ondelettes il est possible de déterminer l’ondelette la plus appropriée pour une application particulière.

B.2 Utilisation de la transformée en ondelette pour la détection du spectre

Dans [44] l’objectif est d’identifier les emplacements fréquentiels dans le spectre large bande, là où il n’y a pas de chevauchement dans les bandes de fréquences et ensuite classer ces bandes en catégories : noires, grises ou des espaces blancs, correspondantes au niveau de la densité spectrale de puissance (DSP) élevée, moyenne ou faible. Les auteurs modélisent la large bande entière comme un train de sous-bandes fréquentielles consécutives, dans lesquels la puissance spectrale est constante au sein de chaque sous-bande, mais présente un changement discontinu entre les sous-bandes voisines. Ces changements sont en fait des irrégularités dans le large spectre, qui portent des informations clés sur les lieux et les intensités des trous dans ce large spectre. Afin donc d’analyser les singularités et les structures irrégulières dans le spectre les auteurs utilisent la transformée en ondelettes, qui peut caractériser la régularité locale des signaux [46].

Le problème formulé dans [44] est le suivant : si un total de B Hz dans la gamme de fréquences $[f_0, f_N]$ est disponible pour un réseau à large bande sans fil. Le signal radio reçu par le récepteur de l’US occupe N bandes de fréquences, dont l’emplacement

des fréquences et les niveaux de DSP doivent être identifiés et détectés. Ces bandes de fréquences se trouvent dans l'intervall $[f_0, f_N]$ consécutivement, avec leurs extrémités en fréquences situés à $f_0 < f_1 \dots < f_N$. La n -e bande est donc définie par $B_n : \{ f \in B_n : f_{n-1} < f < f_n \}$, $n = 1, 2, \dots, N$. La structure de la DSP d'un signal à large bande est illustré à la figure 1.10. Les hypothèses de bases suivantes sont adoptées :




FIGURE 1.10 – N bandes de fréquences avec une DSP lisse par morceaux. Figure extraite de [44]

a1) Les extrémités de fréquence f_0 et $f_N = f_0 + B$ sont connus pour le détecteur intelligent. Même si le signal effectivement reçu peut occuper une plus grande bande, ce détecteur intelligent regarde $[f_0, f_n]$ comme la large bande d'intérêt et cherche uniquement des espaces blancs au sein de cette gamme de fréquences.

a2) Le nombre de bandes N et les positions f_1, \dots, f_{N-1} sont inconnues de la part du détecteur intelligent. Elles restent inchangées dans une durée de temps, mais peuvent varier à la présence d'évanouissements lents.

a3) La DSP au sein de chaque bande B_n est lisse et presque plate, mais présente des discontinuités avec ces bandes voisines B_{n-1} et B_{n+1} . De telles irrégularités dans la DSP ne se manifestent que sur les extrémités des N bandes B_n .

a4) Le bruit ambiant est additif blanc gaussien avec une moyenne nulle et de densité spectrale de puissance bilatérale $S_b(f) = \frac{N_0}{2}, \forall f$.

En absence du bruit, la DSP normalisée (inconnue) dans chaque bande B_n est indiquée par $S_n(f)$, qui remplit les conditions suivantes :

$$S_n(f) = 0, \forall f \notin B_n; \quad (1.56)$$

Selon a3), nous pouvons approximer $S_n(f)$ comme suit :

$$S_n(f) = 1, \forall f \in B_n; \quad (1.57)$$

pour $f \in B_n$ on peut écrire donc :

$$\int_{f_{n-1}}^{f_n} S_n(f) df = f_n - f_{n-1}. \quad (1.58)$$

Avec a3) et a4), la DSP du signal observée $y(t)$ par le détecteur intelligent peut être écrite comme :

$$S_y(f) = \sum_{n=1}^N \alpha_n^2 S_n(f) + S_b(f), \quad (1.59)$$

où α_n^2 indique la densité de puissance du signal dans la n -e bande. Le signal correspondant dans le domaine temporel est :

$$y(t) = \sum_{n=1}^N \alpha_n p_n(t) + b(t) \quad (1.60)$$

où $S_n(f)$ est le spectre du signal $p_n(t)$ et $b(t)$ désigne le bruit additif de la DSP $S_b(f)$.

En se basant sur a3) et en se référant à la figure 1.10, la détection du spectre large bande peut être considérée comme un problème de détection d'escalier dans une image représentée par la DSP $S_y(f)$ en fréquence. Les bords de cette image correspondent à l'emplacement des discontinuités de fréquence $\{f_i\}_{i=1}^{N-1}$, qui doivent être identifiés.

Ensuite les auteurs de [44] utilisent les résultats montrés dans [48] qui prouvent que la transformée en ondelettes peut caractériser efficacement les bords d'escalier exposés dans la structure de la DSP. En effet, il est montré dans [48] que les extremums locaux de la dérivée première et les passages par zéro de la dérivée seconde permettent de caractériser les irrégularités du signal. L'identification de $\{f_i\}_{i=1}^{N-1}$ peut donc être réalisée avec les deux propositions équivalentes suivantes :

$$P_1 \hat{f}_n = \max_f \{|W' S_y(0, s)|\}, f \in [f_0, f_N] \quad (1.61)$$

ou bien

$$P_2 \hat{f}_n = \text{zeros}_f \{|W'' S_y(0, s)|\} \quad (1.62)$$

Après que les $\{f_i\}_{i=1}^{N-1}$ ont été détectées et estimées par les équations (1.61) ou (1.62), la tâche du détecteur du spectre est d'estimer les $\{\alpha_i\}_{i=1}^{N-1}$. Pour cela, les auteurs commencent à calculer la DSP moyenne sur la bande B_n , $n = 1, \dots, N$, en utilisant l'intégrale :

$$\beta_n = \frac{1}{f_n - f_{n-1}} \int_{f_{n-1}}^{f_n} S_y(f) df \quad (1.63)$$

Sur la base des hypothèses (a3) et (a4), et des approximations (1.56) et (1.57) sur la forme de la DSP, il est évident que β_n est lié à α_n^2 par $\beta_n \approx \alpha_n^2 + \frac{N_0}{2}$. Apparemment, $\beta'_n = \frac{N_0}{2}$ est la plus petite valeur possible pour tous les $\{\beta_n\}$, puisque l'utilisation du spectre dans les systèmes actuels sans fil est assez faible (en dessous de 20%). Et donc pour chaque bande de fréquence B_n la densité spectrale α_n^2 peut être estimée à partir de $S_y(f)$ avec :

$$\hat{\alpha}_n^2 = \beta_n - \min_{n'} \beta_{n'}, n' = 1, \dots, N \quad (1.64)$$

Enfin, suivant les valeurs obtenues de $\hat{\alpha}_n^2$, les bandes détectées B_n peuvent être classées en noire, grise ou blanche.

Une approche similaire a ensuite été proposée dans [47], à la différence de l'approche de [44] qui utilise les dérivées d'ordre 1 ou 2, dans leurs approches les auteurs n'utilisent

que la transformée continue en ondelettes en utilisant différentes ondelettes mères connues sous le nom de « Mexican Hat » et « Harr » afin de détecter les escaliers dans la fonction de DSP d'une manière plus rapide. Les résultats montrent que suivant les ondelettes mères choisies les performances varient.

Dans des situations réelles, les DSP apparaissant aux bornes des détecteurs intelligents ont tendance à fluctuer dans le temps, et dans de tels cas, un modèle probabiliste doit être utilisé pour la détection des trous du spectre afin d'avoir un détecteur qui fonctionne dans la pratique. Actuellement, les modèles développés utilisent des signaux statiques. Aussi une mise en œuvre des systèmes analogiques se basant sur la transformée en ondelettes pour la détection est proposée dans [49, 50, 51] pour la détection grossière [52]. Cette mise en œuvre analogique rend possible la détection grossière à faible consommation d'énergie et en temps réel. Une détection multi-résolution est réalisée en modifiant les fonctions de bases sans aucune modification au circuit de détection est expliquée dans [49].

Dans [53] les auteurs s'inspirent d'une méthode algébrique utilisée dans l'électroencéphalographie (*EEG*) pour la détection des pointes et du travail de Giannakis et. al. proposé dans [44]. La méthode algébrique utilisée dans la détection des extrema dans les (*EEG*) a initialement été développée dans [54, 55]. Les auteurs de [53] modélisent algébriquement les discontinuités du spectre large bande, ensuite l'information tirée de ces irrégularités (en utilisant cette nouvelle méthode algébrique), sera exploitée afin de dériver un algorithme de détection des trous dans le spectre. Ce nouvel algorithme de détection est plus performant que le radiomètre avec une complexité comparable à celui-ci. Les résultats de simulations numériques montrent des performances satisfaisantes en termes de détection. Une description plus complète de cette nouvelle méthode de détection peut être trouvée dans [56, 57, 58].

C. Détection du spectre large bande en utilisant le compressed sensing

Pour détecter un large spectre de fréquence, une grande fréquence d'échantillonnage est requise, ce qui est très difficile pour la mise en œuvre pratique. Heureusement, si une grande partie du spectre est vacante, ce qui le rend parcimonieux dans le domaine fréquentiel, sa reconstruction (ou estimation) peut être faite en utilisant la technique du compressed sensing [59, 60, 61], qui nous permet de l'estimer en utilisant une fréquence d'échantillonnage inférieur à la fréquence de Nyquist, ce qui relâche les contraintes pour la mise en œuvre pratique. L'idée d'estimer le spectre large bande utilisant le compressed sensing a été introduite dans [62]. L'échantillonnage aléatoire avec un taux inférieur à la fréquence d'échantillonnage de Nyquist est utilisé pour formuler un problème de reconstruction du signal, qui utilise ensuite le détecteur basé sur les ondelettes données par les mêmes auteurs de [62], dans [44], que nous avons présenté dans la section B.

Supposons que la fenêtre temporelle pour la détection est $t \in [0, M_{cs}T_{nyq}]$, où T_{nyq} représente la période d'échantillonnage de Nyquist. En utilisation le théorème d'échantillonnage de Nyquist, M_{cs} échantillons sont nécessaires pour récupérer $y(t)$ sans aliasing. Un décodeur numérique convertit le signal $y(t)$ du domaine continu à une séquence discrète $\mathbf{r}_t \in \mathbb{C}^{K_{cs}}$ de longueur K_{cs} . Le procédé d'échantillonnage peut être exprimé dans le domaine temporel discret avec la forme générale suivante :

$$\mathbf{r}_t = \mathbf{S}_p^T \mathbf{y}_t \quad (1.65)$$

où \mathbf{S}_p est une matrice de projection de dimension $M_{cs} \times K_{cs}$ et \mathbf{y}_t représente le vecteur de dimension $M_{cs} \times 1$ avec les éléments $y_t[n] = y(t)|_{t=nT_{nyq}}$, $n = 1, \dots, M_{cs}$. Les colonnes $\{\mathbf{s}_k\}_{k=1}^{K_{cs}}$ de \mathbf{S}_p peuvent être considérées comme un ensemble d'une base, tandis que les mesures $\{r_t[k]\}_{k=1}^{K_{cs}}$ sont essentiellement la projection de $y(t)$ sur cette base. Le modèle (1.65) subsume tous les plans d'échantillonnage donnant des mesures linéaires. Par exemple, $\mathbf{S}_p = \mathbf{I}_{M_{cs}}$ représente un échantillonnage uniforme de Nyquist, où $\mathbf{I}_{M_{cs}}$ est la matrice identité de taille M_{cs} ; $\mathbf{S}_p = \mathbf{F}_{M_{cs}}$ revient à l'échantillonnage dans le domaine fréquentiel, où $\mathbf{F}_{M_{cs}}$ est la matrice de transformée de Fourier discrète de taille M_{cs} . Lorsque $K_{cs} < M_{cs}$, un taux réduit d'échantillonnages (inférieur au taux de Nyquist) s'applique.

Une des approches proposées dans [62] pour la détection du spectre avec une complexité réduite utilise les quatre étapes suivantes :

1. l'échantillonnage aléatoire comprimé ($K_{cs} < M_{cs}$) (*compressed random sampling*) pour générer \mathbf{r}_t à partir de \mathbf{y}_t
2. la reconstruction de la réponse en fréquence $\mathbf{y}_f = \mathbf{F}_{M_{cs}} \mathbf{y}_t$ à partir de \mathbf{r}_t
3. l'estimation du nombre N des bandes de fréquence ainsi que les emplacements $\{f_i\}_{i=1}^{N-1}$ en utilisant $\hat{\mathbf{y}}_f$
4. l'estimation de l'amplitude moyenne de \mathbf{y}_f dans chaque sous-bande identifier

Il est important de souligner que l'étape 2 fait une reconstruction du spectre \mathbf{y}_f représentée par M_{cs} échantillons de fréquence, alors que l'ensemble de la mesure disponible \mathbf{r}_t est d'une taille réduite de $K_{cs} (< M_{cs})$ éléments. À noter aussi que les étapes 3 et 4 sont effectuées en utilisant le détecteur utilisant les ondelettes proposées dans [44].

Soit \tilde{F} le domaine des fréquences non nulles dans le support fréquentiel de $y(t)$ dans le cas non bruité. Il est généralement considéré que l'amplitude de \tilde{F} , notée $|\tilde{F}|$ vérifie $|\tilde{F}| \ll B$ [42], indiquant la nature parcimonieuse de $y(t)$ dans le domaine fréquentiel. D'une manière équivalente, la réponse en fréquence du vecteur \mathbf{y}_f contient en moyenne $K_b := \lceil |\tilde{F}|/B \times M_{cs} \rceil$ éléments non nuls dans le cas non bruité, avec $K_b \ll M_{cs}$ et $\lceil \cdot \rceil$ dénote la partie entière supérieure. Les principaux résultats en compressed sensing montrent que le vecteur \mathbf{y}_f creux, peut être asymptotiquement récupéré à partir de $K_{cs} (< M_{cs})$ échantillons de $y(t)$, tant que $K_{cs} > K_b$. Ces échantillons \mathbf{r}_t peuvent être générés à partir de (1.65) via un échantillonnage non uniforme [63] qui permet la récupération parfaite de \mathbf{y}_f dans le cas non bruité. On note \mathbf{S}_c , la matrice d'échantillonnage à taux réduit de dimensions $M_{cs} \times K_{cs}$ où $K_b < K_{cs} \ll M_{cs}$. Un exemple simple de \mathbf{S}_c , est une matrice de sélection qui conserve au hasard K_{cs} colonnes de la matrice identité de taille M_{cs} , ce qui signifie que $M_{cs} - K_{cs}$ instants sur la grille d'échantillonnage sont ignorés.

Avec les K_{cs} mesures $\mathbf{r}_t = \mathbf{S}_c^T \mathbf{y}_t$, on estime maintenant la réponse en fréquence de $y(t)$ sous la forme de $\mathbf{y}_f = \mathbf{F}_m \mathbf{y}$. Pour un échantillonneur linéaire donné $\mathbf{S}_c : \mathbb{C}^{M_{cs}} \rightarrow \mathbb{C}^{K_{cs}}$, il faut chercher une fonction non linéaire $R(\cdot) : \mathbb{C}^{K_{cs}} \rightarrow \mathbb{C}^{M_{cs}}$ qui offre une reconstruction approximative de $\mathbf{y}_f \in \mathbb{C}^{M_{cs}}$ depuis $\mathbf{r}_t \in \mathbb{C}^{K_{cs}}$ basée sur l'égalité de la transformation linéaire $\mathbf{r}_t = (\mathbf{S}_c^T \mathbf{F}_{M_{cs}}^{-1}) \mathbf{y}_f$. Il s'agit d'un problème inverse linéaire avec la contrainte de

parcimonie, qui est NP-hard. L'approche intuitive pour la reconstruction du signal est l'utilisation du *basis pursuit* (BP) [64], qui transforme la contrainte de parcimonie sur \mathbf{y}_f en une optimisation convexe qui peut être résolue facilement en programmation linéaire :

$$\mathcal{P}_1 : \hat{\mathbf{y}}_f = \underset{\mathbf{y}_f}{\operatorname{argmin}} \|\mathbf{y}_f\|_1, \quad \text{s.t.} \quad (\mathbf{S}_c^T \mathbf{F}_{M_{cs}}^{-1}) \mathbf{y}_f = \mathbf{r}_t \quad (1.66)$$

à côté du BP, un certain nombre de méthodes de reconstructions efficaces existent, notamment l'*orthogonal matching pursuit* (OMP), Lasso etc... Ces algorithmes et d'autres vont être présentés dans l'état de l'art sur la parcimonie et le *compressed sensing* dans le chapitre 3.

Une autre approche aussi présentée dans [62] consiste à détecter et estimer directement les bandes de fréquences en estimant la dérivée du spectre qui est aussi parcimonieuse et présente des pics sur les irrégularités du spectre.

Comme la reconstruction inverse des problèmes parcimonieux est souvent coûteuse en temps et aussi en consommation d'énergie, on propose dans [65] une méthode de détection large bande qui utilise un sous échantillonnage non uniforme (inférieure à la fréquence de Nyquist), ensuite comme les échantillons sont corrélés en temporel les auteurs de [65] estiment les échantillons manquants en utilisant l'algorithme de l'*expectation-maximisation* (EM) [66, 67]. Il est montré ensuite par simulation que la combinaison du sous échantillonnage et de l'application de l'algorithme de l'EM donne des performances de détection satisfaisante et réduit la consommation en énergie.

Des versions coopératives de détection large bande en utilisant le *compressed sensing* ont également été développées [68, 69, 70, 71]. Les US peuvent faire une décision locale sur la présence ou l'absence d'un UP, et ces résultats peuvent être fusionnés de manière centralisée ou décentralisée. Toutefois, un plus grand gain de coopération peut être réalisé par fusion de toutes les mesures comprimées (*compressed measurements*) de manière centralisée ou décentralisée [3].

1.4.2 Méthodes de reconnaissance du signal

Dans cette section on décrit les méthodes de détection qui exploitent des propriétés particulières du signal afin de l'identifier (détecter), comme la bande passante du signal, la cyclostationarité (ou signature cyclostationnaire) créée par les porteuses pilotes ou introduites artificiellement, le type de modulation etc. On note que le filtre adapté et la détection cyclostationnaire qui se base sur les caractéristiques cyclostationnaire du signal à détecter (autre que la détection des signatures cyclostationnaires) sont deux méthodes de reconnaissance du signal par excellence et sont déjà présentées dans les sections 1.4.1.1.A et 1.4.1.1.C respectivement.

1.4.2.1 La reconnaissance de bande passante du canal

Comme écrit dans [6], dans [72, 73] il a été montré en 2001 que le paramètre bande passante du canal (BPC) d'un standard donné était complètement discriminant. Les auteurs ont utilisé un réseau de neurone RBF (*Radial Basis Function*) afin de comparer les

densités spectrales de puissances (DSP) des signaux reçus avec des DSP de références, données par l'équation (1.67), des différents standards à identifier. La forme de la bande passante est donnée par le filtre de mise en forme et par la largeur de bande. Cette forme est spécifique à chaque standard et peut donc être reconnue par un réseau de neurones de type RBF. L'avantage d'un réseau de neurones pour la recherche de la bande passante du canal BPC est qu'il effectue une reconnaissance de forme sur le spectre de signaux. Il tient donc compte des paramètres largeur de bande, modulation et filtre de mise en forme. De plus il est résistant aux perturbations engendrées par le canal de transmission.

$$\gamma_{ref}(k) = |Fem_s \left(\frac{f_p}{f_e} - k \right)|^2 \gamma_{mod} \left(\frac{f_p}{f_e} - k \right) \quad (1.67)$$

avec γ_{ref} la DSP du signal référence, Fem_s le filtre de mise en forme (racine de Nyquist, par exemple) de la porteuse modulée P du standard S considéré et $\gamma_{mod} \left(\frac{f_p}{f_e} - k \right)$ la densité spectrale de puissance de la modulation de la porteuse P du standard S . Le signal multistandard reçu, échantillonné à la fréquence f_e est donné par l'équation (1.68) :

$$x(kT_e) = \sum_{s=1}^S \sum_{p=1}^P h_{s,p}(kT_e) * \left(Fem_s(kT_e) * m_{s,p}(kT_e) e^{(2j\pi \frac{kf_p}{f_e})} \right) + b(kT_e) \quad (1.68)$$

avec $Fem_s(kT_e)$ le filtre de mise en forme, $m_{s,p}(t)$ la modulation relative à la porteuse P du standard S , $h_{s,p}(kT_e)$ la réponse du canal de la porteuse P du standard S , $T_e = \frac{1}{f_e}$ est la période d'échantillonnage et $b(kT_e)$ le bruit additif. La DSP de ce signal est obtenue à l'aide d'un périodogramme moyenné. Ce spectre contient donc la somme de p canaux qui sont chacun le produit des différentes densités spectrales des modulations par le filtre de mise en forme multiplié par les perturbations fréquentielles du canal. A l'aide du réseau de neurones montré dans [6] ce spectre réel est comparé avec une base de spectres de référence donnée par l'équation (1.67).

Avec l'apparition de nouveaux standards IEEE, la discrimination avec le détecteur précédent n'est plus suffisante. En particulier, il n'est pas possible de discriminer le Bluetooth et le Wi-Fi 802.11b à 2,4 GHz. En effet, ces deux standards peuvent coexister dans la même bande et en même temps et leurs spectres sont identiques.

1.4.2.2 Identification du système présent en utilisant les symboles pilotes

Les auteurs de [74] étudient les systèmes OFDM existants (Wifi, WiMAX, DVB-T etc.), et remarquent que les symboles pilotes, utilisés pour l'estimation du canal et/ou des opérations de synchronisation, sont souvent dupliqués dans le plan temps-fréquence en suivant une distribution particulière. Cette propriété induit de la corrélation entre les porteuses pilotes qu'ils proposent d'exploiter conjointement avec la périodicité de la position de ces pilotes dans le plan temps-fréquence pour effectuer l'identification. La répartition des porteuses pilotes OFDM dans le plan temps-fréquence est toujours déterministe pour répondre aux contraintes d'estimation du canal. Par exemple, dans [75] il est démontré que les pilotes optimaux, au sens du minimum de l'erreur quadratique moyenne d'estimation du canal, sont ceux qui sont identiquement espacés en fréquence et de même puissance. L'emplacement et la périodicité de ces porteuses pilotes créent une cyclostationarité qui est vue comme une signature spécifique et discriminante du système utilisé.

Ces signatures sont appelées structures « PIC » pour *pilot induced cyclostationarity*. A titre d'exemple, les structures pilotes DVB-T, Wifi et WiMAX peuvent être vues comme des signatures PIC (non intentionnelles) et chacune de ces signature est spécifique ce qui permet la discrimination entre les systèmes.

Après avoir déterminé les PIC de chacun des systèmes OFDM, les auteurs de [74] proposent un test de détection contraint par un taux de fausse alarme constant.

Cette nouvelle méthode d'identification/détection proposée dans [74] exploite les motifs cyclostationnaires embarqués dans les tons pilotes. Elle présente l'avantage :

- de discriminer des systèmes OFDM qui ont les mêmes paramètres de modulation
- de créer des signatures faciles à intercepter car les tons pilotes sont (quasiment) toujours présents dans le signal
- d'éviter d'ajouter de la signalisation dédiée aux opérations de détection/identification.

Les résultats de simulation prouvent l'efficacité du critère d'identification proposé dans un environnement de propagation doublement sélectif.

1.4.2.3 Détecteur de signature cyclostationnaire

L'idée de l'ajout d'une signature cyclostationnaire artificielle dans le signal émis qui est utilisé pour la détection des signaux OFDM a été initialement introduite dans [76]. Dans [77] les auteurs utilisent cette idée pour ajouter une signature cyclostationnaire artificiel pour la détection des signaux OFDM/OQAM (*orthogonal frequency division multiplexing carrying offset QAM*). Les auteurs de [77] dérivent les expressions explicites de l'auto-corrélation cyclique et de la corrélation spectrale pour les signaux OFDM/OQAM, et ont constaté que le signal OQAM a une très faible propriété cyclostationnaire inhérente. En effet même pour les signaux OFDM qui contiennent des caractéristiques cyclostationnaires en raison de l'insertion du cyclique préfixe, la détection fiable de cette cyclostationnarité requiert une architecture complexe et une longue observation [76]. Afin d'augmenter les propriétés cyclostationnaires, une signature cyclostationnaire peut être facilement générée sans ajouter une complexité supplémentaire à l'émetteur en mappant un ensemble de sous porteuse sur une deuxième série comme suit :

$$\gamma_{n,l} = \gamma_{n+p,l} \quad n \in N_{sp} \quad (1.69)$$

où $\gamma_{n,l}$ est le l -e message distribué indépendant et identiquement sur la n -e sous-porteuse, avec N_{sp} l'ensemble des sous-porteuses à mapper et p est le nombre de sous-porteuses entre sous-porteuses mappés. Ainsi, un motif de corrélation est créé et une signature cyclostationnaire est incorporée dans le signal par la transmission redondante des symboles. La figure 1.11 illustre comment la signature cyclostationnaire est générée par répétition des symboles dans une modulation multiporteuse.

La signature cyclostationnaire incorporée peut être facilement détectée en utilisant le détecteur de signature développée dans [76] qui est un détecteur à faible complexité nécessitant un faible temps d'observation. La détection peut aussi être améliorée en utilisant un nombre plus grand de sous-porteuse pour créer la signature cyclostationnaire mais cette augmentation du nombre de sous porteuses induit une diminution du débit utile à cause de l'augmentation de l'entête.




FIGURE 1.11 – Génération de signatures cyclostationnaires par répétition des symboles. Figure extraite de [43]

En pratique il faut faire un compromis entre le nombre de sous-porteuses utilisées pour faire la signature cyclostationnaire et les performances de détection désirées. Le seul inconvénient de cette méthode est la nécessité de faire une modification dans les émetteurs des UP.

1.4.2.4 D'autres détecteurs

Comme écrit dans [6], *suivant le degré d'autonomie souhaité de l'équipement et suivant le niveau de connaissance, a priori, sur les paramètres des couches physiques considérées, le nombre et le type de détecteurs pourraient appartenir à la liste (non exhaustive) ci dessous :*

- détection des fréquences porteuses et symboles
- reconnaissance du type de modulation
- reconnaissance du codage (codes convolutifs, codage en bloc, codage espace temps, etc.)
- reconnaissance du type d'accès
- détection de synchronisation

Détection de spectre dans les normes sans fil courante

Récemment dans une mise au point des normes sans fil, on observe l'introduction des fonctions intelligentes. Même s'il est difficile de s'attendre à un standard sans fil qui est basé sur la détection du spectre large bande et l'exploitation opportuniste du spectre, la tendance est dans cette direction [15]. On cite quelques technologies sans fil qui exigent une sorte de détection de spectre et d'adaptation pour l'accès dynamique au spectre comme l'IEEE 802.11k, *Bluetooth*, et la norme IEEE 802.22. Le standard IEEE 802.22 qui est connu en tant que « le standard de la radio intelligente », est présenté d'une manière plus détaillée dans l'annexe A.

1.5 Les détections collaboratives

La coopération est proposée dans la littérature comme une solution aux problèmes qui se posent dans la détection du spectre causés par l'incertitude du bruit, l'évanouissement, et l'ombrage. La détection coopérative diminue considérablement les probabilités d'erreurs de détections et de fausses alarmes. En outre, la coopération peut résoudre le problème des nœuds cachés et permet aussi de réduire le temps de détection [18, 78, 79]. L'interférence causée aux utilisateurs primaires par les dispositifs de la radio intelligente utilisant des mécanismes d'accès au spectre basés sur une simple écoute avant de parler *listen-before-talk* (LBT) est étudiée dans [80]. Les résultats montrent que même une simple détection locale peut être utilisée pour explorer la partie inutilisée du spectre sans causer de brouillage pour les utilisateurs existants. Dans [80], il a été montré analytiquement et par des résultats numériques, que la détection collaborative offre des gains beaucoup plus élevés que la détection locale. Le fait que la détection locale travaille sans aucune connaissance sur la localisation des utilisateurs principaux dégrade les performances de la détection.

La détection collaborative du spectre est plus efficace lorsque les détecteurs des US observent des évanouissements ou des ombrages (*shadowing*) indépendants [18, 81]. La dégradation des performances due au *correlated shadowing* est étudiée dans [82, 83] en termes de détection. Il se trouve qu'il est plus avantageux d'avoir la même quantité d'utilisateurs qui collaborent sur une grande surface que sur une petite surface. Toutefois, les utilisateurs intelligents doivent être capables de communiquer sans perturber le système primaire ils doivent être donc suffisamment proches les uns des autres. Ainsi, il y a un compromis à faire sur la distance entre les utilisateurs secondaires afin d'obtenir une bonne performance de détection et une communication intelligente qui ne perturbe pas les utilisateurs primaires [84].

Afin de lutter contre l'ombrage, des antennes directionnelles peuvent aussi être utilisées [18]. Dans [85], il est démontré que la coopération avec tous les utilisateurs du réseau ne nous laisse pas nécessairement atteindre l'optimum en termes de performances. Les terminaux intelligents avec le plus haut rapport signal (primaire) sur bruit sont choisis pour la collaboration afin d'obtenir de meilleures performances.

La coopération peut être à travers les radios intelligentes ou bien à travers des capteurs externes qui peuvent être utilisés pour construire un réseau coopératif de détection. Dans le premier cas, la coopération peut être mise en œuvre en deux modes : centralisée ou distribuée [86]. Ces deux méthodes et la méthode externe de détection sont discutées dans les sections suivantes.

Quelle que soit la méthode de détection utilisée afin d'éviter l'interférence avec les utilisateurs primaires, l'échange d'informations entre les utilisateurs secondaires se fait à travers un canal dédié (par exemple une bande non réglementée) ou canal de contrôle afin d'échanger les résultats de partage du spectre et de détection entre les US. Différentes architectures pour les canaux de contrôle sont proposées dans la littérature de la radio intelligente [87, 88].

La théorie des jeux pour le partage dynamique du spectre a été largement étudiée pour une utilisation plus flexible, plus efficace et plus équitable du spectre à travers l'analyse des comportements des utilisateurs du réseau intelligent. Cet aspect ne sera pas détaillé dans ce chapitre car il est situé en dehors des objectifs de cette thèse. Pour plus de détails sur la théorie des jeux pour le partage dynamique du spectre le lecteur peut éventuellement se référer aux articles suivants [89, 90].

1.5.1 Détection centralisée

Dans la détection centralisée, une entité centrale (appelée centre de fusion) rassemble toutes les informations de tous les utilisateurs secondaires pour prendre une décision sur l'état du canal, qui est ensuite retransmise à ses utilisateurs secondaires. Cependant, la communication des informations locales peut être très coûteuses pour des applications pratiques. Ainsi, dans de nombreux cas, seuls les utilisateurs envoient des données traitées/compressées au centre de fusion. Un simple système coopératif de détection basé sur la détection d'énergie est la détection d'énergie combinée. Pour cette méthode, chaque utilisateur calcule l'énergie du signal reçu de la manière suivante :

$$\mathcal{T}_{ED,i} = (1/N_{ech}) \sum_{n=0}^{N_{ech}-1} |y_i(n)|^2 \quad (1.70)$$

et l'envoi au centre de fusion, qui collecte les valeurs de l'énergie collectée en utilisant une combinaison linéaire (CL) afin d'obtenir le test de statistique suivant :

$$\mathcal{T}_{CL} = \sum_{i=1}^K g_i \mathcal{T}_{ED,i} \quad (1.71)$$

où g_i est le facteur de pondération, $g_i \geq 0$ avec $\sum_{i=1}^K g_i = 1$ avec K le nombre de récepteurs secondaires. S'il n'y a pas d'information sur la puissance du signal source reçue par chaque utilisateur, l'EGC (*equal gain combining*) peut être utilisé, c'est-à-dire $g_i = 1/K$ pour tout i . Si la puissance du signal primaire est connue par chaque utilisateur secondaire, les coefficients de la combinaison optimale peuvent être trouvés [91, 92]. Pour le cas de faible *RSB*, il peut être démontré [92] que les coefficients de la combinaison optimale sont donnés par :

$$g_i = \frac{\sigma_i^2}{\sum_{k=1}^K \sigma_k^2}, i = 1, \dots, K, \quad (1.72)$$

où σ_i^2 est la puissance reçue (à l'exclusion du bruit) du signal source de l'utilisateur i . Un schéma de fusion est donné dans [93], qui a la capacité de limiter les interférences et l'incertitude du bruit.

1.5.1.1 Détection en utilisant les valeurs propres

Les auteurs de [37] sont les premiers à avoir exploité les propriétés des valeurs propres dans le *spectrum sensing*. Ils calculent les valeurs propres de la matrice de covariance et utilisent une statistique de test fonction des valeurs propres comme il est montré dans la section 1.4.1.1.D. Cardoso et al. [94] et Zeng et al. [95], utilisent ensuite les valeurs propres pour développer une technique de détection coopérative. Cette technique est basée sur l'évaluation des valeurs propres d'une matrice formée par les échantillons recueillis par des capteurs multiples par rapport à la loi Marchenko-Pastur. Ici, nous allons explorer l'approche comme cela a été présenté dans [94], car l'approche dans [95] est très similaire.

Afin de mieux comprendre comment fonctionne cette technique de détection, nous commençons par les suppositions suivantes :

- Soit K le nombre des stations de base dans le système secondaire qui partagent des informations entre elles. Ce partage peut être effectué à l'aide d'un canal de contrôle à haut débit ;

– Les stations de base analysent la même portion du spectre.

Il est supposé que tous les récepteurs secondaires $\{RX_1, RX_2, RX_3, \dots, RX_K\}$, sont dans la portée d'un certain émetteur primaire comme le montre la figure 1.12. Alors, si l'hypothèse d'un canal plat est considérée, nous avons :

$$\begin{aligned} H_0 &: y_i(k) = b_i(k) \\ H_1 &: y_i(k) = h_i(k)x(k) + b_i(k) \end{aligned} \quad (1.73)$$

où i représente l'indice du récepteur secondaire. b_i le bruit additif (pas nécessairement Gaussien) de variance σ^2 reçu par le récepteur i , et h_i le canal entre l'utilisateur primaire et le récepteur secondaire. Considérons la matrice \mathbf{Y} de dimensions (K, N_{ech}) constituée




FIGURE 1.12 – Scénario de détections collaboratives avec RX_1, RX_2, \dots, RX_K le réseau secondaire. Figure extraite de [19], avec l'accord de l'auteur.

des échantillons reçus par les K récepteurs secondaires RX_i :

$$\mathbf{Y} = \begin{pmatrix} y_1(1) & y_1(2) & \dots & y_1(N_{ech}) \\ y_2(1) & y_2(2) & \dots & y_2(N_{ech}) \\ y_3(1) & y_3(2) & \dots & y_3(N_{ech}) \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ y_K(1) & y_K(2) & \dots & y_K(N_{ech}) \end{pmatrix}$$

L'objectif de l'approche est d'effectuer un test sur l'indépendance des signaux reçus par les RX_i . Comme indiqué précédemment, dans le cas H_1 , tous les échantillons reçus devraient être corrélés, alors que dans le cas H_0 , les échantillons sont décorrélés. Par conséquent, sous l'hypothèse H_0 et pour un K fixé et $N_{ech} \rightarrow \infty$, la matrice de covariance $\frac{1}{N_{ech}} \mathbf{Y} \mathbf{Y}^H$ converge vers $\sigma^2 \mathbf{I}_K$. En pratique, N_{ech} peut être du même ordre de grandeur que K et donc on ne peut pas conclure sur l'indépendance des échantillons à travers $\frac{1}{N_{ech}} \mathbf{Y} \mathbf{Y}^H$ directement. Ceci peut être formalisé en utilisant des outils de la théorie des matrices aléatoires [96]. Dans le cas où les entrées de \mathbf{Y} sont indépendantes (indépendamment de la distribution de probabilité, ce qui correspond à H_0), le résultat suivant qui dérive de la théorie asymptotique des matrices aléatoires [96] peut être utilisé :

Théorème. Considérons une matrice \mathbf{W} de dimensions (K, N) dont les entrées complexes (ou réelles) sont des variables aléatoires indépendantes de moyenne nulle, de variance $\frac{\sigma^2}{N}$ et de moments d'ordre quatre en $O(\frac{1}{N^2})$. Si, $K, N, \rightarrow \infty$ avec $\frac{K}{N} \rightarrow c$, la distribution empirique des valeurs propres de $\mathbf{W}\mathbf{W}^H$ converge presque sûrement vers une répartition non aléatoire de densité :

$$f(x) = (1 - \frac{1}{c})^+ \delta(x) + \frac{\sqrt{(x-a)^+(b-x)^+}}{2\pi cx}$$

où

$$a = \sigma^2(1 - \sqrt{c})^2$$

et

$$b = \sigma^2(1 + \sqrt{c})^2$$

qui est connue sous le nom de la loi Marchenko-Pastur.




FIGURE 1.13 – Le support de la loi Marchenko-Pastur sous H_0 . Figure extraite de [94], avec l'accord de l'auteur.

Sous l'hypothèse H_0 , le support des valeurs propres de la matrice de covariance (dans la figure 1.13, désigné par MP) est fini. La loi Marchenko-Pastur sert ainsi à une prédiction théorique du support sous l'hypothèse que la matrice n'est formée que des échantillons de bruits (H_0). Suite à cette limite théorique, la distribution des valeurs propres devrait indiquer donc l'existence des composants autres que le bruit.

Dans le cas où un signal est présent (H_1), \mathbf{Y} peut être réécrite comme :

$$\mathbf{Y} = \begin{pmatrix} h_1 & \sigma & 0 \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ h_k & 0 & \sigma \end{pmatrix} \begin{pmatrix} x(1) & \dots & x(N_{ech}) \\ z_1(1) & \dots & z_1(N_{ech}) \\ \cdot & & \cdot \\ \cdot & & \cdot \\ \cdot & & \cdot \\ z_K(1) & \dots & z_K(N_{ech}) \end{pmatrix}$$

où $x(k)$ et $z_i(k) = \sigma b_i(k)$ sont, respectivement, le signal et le bruit avec une variance unité à l'instant k et sur le récepteur secondaire i . Notons \mathbf{T} la matrice :

$$\mathbf{T} = \begin{pmatrix} h_1 & \sigma & 0 \\ \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot \\ h_k & 0 & \sigma \end{pmatrix}$$

il est clair que $\mathbf{T}\mathbf{T}^H$ a une seule valeur propre égale à $\lambda_1 = \sum |h_i|^2 + \sigma^2$ et toutes les autres sont égales à σ^2 . Le comportement des valeurs propres de $\frac{1}{N_{ech}}\mathbf{Y}\mathbf{Y}^H$ est lié à l'étude des valeurs propres des matrices de covariances de grandes dimensions [97]. Ici, le RSB noté ρ est défini comme :

$$\rho = \frac{\sum |h_i|^2}{\sigma^2} \quad (1.74)$$

Les travaux de Baik et al. [97, 98] ont montré que, lorsque :

$$\frac{K}{N_{ech}} < 1 \quad \text{et} \quad \rho > \sqrt{\frac{K}{N_{ech}}} \quad (1.75)$$

(qui sont des conditions largement remplies lorsque le nombre d'échantillons N_{ech} est suffisamment grand), la valeur propre maximale de $\frac{1}{N_{ech}}\mathbf{Y}\mathbf{Y}^H$ converge presque sûrement vers :

$$b' = \left(\sum |h_i|^2 + \sigma^2 \right) \left(1 + \frac{c}{\rho} \right) \quad (1.76)$$

qui est supérieure à la valeur de $b = \sigma^2(1 + \sqrt{c})^2$, vu dans le cas H_0 .

Par conséquent, chaque fois que la distribution des valeurs propres de la matrice $\frac{1}{N_{ech}}\mathbf{Y}\mathbf{Y}^H$ s'écarte de la loi Marchenko-Pastur, comme on le voit sur la figure 1.14, le détecteur décide donc l'hypothèse H_1 . Par conséquent, cette propriété est utilisée afin d'obtenir un moyen de détection. Soit λ_i les valeurs propres de $\frac{1}{N_{ech}}\mathbf{Y}\mathbf{Y}^H$ et $G = [a, b]$, le




FIGURE 1.14 – Le support de la loi Marchenko-Pastur sous H_1 . Figure extraite de [94], avec l'accord de l'auteur.

détecteur collaboratif fonctionne de deux manières possibles :

A. Distribution du bruit inconnue, variance connue

Dans ce cas, les critères de décision utilisés sont :

$$\begin{aligned} H_0 & \text{ si } \lambda_i \in G \\ H_1 & \text{ autrement} \end{aligned} \quad (1.77)$$

B. Distribution du bruit inconnue, et variance inconnue

Le rapport entre le maximum et le minimum des valeurs propres ($\frac{\lambda_{max}}{\lambda_{min}}$) sous l'hypothèse H_0 ne dépend pas de la variance du bruit et peut servir donc comme un critère indépendant du bruit. Le critère de décisions utilisées est donc :

$$\begin{aligned} H_0 & \text{ si } \frac{\lambda_{max}}{\lambda_{min}} \leq \frac{(1+\sqrt{c})^2}{(1-\sqrt{c})^2} \\ H_1 & \text{ autrement} \end{aligned} \quad (1.78)$$

Il convient de noter que, dans ce cas, il faut aussi prendre un nombre suffisamment élevé d'échantillons N_{ech} telles que les conditions de l'équation (1.75) soient satisfaites. En d'autres termes, le nombre d'échantillons croît quadratiquement avec l'inverse du rapport signal sur bruit. On note par ailleurs que le test sous l'hypothèse H_1 est également un bon estimateur du *RSB*. En effet, le rapport de la plus grande valeur propre b' sur la plus petite a de $\frac{1}{N_{ech}}\mathbf{Y}\mathbf{Y}^H$ est lié uniquement à ρ et c [94] :

$$\frac{b'}{a} = \frac{(\rho + 1)(1 + \frac{c}{\rho})}{(1 - \sqrt{c})^2} \quad (1.79)$$

1.5.2 Détection distribuée

Les techniques de coopérations considérées comme optimales nécessitent que tous les utilisateurs secondaires transmettent toutes leurs données à un centre de fusion, qui combine les valeurs (souples) afin de faire une décision commune. Cela est équivalent au cas où le centre de fusion a accès aux données reçues par tous les capteurs des US, et effectue une détection optimale basée sur toutes les données. Cela exige une énorme quantité de données à être transmises au centre de fusion. D'autres cas extrêmes de détecteurs coopératives sont de telle sorte que chaque capteur prend sa propre décision, et ne transmet qu'une valeur binaire au centre de fusion. Ensuite, le centre de fusion combine les décisions « *hard* » afin de prendre une décision commune. Ce dernier type de coopération est connu sous le nom de « coopération distribuée ». Les résultats présentés dans [99, 100] montrent que les méthodes centralisées surpassent les méthodes distribuées en termes de probabilité de détection. D'autre part, il est montré dans [101] que les méthodes distribuées peuvent atteindre les mêmes performances des méthodes centralisées lorsque le nombre d'utilisateurs qui coopèrent devient élevé [101].

Dans ce qui suit, nous allons décrire les règles ET, OU, et celle du VOTE (cf. [102, 103, 104, 18, 105, 106]), permettant de combiner des décisions « *hard* ». Supposons que

les statistiques individuelles $\Lambda^{(i)}$ sont quantifiées à un bit, c'est que $\Lambda^{(i)} \in \{0, 1\}$ est la décision « *hard* » du capteur i . Ici, 1 signifie que le signal est détecté et 0 signifie que le canal est disponible.

1.5.2.1 La règle ET

La règle ET décide que le signal est détecté si tous les capteurs ont détecté un signal. Autrement dit, le test de coopération, selon la règle ET décide H_1 si :

$$\sum_{i=0}^{K-1} \Lambda^{(i)} = K \quad (1.80)$$

1.5.2.2 La règle OU

La règle OU décide la présence du signal si l'un des capteurs détecte un signal. Ainsi, le test de coopération pour la règle OU décide H_1 si :

$$\sum_{i=0}^{K-1} \Lambda^{(i)} \geq 1 \quad (1.81)$$

1.5.2.3 La règle de VOTE

Enfin, la règle de VOTE décide qu'un signal est présent si au moins V des K capteurs ont détecté la présence d'un signal, avec $1 \leq V \leq K$. Le test décide donc H_1 si :

$$\sum_{i=0}^{K-1} \Lambda^{(i)} \geq V \quad (1.82)$$

Prendre une décision basée sur la majorité est un cas particulier de la règle de vote, pour $V = K/2$. Le ET logique et le OU logique sont clairement des cas particuliers de la règle de vote pour $V = K$ et $V = 1$ respectivement.

1.5.2.4 L'efficacité en énergie

Lorsque le nombre d'US qui coopèrent se développent, la consommation en énergie du réseau de la radio intelligente augmente, mais en général les performances en détection seaturent [84]. Par conséquent, des techniques ont été mises au point pour améliorer l'efficacité énergétique (la consommation) des US.

Une première technique simple pour économiser l'énergie, est le mode de détection « on-off » ou mode « veille », où la fonction de *sensing* de chaque US est activée/désactivée au hasard avec une probabilité μ , (le taux de veille) [84]. Cette technique peut être appliquée dans de nombreux différents contextes afin de réduire la consommation.

Une autre approche populaire est la « censure » [107]. Dans un système collaboratif qu'utilise la « censure » le détecteur i n'enverra une réponse de détection que si elle est informative, et censure les réponses qui sont peu informatives ou incertaines. Plus précisément, la réponse de détections ne sera pas envoyée lorsque $\eta_1^{(i)} \leq \Lambda^{(i)} \leq \eta_2^{(i)}$ et $\Lambda^{(i)}$ sera envoyée autrement. Dans [108], l'approche ci-dessus a été adoptée pour la détection

d'énergie binaire. Autrement dit, la décision locale est basée sur l'énergie collectée localement $\Lambda^{(i)} = \|\mathbf{y}_i\|^2$, le résultat ne sera pas envoyé si $\eta_1^{(i)} \leq \Lambda^{(i)} \leq \eta_2^{(i)}$, si $\Lambda^{(i)} < \eta_1^{(i)}$ le bit 0 sera envoyé, enfin si $\Lambda^{(i)} > \eta_2^{(i)}$ le bit 1 sera envoyé.

1.5.3 Détection externe

Une autre technique de détection collaborative n'utilisant pas les capteurs des US est la détection externe [15]. Dans cette technique, la détection est effectuée à travers un ensemble d'agents externes qui diffusent des informations d'occupation sur les canaux du réseau intelligent. La détection externe permet de résoudre certains problèmes liés à la détection interne où la détection est effectuée en interne par les US. Le principal avantage de la détection extérieure, est de surmonter le problème de détection causé par les utilisateurs primaires cachés, aussi ceci permet de résoudre les problèmes d'incertitudes liés à l'évanouissement et à l'effet d'ombrage. En outre, comme les US ne perdent pas de temps pour la détection, l'efficacité du spectre est augmentée. Le réseau de détection externe n'a pas besoin d'être mobile et pas nécessairement d'être alimenté par des batteries. Par conséquent, le problème de consommation de puissance pour la détection interne peut également être résolu [15]. Une architecture de réseaux de capteurs est proposée dans [109]; un réseau composé d'unités dédiées seulement pour le *sensing* est utilisé afin de faire des mesures d'une manière continue ou périodique. Les résultats sont communiqués à un nœud central qui traite les données de détection et partage l'information sur l'occupation du spectre dans la zone des US. Les US utilisent les informations obtenues à partir du réseau de détection pour la sélection des bandes (et de la durée) pour la transmission de leurs données. Les résultats de détections peuvent également être partagés via un canal de contrôle. A titre d'exemple la détection externe est une des méthodes proposées pour identifier les principaux utilisateurs de la norme IEEE 802.22 (pour plus de détails sur la norme IEEE 802.22 cf. annexe A).

1.6 Conclusion

Dans ce chapitre, l'état de l'art des plus importantes techniques de détections des trous dans le spectre pour la radio intelligente ont été couvertes. En outre, nous avons présenté leurs fonctionnements, caractéristiques, avantages et limites. Les techniques de détections étudiées à ce jour envisagent des scénarios bien précis. Pour certaines de ces techniques, il est clair que dans des environnements variables dans le temps, les performances de détection vont être largement inférieures. Pour plus de détails sur les méthodes de détections, le lecteur peut éventuellement se référer à des articles « *review* » sur le sujet [3, 1, 15, 110] ainsi qu'à leurs références.

Chapitre 2

Architecture hybride de détection de bandes libres

2.1 Introduction

Dans le chapitre 1 nous avons présenté les méthodes de détection les plus connues de la littérature consacrées au *spectrum sensing*. Ces méthodes sont présentées comme un test d'hypothèse binaire sur le signal reçu. La première hypothèse (H_0) stipule que le signal reçu est composé uniquement de bruit et la bande est alors déclarée libre. La seconde hypothèse (H_1) stipule que le signal reçu est composé à la fois de bruit et de signaux de télécommunications correspondante ainsi à une bande occupée.

Dans ce chapitre on retient deux méthodes de détections. D'une part le détecteur d'énergie (ou radiomètre) qui est une méthode de détection simple et rapide même à faible *RSB* [21, 111, 14], cependant elle nécessite une connaissance exacte du niveau du bruit N_0 afin de bien détecter comme nous l'avons expliqué en section 1.4.1.1.B du chapitre 1. D'autre part la détection cyclostationnaire qui est robuste face à la présence d'incertitude sur le niveau du bruit N_0 [111, 23], mais a une grande complexité de calcul. Nous proposons deux algorithmes combinant ces deux méthodes de détections aboutissant à des architectures hybrides qui possèdent une complexité voisine de celle d'un radiomètre. Le premier algorithme corrige itérativement les seuils d'un radiomètre à double seuil, qui finalement converge vers les performances du détecteur cyclostationnaire. Le second algorithme utilise le détecteur de cyclostationnarité afin d'estimer directement le niveau de bruit N_0 , qui est ensuite utilisé pour fixer le seuil du radiomètre. Les performances de détection de ce deuxième algorithme dépassent celles du détecteur de cyclostationnarité utilisé.

2.2 Détection des signaux aléatoires

On rappelle le test d'hypothèses (1.1) présenté lors du chapitre 1 :

$$\begin{aligned} H_0 & : y(t) = b(t) \\ H_1 & : y(t) = x(t) + b(t) \end{aligned} \tag{2.1}$$

C'est un test binaire composé de deux hypothèses. H_0 est l'hypothèse dite *nulle* correspondante à l'événement « signal absent » et H_1 est l'hypothèse dite *alternative* corres-

pondante à l'événement « signal présent ». Avec $y(t)$ le signal reçu, $x(t)$ le signal émis et $b(t)$ est un bruit blanc gaussien de variance inconnue. Un détecteur doit donc à partir de $y(t)$ en utilisant un traitement donné, décider entre H_0 ou H_1 . Avant d'introduire les nouvelles architectures de détections on introduit dans les deux sous-section suivantes, le radiomètre et les techniques de détections cyclostationnaires respectivement.

2.2.1 Radiomètre

Dans cette sous-section on étudie les équations du radiomètre et ces limites de fonctionnement, à la différence de la section 1.4.1.1.B du chapitre 1 ou seulement le radiomètre à été présenté d'une manière descriptive en présentant ses avantages et ses inconvénients.

Comme on l'a déjà vu dans la section 1.4.1.1.B du chapitre 1, le radiomètre ou détecteur d'énergie est un simple détecteur dont la statistique de test est proportionnelle à l'énergie du signal reçu. Dans le domaine temporel, la statistique de test est la suivante :

$$\mathcal{T}_{DE} = \frac{1}{T} \int_0^T y(t)^2 dt \quad (2.2)$$

Avec T le temps d'écoute du signal reçu. La statistique \mathcal{T}_{DE} est ensuite comparée à un seuil ξ donné. Si \mathcal{T}_{DE} est supérieur à ce seuil alors c'est H_1 qui est choisi autrement c'est H_0 .

Le schéma bloc du radiomètre est donné sur la figure 2.1. Urkowitz [21] a étudié le




FIGURE 2.1 – Schéma bloc du détecteur d'énergie.

radiomètre avec la statistique de test \mathcal{T}_{DE} de l'équation (2.2). Il a aussi étudié l'expression de la densité de probabilité de la variable aléatoire X qui représente l'ensemble des réalisations de la statistique de test \mathcal{T}_{DE} , et montre que pour un signal occupant une bande B , si le produit BT (*time-bandwidth product*) est large ($BT > 250$), la v.a. X suit une loi gaussienne sous les deux hypothèses H_0 et H_1 . La moyenne et la variance de cette loi gaussienne, sont données selon l'hypothèse par :

$$\begin{aligned} H_0 \quad \mu_1 &= N_0 BT, & \sigma_1^2 &= N_0^2 BT \\ H_1 \quad \mu_2 &= N_0 BT(RSB + 1), & \sigma_2^2 &= N_0^2 BT(2RSB + 1) \end{aligned} \quad (2.3)$$

avec RSB le rapport signal à bruit défini par :

$$RSB \triangleq \frac{E_x}{N_0 B} \quad (2.4)$$

avec E_x la puissance du signal émis $x(t)$, sur la durée T et N_0 la densité spectrale de puissance mono-latérale du bruit blanc gaussien. Les probabilités de détections P_d et de

fausse alarme P_{fa} deviennent :

$$P_{fa} = Q \left\{ \frac{\xi - \mu_1}{\sigma_1} \right\} \quad (2.5)$$

et

$$P_d = Q \left\{ \frac{\xi - \mu_2}{\sigma_2} \right\} \quad (2.6)$$

avec

$$Q(u) \triangleq \frac{1}{\sqrt{2\pi}} \int_u^\infty e^{-v^2/2} dv = \frac{1}{2} \operatorname{erfc}(u/\sqrt{2}) \quad (2.7)$$

Et donc pour une probabilité de fausse alarme désirée $P_{fa,des}$, on fixe le seuil de détection ξ_0 adéquat de la manière suivante :

$$\xi_0 = \mu_1 + \sigma_1 Q^{-1}(P_{fa,des}) = GN_0 \quad (2.8)$$

avec

$$G = [BT + \sqrt{BT} Q^{-1}(P_{fa,des})] \quad (2.9)$$

2.2.1.1 Performance du radiomètre

On note $P_{d,des}$ la probabilité de détection désirée, et $P_{fa,des}$ la probabilité de fausse alarme désirée. Soit $u = Q^{-1}(P_{d,des})$ et $v = Q^{-1}(P_{fa,des})$. On montre dans [111] que pour un large produit BT et si N_0 est connue avec précision, le rapport signal à bruit minimal, RSB_m garantissant $P_{d,des}$ et $P_{fa,des}$ et donné par :

$$RSB_m = \frac{v}{\sqrt{BT}} + \frac{u}{BT} \left[u - \sqrt{u^2 + BT + 2v\sqrt{BT}} \right] \quad (2.10)$$

l'évolution du RSB_m en fonction du produit BT est donnée sur la figure 2.2 pour plusieurs valeurs de $P_{fa,des}$ et de probabilités de non-détection $P_{m,des} = 1 - P_{d,des}$. On remarque que le RSB_m requis pour une détection désirée diminue avec l'augmentation du produit BT , qui est directement proportionnelle au nombre d'observations quand le signal reçu est échantillonné.

2.2.1.2 Limite de la détection d'énergie

Les performances du radiomètre vues dans la section 2.2.1.1 sont exactes à condition que la densité spectrale du bruit N_0 soit connue avec grande précision. Dans une communication classique entre émetteur-récepteur un échange préliminaire de données est établi dont le contenu est connu par le récepteur (porteuse pilote...). Ce dernier peut donc estimer avec précision la valeur de N_0 . Cet aspect collaboratif entre émetteur-récepteur n'existe malheureusement pas normalement dans le *spectrum sensing* car aucune communication n'existe entre les terminaux de la radio opportuniste au moment de la détection. Par la suite, l'estimation du niveau de bruit N_0 , n'est pas exempte d'erreur surtout quand la bande testée est occupée. Comme le seuil de détection du radiomètre est proportionnel à N_0 (cf. équation (2.8)), il ne peut donc être déterminé avec exactitude, ce qui dégrade sérieusement les performances du radiomètre [111].




FIGURE 2.2 – La variation du rapport signal à bruit minimal RSB_m en fonction du produit BT , lorsque le niveau de bruit N_0 est parfaitement connu. On note que RSB_m diminue linéairement avec l’augmentation du produit BT .

Soit \hat{N}_0 la valeur estimée de N_0 et $\hat{\xi}_0$ le seuil correspondant. Dans le cas d’une sous-estimation de N_0 , *i.e.*, $\hat{N}_0 < N_0$, figure 2.3 montre qu’une mauvaise décision est faite quand la statistique \mathcal{T}_{DE} du signal reçu est dans l’intervalle $[\hat{\xi}_0, \xi_0]$. Dans le contexte du *spectrum sensing*, cette mauvaise décision cause la déclaration que la bande est occupée alors qu’elle est libre, augmentant ainsi la probabilité de fausse alarme.

Dans le cas contraire d’une sur-estimation de N_0 , *i.e.*, $\hat{N}_0 > N_0$, figure 2.4 montre qu’une mauvaise décision est faite quand la statistique \mathcal{T}_{DE} du signal reçu est dans l’intervalle $[\xi_0, \hat{\xi}_0]$. Dans le contexte du *spectrum sensing*, cette mauvaise décision cause la déclaration que la bande est libre alors qu’elle est occupée, diminuant ainsi la probabilité de détection.

On conclue donc que l’incertitude sur le niveau du bruit conduit, selon le cas, soit à une sous-exploitation des bandes libres par les utilisateurs secondaires soit à une génération d’interférence sur les utilisateurs primaires.

Afin de tenir compte de l’incertitude sur l’estimation du niveau du bruit N_0 , Les auteurs du papier [111] proposent l’analyse de l’impact d’une information incertaine relative au niveau du bruit sur les performances du détecteur d’énergie. Ils supposent que le niveau du bruit est borné avec l’inégalité suivante :

$$(1 - \epsilon_1)N_0 \leq \hat{N}_0 \leq (1 + \epsilon_2)N_0 \quad (2.11)$$

avec $0 \leq \epsilon_1 < 1$ et $\epsilon_2 \geq 0$ déterminent l’intervalle d’incertitude sur l’estimation de N_0 . A partir de (2.5),(2.9) ou de la figure 2.3, il est clair qu’une sous-estimation du vrais

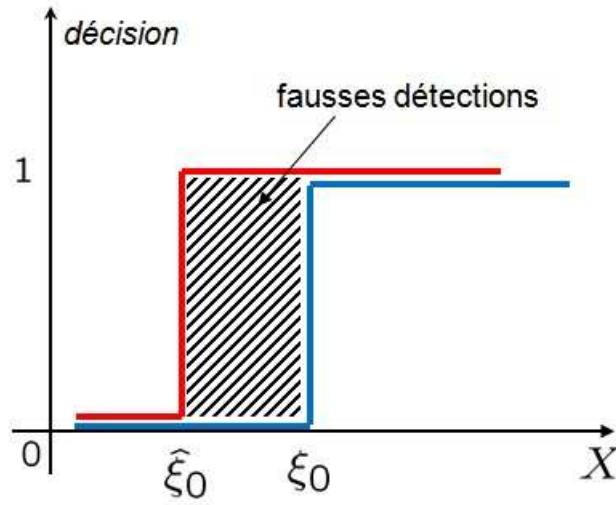


FIGURE 2.3 – Erreur de décision dans le cas d’une sous-estimation du niveau du bruit N_0 . Dans ce cas il en résulte la déclaration d’une bande occupée alors qu’elle est libre, provoquant une augmentation de la probabilité de fausse alarme.

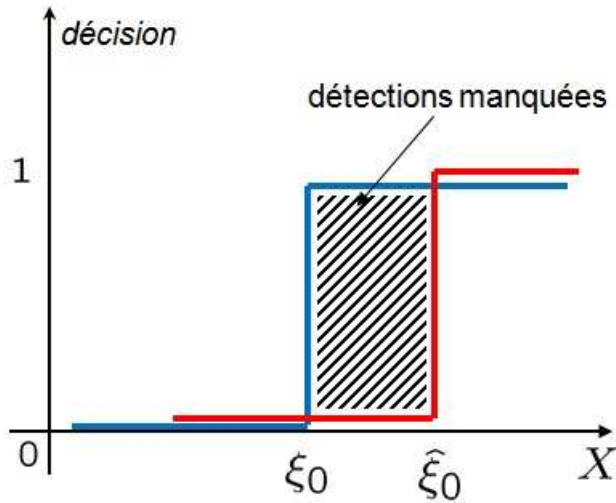


FIGURE 2.4 – Erreur de décision dans le cas d’une surestimation du niveau du bruit N_0 . Dans ce cas la bande testée est déclarée libre, alors qu’elle est occupée, provoquant ainsi des interférences sur les UP.

niveau de bruit N_0 cause $P_{fa} > P_{fa,des}$. Par conséquent, pour garantir $P_{fa} \leq P_{fa,des}$ sur l’ensemble des valeurs de l’estimateur donné par (2.11), l’estimateur biaisée du seuil :

$$\hat{\xi}_0 = \frac{\hat{N}_0}{(1 - \epsilon_1)} G \quad (2.12)$$

doit être utilisé dans (2.5).

Pour examiner maintenant l'effet de l'utilisation de l'estimation du seuil (2.12) sur la probabilité de détection du signal, en remplaçant $\hat{\xi}_0$ dans (2.6) et en utilisant (2.3), on obtient :

$$P_d = Q \left(\frac{\hat{\xi}_0 - N_0TB(RSB + 1)}{N_0\sqrt{TB(2RSB + 1)}} \right) \quad (2.13)$$

Comme $Q(\cdot)$ est une fonction monotone décroissante, P_d est minimal (c.-à-d. pire cas de P_d) lorsque $\hat{\xi}_0$ prend sa valeur maximale. Cela se produit lorsque :

$$\hat{N}_0 = (1 + \epsilon_2)N_0 \quad (2.14)$$

dans ce cas,

$$\hat{\xi}_0 = G \left(\frac{\hat{N}_0}{1 - \epsilon_1} \right) = G \left(\frac{1 + \epsilon_2}{1 - \epsilon_1} \right) N_0 = U\xi_0 \quad (2.15)$$

avec U l'incertitude pic-à-pic sur l'estimation de N_0 donnée par :

$$U \triangleq \frac{1 + \epsilon_2}{1 - \epsilon_1} \geq 1 \quad (2.16)$$

Ainsi,

$$P_{d,pire-cas} = Q \left(\frac{U\xi_0 - N_0TB(RSB + 1)}{N_0\sqrt{TB(2RSB + 1)}} \right) \quad (2.17)$$

Nous pouvons garantir que $P_d > P_{d,des}$, sur la totalité de l'intervalle d'incertitude sur le bruit en exigeant que $P_{d,des} = P_{d,pire-cas}$. En utilisant cette substitution, et en utilisant (2.3) et (2.8) dans l'expression précédente on obtient :

$$P_{d,des} = Q \left(\frac{(U - 1)\sqrt{TB} + UQ^{-1}(P_{fa,des}) - RSB\sqrt{TB}}{\sqrt{1 + 2RSB}} \right) \quad (2.18)$$

Le RSB, nécessaire pour atteindre $P_d > P_{d,des}$ et $P_{fa} < P_{fa,des}$ sur toute la plage de l'incertitude sur le bruit (2.11) est obtenue en résolvant l'équation (2.18) en RSB, ainsi l'expression du RSB_m (RSB minimal) [111] devient :

$$RSB_m \approx (U - 1) + O \left(\frac{1}{\sqrt{BT}} \right) \quad (2.19)$$

Le terme $(U - 1)$ détermine le « SNR_{wall} », RSB en dessous duquel la détection n'est plus possible indépendamment des paramètres $P_{fa,des}$, B et T du détecteur. Dans le cas où $P_{fa,des} = 1 - P_{d,des} = 0,01$ et U variable, la figure 2.5 montre la variation du RSB_m en fonction du produit BT pour différentes valeurs de U .

On constate que pour U nul ou non, le rapport RSB_m est décroissant à mesure que le produit BT augmente. En revanche, lorsque $U \neq 0$ (présence d'incertitude), cette décroissance tend asymptotiquement vers sa valeur limite (en anglais *snr wall*) égale à $U - 1$. Par exemple, pour $U = 3$ dB (2 en linéaire), cette valeur limite du RSB_m est 0 dB.




FIGURE 2.5 – Lorsque la valeur de U est différente de zéro (la présence d'incertitude), la valeur de RSB_m diminue avec l'augmentation du produit BT , et tend asymptotiquement vers sa limite $U - 1$.

La difficulté en pratique d'aboutir à un intervalle (l'intervalle donné par (2.11)) certain (avec probabilité 1) a mené les auteurs de [111] à considérer un modèle plus réaliste mais plus complexe à résoudre. Il repose sur des mesures empiriques. Ces dernières montrent que dans de nombreux scénarios, l'estimation de la puissance du bruit semble suivre une loi log-normale. Cela ramène l'étude de leur détecteur à un ratio entre une variable de loi χ^2 et une variable de loi log-normale. Un tel ratio n'a malheureusement pas de forme explicite simple [112]. Ils ramenèrent donc le second problème au premier modèle à travers un intervalle de confiance. Afin de répondre au second modèle, Wassim Jouini propose dans sa thèse [112] une approximation de la loi χ^2 par une loi log-normale, de plus il montre qu'une loi χ^2 est mieux approximée par une loi log-normale que par une loi normale. Cette approximation est évaluée puis exploitée afin de résoudre le problème resté non-résolu dans le papier [111]. Ainsi, le nouveau modèle considéré, ainsi que l'approximation mathématique, ont permis de concevoir un détecteur d'énergie avec un taux de fausse alarme fixe malgré l'incertitude. En outre en s'appuyant sur ces résultats, il a présenté une nouvelle expression du *snr wall*, différente de l'expression donnée dans [113]. Cette nouvelle expression dépend des performances souhaitées du détecteur ($P_{fa,des}$ et $P_{d,des}$), l'incertitude du bruit et le nombre d'échantillons. Pour plus de détails, les lecteurs peuvent se référer aux articles [114, 115].

Enfin, malgré sa faible complexité et sa facilité d'implémentation, le radiomètre ne permet pas une détection fiable des bandes libres surtout si l'incertitude sur le niveau du bruit est importante ou que le RSB est faible.

2.2.2 Détection Cyclostationnaire

Après l'introduction des notions liés à la cyclostationarité dans la section 1.4.1.1.C du chapitre 1, on présente maintenant un « *review* » des techniques de détection cyclostationnaire les plus connues.

Les travaux de Gardner [116] en particulier étudient la cyclostationnarité des signaux, provenant de la redondance en fréquence des signaux transmis. Cette cyclostationnarité est pleinement caractérisée par la norme de la fonction de cohérence spectrale $\rho_x^\alpha(f)$. La fonction de cohérence spectrale définie pour un processus $x(t)$ pris à la fréquence f pour une cyclicité α , est donnée par l'équation (2.20) [116] :

$$\rho_x^\alpha(f) = \frac{\tilde{S}_{xx}(\alpha, f)}{[\tilde{S}_{xx}(f + \frac{\alpha}{2}) \cdot \tilde{S}_{xx}(f - \frac{\alpha}{2})]^{1/2}} \quad (2.20)$$

avec $\tilde{S}_{xx}(f)$ la densité spectrale classique. Différents critères de cohérence spectrale peuvent être envisagés [6], voir [116] et [117] pour plus de détails.

Lorsqu'il apparait que des signaux détectés à une fréquence f exhibent un caractère cyclostationnaire de fréquence α , H_1 doit être décidé, tandis que si aucune corrélation particulière du signal à toute fréquence cyclique α n'est détectée, H_0 doit être décidé. Concrètement, un seuil de détection ξ_{cyc} doit être décidé tel que, en dénotant C_{cyc} le test :

$$C_{cyc} = \sup_{\alpha} |\rho_x^\alpha(f)| \quad \text{avec } \alpha \neq 0 \quad (2.21)$$

nous effectuons la décision :

$$\begin{aligned} H_0 & : C_{cyc} < \xi_{cyc} \\ H_1 & : C_{cyc} > \xi_{cyc} \end{aligned} \quad (2.22)$$

Ce seuil de décision est fonction de la variance σ^2 du bruit additif.

À nouveau, il n'est cependant pas trivial que le caractère de cyclostationnarité soit simple à mettre en évidence dans le signal à détecter. Dans le contexte de transmissions à minimum de redondance, il peut apparaître que la cohérence spectrale du signal reçu soit très faible [6].

2.2.2.1 Tests de présence de la cyclostationnarité sur une fréquence

Le premier *test statistique* de présence de cyclostationnarité sur une fréquence cyclique donnée, a été développé par Dandawaté et Giannakis dans [2]. C'est un test statistique dont la règle de décision est :

$$\mathcal{Z}_G \propto \hat{\mathbf{C}}_{kx} \boldsymbol{\Sigma}_{kx}^{-1} \hat{\mathbf{C}}_{kx}^T \underset{H_1}{\overset{H_0}{\lesseqgtr}} \xi_G \quad (2.23)$$

avec $\hat{\mathbf{C}}_{kx}$, un vecteur d'estimations des cumulants d'ordre k du processus $x(t)$, $\hat{\mathbf{C}}_{kx}^T$ le vecteur transposé de $\hat{\mathbf{C}}_{kx}$ et $\boldsymbol{\Sigma}_{kx}$ la matrice de covariance de $\hat{\mathbf{C}}_{kx}$. Les auteurs déterminent

les distributions de la statistique Z_G suivant les deux hypothèses H_0 et H_1 . Ce qui permet, par la suite, de déterminer pour une probabilité de fausse alarme donnée, le seuil de détection ξ_G .

Très présent dans la littérature, cet algorithme est utilisé dans la reconnaissance des standards accessibles à un terminal radio logicielle [118] ou dans la détection des canaux de fréquences libres sur la bande GSM [119]. Dans ces exemples, les systèmes à détecter sont a priori connus permettant le test de cyclostationarité sur un nombre réduit de fréquences. Ce test, le plus célèbre parmi les méthodes de cyclostationarité va être utilisé dans nos nouveaux algorithmes de détection proposés dans ce chapitre. Pour une description complète du test de Dandawaté et Giannakis cf. annexe B.

Les travaux de Marchand [120] reprennent les tests proposés par Dandawaté et Giannakis [2] dans le cas de la détection et de la reconnaissance en aveugle des modulations numériques linéaires à l'aide des statistiques d'ordres supérieurs [32]. Afin de réduire la complexité de calcul, Marchand introduit une simplification dans l'algorithme de test de Dandawaté sans dégradation des performances. Cette simplification consiste en effet à considérer dans le calcul de la statistique (2.23) que Σ_{kx} est diagonale. Marchand montre que la détection à l'ordre 4 surpasse l'ordre 2 pour des signaux qui sont mis en forme par un filtre d'excès de bande faible exigeant toutefois une complexité de calcul trop importante. De plus, afin de remédier l'indétermination *a priori* de la fréquence cyclique, Marchand propose de rechercher la cyclostationarité sur un large intervalle de fréquences en répétant plusieurs fois le test de Dandawaté, aboutissant également à une complexité et un temps de calculs importants.

Une nouvelle méthode de détection cyclostationnaire sur une fréquence cyclique a été proposée dans les travaux de thèse de M. Ghozzi [30]. Ce test s'applique lorsque les systèmes primaires sont connus du terminal radio opportuniste et que les harmoniques de leurs fréquences cycliques fondamentales sont présentes. D'une manière générale, on peut mettre la fonction d'autocorrélation d'un processus aléatoire sous la forme suivante :

$$r_{xx}(t, \tau) = \underbrace{r_{xx}(\tau)}_{\text{CC}} + \underbrace{\sum_{\alpha \in \mathcal{A}_\alpha} r_{xx}(\alpha, \tau) e^{i2\pi\alpha t}}_{\text{CP}} \quad (2.24)$$

Le terme de droite est formé de deux composantes (CC et CP) respectivement continues et périodiques en fonction du temps. La composante CP est non nulle si et seulement si le processus $x(t)$ est cyclostationnaire. Par contre, la composante CC est non nulle quel que soit $x(t)$ cyclostationnaire ou non. Ainsi, en posant $\tilde{r}_{xx}(t, \tau) = r_{xx}(t, \tau) - r_{xx}(\tau)$, le test de présence de la cyclostationarité devient équivalent au test d'hypothèses suivant :

$$\begin{aligned} H_0 & \tilde{r}_{xx}(t, \tau) = 0 \quad \forall t \\ H_1 & \tilde{r}_{xx}(t, \tau) \neq 0 \quad \text{pour quelques valeurs de } t \end{aligned} \quad (2.25)$$

où l'hypothèse H_0 correspond au cas d'un processus $x(t)$ stationnaire et l'hypothèse H_1 correspond au cas d'un processus $x(t)$ cyclostationnaire.

Pour estimer la fonction d'autocorrélation Ghozzi, utilise l'estimateur proposé dans [29]. Soit T_e la période d'échantillonnage et P_0 un nombre entier supérieur à 2, cet estimateur présente la particularité d'avoir des valeurs non nulles si et seulement si $x(t)$ est

cyclostationnaire de fréquence cyclique multiple entier de $\frac{T_e}{P_0}$. Par conséquent, le test de cyclostationnarité proposé est effectué, sur un ensemble discret de fréquences données par $\{\frac{kT_e}{P_0}, k \in \mathbb{N}^*\}$. dans le cas d'un processus à temps discret $x(n) = x(nT_e)$, l'estimateur de l'autocorrélation du processus est donné par :

$$\hat{r}_{xx}^{(N)}(n, \tau) = \frac{1}{N} \sum_{k=0}^{N-1} x(n + kP_0)x^*(n + kP_0 - \tau) \quad (2.26)$$

On démontre dans [30] que :

$$\lim_{N \rightarrow \infty} \hat{r}_{xx}^{(N)}(n, \tau) \stackrel{m.q.}{=} r_{xx}(n, \tau) \quad (2.27)$$

avec ($\stackrel{m.q.}{=}$) désignant la convergence en moyenne quadratique, donc l'estimateur de $\hat{r}_{xx}^{(N)}(n, \tau)$ est convergent.

En pratique une erreur d'estimation existe toujours à cause du nombre d'échantillons N qui est limité, et donc $r_{xx}^{(N)}(n, \tau)$ ne peut être jamais identiquement nulle même si $x(n)$ n'est pas un signal cyclostationnaire. Il est donc plus convenable d'écrire le test d'hypothèse sous la forme :

$$\begin{aligned} H_0 \quad & \hat{r}_{xx}^{(N)}(n, \tau) = \varepsilon^{(N)}(n, \tau) \\ H_1 \quad & \hat{r}_{xx}^{(N)}(n, \tau) = r_{xx}(n, \tau) + \varepsilon^{(N)}(n, \tau) \end{aligned} \quad (2.28)$$

où $\varepsilon^{(N)}(n, \tau)$ est l'erreur d'estimation tel que :

$$\lim_{N \rightarrow \infty} \varepsilon^{(N)}(n, \tau) = 0$$

A. Distributions des parties réelles et imaginaires de l'estimateur

Soient $\hat{a}_{xx}^{(N)}(n, \tau)$ et $\hat{b}_{xx}^{(N)}(n, \tau)$ respectivement les parties réelles et imaginaires de $\hat{r}_{xx}^{(N)}(n, \tau)$ on a donc :

$$\hat{a}_{xx}^{(N)}(n, \tau) = \frac{1}{2} \left(\hat{r}_{xx}^{(N)}(n, \tau) + \hat{r}_{xx}^{*(N)}(n, \tau) \right) \quad (2.29)$$

et

$$\hat{b}_{xx}^{(N)}(n, \tau) = -i \frac{1}{2} \left(\hat{r}_{xx}^{(N)}(n, \tau) - \hat{r}_{xx}^{*(N)}(n, \tau) \right) \quad (2.30)$$

Si on suppose que $\hat{a}_{xx}^{(N)}(n, \tau)$ et $\hat{b}_{xx}^{(N)}(n, \tau)$ sont statistiquement indépendants alors on montre dans [30] que :

$$\hat{a}_{xx}^{(N)}(n, \tau) \sim \mathcal{N} \left(a_{xx}(n, \tau), \frac{\sigma^{(N)2}(n, \tau)}{2} \right) \quad (2.31)$$

$$\hat{b}_{xx}^{(N)}(n, \tau) \sim \mathcal{N} \left(b_{xx}(n, \tau), \frac{\sigma^{(N)2}(n, \tau)}{2} \right) \quad (2.32)$$

avec $a_{xx}(n, \tau)$ et $b_{xx}(n, \tau)$ les valeurs asymptotiques de $\hat{a}_{xx}^{(N)}(n, \tau)$ et $\hat{b}_{xx}^{(N)}(n, \tau)$, i.e. :

$$\begin{aligned} a_{xx}(n, \tau) &= \lim_{N \rightarrow \infty} \hat{a}_{xx}^{(N)}(n, \tau) \\ b_{xx}(n, \tau) &= \lim_{N \rightarrow \infty} \hat{b}_{xx}^{(N)}(n, \tau) \end{aligned} \quad (2.33)$$

Comme $r_{xx}(n, \tau)$ est une quantité déterministe alors $\varepsilon^{(N)}(n, \tau)$ est une variable aléatoire à valeurs complexes, de moyenne nulle et de même variance que $\hat{r}_{xx}^{(N)}(n, \tau)$, soit :

$$\Re\{\hat{\varepsilon}_{xx}^{(N)}(n, \tau)\} \sim \mathcal{N}\left(0, \frac{\sigma^{(N)2}(n, \tau)}{2}\right) \quad (2.34)$$

$$\Im\{\hat{\varepsilon}_{xx}^{(N)}(n, \tau)\} \sim \mathcal{N}\left(0, \frac{\sigma^{(N)2}(n, \tau)}{2}\right) \quad (2.35)$$

Ainsi on montre que pour une valeur de τ donnée non nulle, la résolution du test d'hypothèse (2.28) au sens du maximum de vraisemblance aboutit à l'utilisation de la statistique de test suivante :

$$\tilde{\mathcal{Z}}_{gh}(\tau) = 2L \sum_{l=0}^{L-1} \frac{|\hat{r}_{xx}^{(N)}(l, \tau)|^2}{\sigma^{(N)2}(l, \tau)} = L \sum_{l=0}^{L-1} \frac{(\hat{a}_{xx}^{(N)}(l, \tau))^2}{\sigma^{(N)2}(l, \tau)/2} + L \sum_{l=0}^{L-1} \frac{(\hat{b}_{xx}^{(N)}(l, \tau))^2}{\sigma^{(N)2}(l, \tau)/2} \quad (2.36)$$

La comparaison de cette statistique à un seuil permet donc de déterminer l'hypothèse la plus vraisemblable :

$$\tilde{\mathcal{Z}}_{gh}(\tau) \underset{H_1}{\overset{H_0}{\leq}} \xi_{gh} \quad (2.37)$$

$\tilde{\mathcal{Z}}_{gh}(\tau)$ est la somme de $2L$ v.a. gaussiennes de variances unités, indépendantes entre elles et élevées au carré. Suivant H_0 , ces v.a. sont centrées, par conséquent $\tilde{\mathcal{Z}}_{gh}(\tau)$ suit une loi de chi-deux à $2L$ degrés de liberté :

$$\tilde{\mathcal{Z}}_{gh}(\tau)|H_0 \sim \chi_{2L}^2 \quad (2.38)$$

Lorsque $2L$ est suffisamment grand, la loi de distribution de $\tilde{\mathcal{Z}}_{gh}(\tau)$ peut être approchée [121] suivant H_0 par une loi normale de paramètres :

$$\mu' = 2L, \quad \sigma' = 4L \quad (2.39)$$

ainsi la probabilité de fausse alarme qui est la probabilité de décider qu'un signal cyclostationnaire de fréquence cyclique fondamentale multiple entier de $\frac{1}{P_0 T_e}$ est présent alors que ce n'est pas le cas :

$$P_{fa} = P(\tilde{\mathcal{Z}}_{gh}(\tau) > \xi_{gh} | H_0) \quad (2.40)$$

Lorsque L est grand (≥ 10), cette probabilité peut être approximée par :

$$P_{fa} = Q\left(\frac{\xi_{gh} - \mu'}{\sigma'}\right) \quad (2.41)$$

avec

$$Q(a) = \frac{1}{\sqrt{2\pi}} \int_a^{\infty} e^{-\frac{y^2}{2}} dy \quad (2.42)$$

et donc pour une P_{fa} désirée on peut fixer le seuil ξ_{gh} .

B. Résultats de simulations

Quelques résultats de simulations du test de présence de cyclostationnarité (TPC) proposé dans [30] sont fournis sous forme de courbes ROC ($P_d = f(P_{fa})$). Les résultats sont donnés pour un signal d'intérêt du type MDP4 avec une forme d'onde rectangulaire des symboles de données et échantillonnés à la période T_e . Ce signal, de période symbole $T_s = 20 \cdot T_e$, est immergé dans un bruit blanc gaussien. L'autocorrélation est estimée pour $P_0 = \frac{T_s}{T_e} = 20$, $\tau = 10$ et N variable. Dans les mêmes conditions de RSB et de nombres de symboles N_{symb} (donc du nombre d'échantillons N), les figures 2.6 et 2.7 comparent les performances de détection de l'algorithme proposé (TPC) aux performances de détection de l'algorithme de test de cyclostationnarité de Dandawaté et Giannakis [2]. Cette comparaison est faite dans le cas d'une forme d'onde rectangulaire et dans le cas d'un filtre d'émission du type cosinus surélevé de facteur de retombée $\beta = 0,3$. Ces figures montrent qu'une différence de performances existe entre les deux tests. Dans le cas d'une mise en forme rectangulaire, cette différence est en faveur du test TPC qui détecte la cyclostationnarité, non seulement sur la fréquence cyclique fondamentale, mais aussi sur ses harmoniques. Ceci peut être avantageux dans la détection de certains signaux comme l'OFDM et le DS-CDMA dont l'ensemble des fréquences cycliques est constitué d'harmoniques d'une fréquence cyclique fondamentale.

Cependant, lorsqu'un filtre d'émission est employé, la figure 2.7 montre que le signal n'est détecté qu'à un RSB plus élevé (RSB = 5 dB) et un nombre de symboles plus importants ($N_{symb} = 500$). Ceci est bien le cas des deux tests (le TPC de Dandawaté et Giannakis) avec un avantage pour le test de Dandawaté et Giannakis.

Cette particularité du test proposé permet, comme il est montré dans les simulations, d'améliorer la détection en cas de présence d'harmoniques de la fréquence cyclique fondamentale. Cependant, lorsque ces harmoniques sont absentes, parce qu'un filtre d'émission est appliqué, le test proposé ne fait pas mieux que les tests de cyclostationnarité de Dandawaté et Giannakis qui devient plus avantageux. Dans le chapitre 3 on proposera un nouvel estimateur de la FAC qui se base sur le *compressed sensing*. On utilisera par la suite dans le chapitre 4 ce nouvel estimateur pour proposer de nouveaux tests aveugles de présence de cyclostationnarité utilisant un faible nombre d'échantillons, dont les performances s'améliorent avec l'utilisation d'un filtrage à l'émission contrairement au TPC.

2.2.2.2 Autres tests de cyclostationnarité

Dans la littérature, d'autres méthodes de détection/estimation cyclique existent. Par exemple, Zivanovic et Gardner [122] définissent le degré de cyclostationnarité d'un processus aléatoire par :

$$DCS = \frac{\sum_{\alpha \neq 0} \int_{-\infty}^{\infty} |R_{xx}(\alpha, \tau)|^2 d\tau}{\int_{-\infty}^{\infty} |R_{xx}(0, \tau)|^2 d\tau} \quad (2.43)$$

Il s'agit de mesurer la distance entre la corrélation du processus d'intérêt et la corrélation du processus stationnaire le plus proche. On peut aussi définir le degré de cyclostationnarité




FIGURE 2.6 – Comparaison des performances du test proposé (TPC) et d'un deuxième test donné dans [2]. Le signal détecté utilise une forme d'onde rectangulaire des symboles de données. Figure extraite de [30] avec l'accord de l'auteur.

d'un processus sur une fréquence α par :

$$DCS^\alpha = \frac{\int_{-\infty}^{\infty} |R_{xx}(\alpha, \tau)|^2 d\tau}{\int_{-\infty}^{\infty} |R_{xx}(0, \tau)|^2 d\tau} \quad (2.44)$$

Même si les auteurs de cet article n'abordent pas le problème de détection, cette notion de degré de cyclostationarité peut être utile à la détection. Il suffit alors de comparer la mesure DCS (ou DCS^α) à un seuil dont la valeur est fixée par un critère tel que P_{fa} constante.

Hurd et Gerr [123] proposent un test de présence de la cyclostationarité basé sur le calcul de la corrélation spectrale normalisée :

$$\mathcal{V}(\alpha_p, \alpha_q, M) = \frac{|\sum_{m=0}^{M-1} I_N(\alpha_{p+m}) I_N^*(\alpha_{q+m})|^2}{\sum_{m=0}^{M-1} |I_N(\alpha_{p+m})|^2 \sum_{m=0}^{M-1} |I_N(\alpha_{q+m})|^2} \quad (2.45)$$

avec $I_N(\alpha_k) = \sum_{n=0}^{N-1} x(n) e^{-j\pi\alpha_k n}$, $\alpha_k = 2\pi k/N$ et M un paramètre de lissage. La présence, sur le tracé de $\mathcal{V}(\alpha_p, \alpha_q, M)$ en fonction de α_p , de lignes sombres parallèles à la diagonale indiquent la cyclostationarité du signal $x(t)$. La détection est donc effectuée d'une manière visuelle.

Dans un environnement bruité de densité spectrale N_0 connue, Gardner [124] et Izzo [125] montrent que le *détecteur d'énergie optimale* (supposé aussi connaître la DSP du




FIGURE 2.7 – Comparaison des performances du test proposé (TPC) et d'un deuxième test donné dans [2]. Le signal détecté utilise une forme d'onde du type cosinus-surélevé. Figure extraite de [30] avec l'accord de l'auteur.

signal émis) est meilleur que le détecteur monocycle cohérent (cf. [30]). Dans ces travaux de thèse, Rostaing [126] reprend cette étude en considérant différents modèles de bruit : gaussien et non-gaussien, blanc et non-blanc. Il conclut que, dans une situation réaliste caractérisée par un niveau spectral N_0 variable, les performances du détecteur d'énergie optimale se dégradent considérablement devenant nettement inférieures à celles du détecteur monocycle cohérent. Par ailleurs, Rostaing montre aussi la supériorité du détecteur monocycle dans un environnement bruité caractérisé par des interférences additives.

Dans [127] les auteurs proposent un test de présence de cyclostationarité utilisant les statistiques d'ordres supérieurs (supérieurs à 2). Ils proposent un test à l'ordre 4 pour la détection des modulations linéaires. Ce test donne des performances similaires au test à l'ordre 2 pour un RSB proche de 0 dB avec une complexité similaire. Ce test peut donc remplacer le test à l'ordre 2 dans le cas d'un signal qui ne présente pas une cyclostationarité à l'ordre 2. Aussi les auteurs montrent que les performances du détecteur d'ordre 4 peuvent dépasser les performances du détecteur d'ordre 2 mais en augmentant le temps d'observation, donc la complexité. De plus, une comparaison faite avec le radiomètre pour une valeur connue de N_0 montre que les performances de ce dernier dépassent les détecteurs cyclostationnaires à l'ordre 2 et 4 (utilisant la fréquence cyclique symbole) dans les mêmes conditions de simulations. Finalement ils montrent la forte dégradation des performances du radiomètre en ajoutant une incertitude sur le niveau de bruit N_0 tandis que les performances des détecteurs aux ordres 2 et 4 sont légèrement dégradées,

rendant les tests de cyclostationarité plus robustes dans le cas d'une incertitude sur le niveau du bruit ou un faible RSB .

2.3 Détecteur Hybride

2.3.1 Généralités

Comme on a vu dans le chapitre 1, les utilisateurs secondaires (US) s'engagent à ne pas créer d'interférence sur les bandes des utilisateurs primaires (UP) quand elles sont utilisées/réutilisées par les UP. Afin de tenir cet engagement, les US doivent effectuer des vérifications périodiques de ces bandes. Plus ces vérifications sont fréquentes, plus le risque d'interférence diminue. Par la suite, l'analyse périodique du contenu des bandes est soumise à des contraintes de temps surtout que le nombre de bandes partagées avec l'utilisateur primaire peut être important, d'où la nécessité de proposer un détecteur robuste avec une faible complexité. C'est pour cela que nous proposons dans ce qui suit une architecture qui présente une faible complexité et une détection robuste à la fois, en combinant la détection cyclostationnaire et le radiomètre.

2.3.2 Architecture du détecteur

La table 2.1 montre une comparaison entre les caractéristiques des détecteurs d'énergie et de cyclostationnarité. Hormis sa sensibilité au bruit, qui dégrade sa détection à faible RSB , le détecteur d'énergie est la solution la plus simple pour détecter les bandes libres [127] car aucune information *a priori* sur le signal n'est nécessaire. De plus, c'est une méthode très simple à mettre en œuvre.

	Complexité de calcul	insensibilité aux variations du niveau de bruit	connaissances a priori	détection à faible rsb
radiomètre	+	-	niveau du bruit N_0	-
Détecteur cyclostationnaire.	-	+	fréquences cycliques	+

TABLE 2.1 – Comparaison des principales propriétés des détecteurs d'énergie (radiomètre) et cyclostationnaire. Le (+) signifie un avantage et le (-) signifie un inconvénient

Au contraire, la détection cyclostationnaire est plus robuste face à l'incertitude sur le niveau du bruit [111, 23, 127] mais beaucoup plus complexe et nécessite la connaissance préalable des fréquences cycliques afin de prendre une décision relativement rapide. Si cette information est inconnue, le processus devient trop compliqué et il ne sera pas possible de l'implémenter (aujourd'hui) en temps réel. Cependant, après une lecture attentive de la table 2.1, on remarque que ces deux méthodes sont complémentaires. C'est la raison pour laquelle on propose notre architecture hybride, qui permet de détecter rapidement avec un minimum d'information les bandes libres, en prenant avantage des deux méthodes. Cette architecture hybride, qui est présentée dans la figure 2.8 est une architecture adaptative, elle présente deux étages de détection, un étage de détection d'énergie avec un

double seuil ξ_1 et ξ_2 , un étage de détection cyclostationnaire, et un étage d'adaptation. Dans notre nouvelle architecture, on utilise dans le bloc cyclostationnaire, l'algorithme




FIGURE 2.8 – Architecture de détection hybride des bandes libres

temporel de second ordre, proposé par Dandawaté et Gianakis [2]. On note que n'importe quel autre test de cyclostationarité peut aussi être utilisé. On propose deux algorithmes qui utilisent cette architecture. Le premier algorithme, le *hybrid spectrum detector* HSD corrige itérativement les seuils ξ_1 et ξ_2 du radiomètre à double seuils, l'HSD finalement converge vers les performances du détecteur cyclostationnaire avec une complexité globale inférieure. Le second algorithme, le *enhanced hybrid spectrum detector* EHSD utilise le détecteur de cyclostationarité afin d'estimer directement le niveau du bruit N_0 , qui est ensuite utilisé pour fixer le seuil du radiomètre. Les détails du fonctionnement de ces algorithmes ainsi que le fonctionnement de cette architecture correspondant à chacun de ces deux algorithmes (fonctionnement des différents étages ou blocs) vont être décrits dans les prochaines sections.

2.4 Règle de décision de l'algorithme HSD

On suppose d'abord que N_0 est constant par rapport au temps. Soit $\mathcal{T}_{DE,i}$ la statistique du signal reçu $x(t)$ pendant le temps d'observation T , après l'itération i , B la bande passante de la bande testée, ξ_1 et ξ_2 deux seuils sont d'abord initialisés à 0 et $+\infty$ respectivement. ξ_G , qui est le seuil du bloc cyclostationnaire est défini dans le but de respecter la $P_{fa,des}$ souhaitée, est fixé à l'aide de la table χ^2 centrale comme décrit dans [2] ou dans l'annexe B.

Nous utilisons une règle de décision comme le montre la figure 2.9. Au début de la détection, le détecteur d'énergie calcule la statistique \mathcal{T}_{DE} du signal reçu, après un temps d'observation T . Ensuite, si \mathcal{T}_{DE} tombe à l'intérieur de l'intervalle $[\xi_1, \xi_2]$, le détecteur d'énergie ne peut pas prendre une décision directe du type « signal présent » ou « signal absent ». Dans ce cas, la bloc d'adaptation présenté à la figure 2.8 appellera le bloc cyclostationnaire (qui *a priori* connaît la fréquence cyclique α du signal d'intérêt) pour prendre la décision. Après que la décision du test cyclique est prise, si cette dernière est du type « signal présent » (resp. « signal absent »), la valeur \mathcal{T}_{DE} calculée est alors enregistrée dans une mémoire tampon appelée $buffer_2$ de taille N_2 , (resp. $buffer_1$ de taille N_1).

L'algorithme continue de la même manière, sauf lorsque $buffer_2$ (resp. $buffer_1$) est plein, dans ce cas, l'étage d'adaptation commence à modifier la valeur du seuil ξ_2 (resp. ξ_1) par la moyenne de $buffer_2$, (resp. $buffer_1$) et alors la valeur la plus ancienne dans la mémoire tampon ($buffer_2$, (resp. $buffer_1$)) sera remplacée par la nouvelle calculée ($\mathcal{T}_{DE,i}$ après l'itération i).

A tout moment, si la valeur de la statistique calculée \mathcal{T}_{DE} est à l'extérieur de l'intervalle $[\xi_1, \xi_2]$, l'étage d'adaptation prend une décision automatique de type de « signal absent » (resp. « signal présent ») si \mathcal{T}_{DE} est inférieur à ξ_1 (resp. supérieur à ξ_2) évitant ainsi l'utilisation du test cyclique.




FIGURE 2.9 – La règle de décision de l'architecture HSD

Le processus est répété rendant l'intervalle $[\xi_1, \xi_2]$ de plus en plus petit. Deux cas doivent être étudiés, afin d'analyser les limites de fonctionnement de l'architecture HSD, le cas d'un fort et celui d'un faible *RSB*. Ces analyses seront expliquées dans la section suivante. La figure 2.10 montre l'organigramme de l'architecture HSD.

Il convient de noter que, à faible *RSB*, le test de « Dandawaté et Giannakis » peut commettre des erreurs (fausse alarme ou non-détection), dans ce cas, les valeurs qui doivent être enregistrées dans $buffer_1$ pourraient être enregistrées dans $buffer_2$ et vice versa. Mais l'utilisation des buffers fait une *dilution* de ces erreurs introduites sur les valeurs de ξ_1 et ξ_2 , garantissant donc une évolution souple des valeurs de ξ_1 et ξ_2 . Cette évolution souple de ξ_1 et ξ_2 garantit un fonctionnement plus stable surtout pour les faible *RSB* comme il va être expliqué dans la prochaine section.




FIGURE 2.10 – Organigramme de l'architecture HSD

2.4.1 Étude analytique de l'algorithme HSD en utilisant l'outil statistique d'ordre

Dans cette section, pour des raisons de simplicité, nous supposons que la taille des $buffer_1$ et $buffer_2$ est unitaire. Afin d'étudier l'architecture HSD d'un point de vue statistique, nous allons utiliser l'outil appelé « statistiques d'ordres » (en anglais *order statistics*). Par définition la statistique d'ordre K d'un échantillon statistique (un ou plusieurs

individus d'une population statistique) notée $X_{(k)}$ est égale à sa K -e plus petite valeur.

La statistique de premier ordre (ou plus petit ordre statistique) est toujours le minimum de l'échantillon statistique défini par :

$$X_{(1)} = \min\{X_1, X_2, \dots, X_n\} \quad (2.46)$$

De même, pour un échantillon de taille n , la statistique d'ordre n (autrement dit, le maximum) est défini par :

$$X_{(n)} = \max\{X_1, X_2, \dots, X_n\} \quad (2.47)$$

Soit $p(x)$ la densité de probabilité de la variable aléatoire X et $F(x)$ sa fonction de répartition. Il est montré dans [128] que la densité de probabilité de la statistique d'ordre K d'un échantillon de taille n est donnée par :

$$p_{X_{(k)}}(x) = \frac{n!}{(k-1)!(n-k)!} F(x)^{k-1} [1-F(x)]^{n-k} p(x) \quad (2.48)$$

pour le cas particulier $k = 1$, (2.48) devient :

$$p_{X_{(1)}}(x) = n \cdot [1-F(x)]^{n-1} p(x) \quad (2.49)$$

et pour le cas $k = n$, (2.48) devient :

$$p_{X_{(n)}}(x) = n \cdot F(x)^{n-1} p(x) \quad (2.50)$$

On considère maintenant la variable aléatoire X qui représente l'ensemble des réalisations de \mathcal{T}_{DE} sous H_0 (resp. sous H_1). La taille de l'échantillon statistique n dans (2.49) (resp. (2.50)) représente maintenant le nombre d'itérations de l'algorithme HSD sous H_0 (resp. H_1). On remplace l'expression de la distribution de X à partir de (2.3) dans (2.49) (resp. (2.50)). Ainsi on obtient l'expression de la distribution de ξ_1 sous H_0 (resp. ξ_2 sous H_1) donnée par (2.51) (resp. (2.52)) après n itérations de l'algorithme HSD :

$$p_{\xi_1(k=1)}(x) = \frac{n}{2\sigma_1\sqrt{2\pi}} \left[1 + \operatorname{erf} \left(\frac{x - \mu_1}{\sigma_1\sqrt{2}} \right) \right]^{n-1} e^{-\frac{1}{2} \left(\frac{x - \mu_1}{\sigma_1} \right)^2} \quad (2.51)$$

$$p_{\xi_2(k=n)}(x) = \frac{n}{2\sigma_2\sqrt{2\pi}} \left[1 - \operatorname{erf} \left(\frac{x - \mu_2}{\sigma_2\sqrt{2}} \right) \right]^{n-1} e^{-\frac{1}{2} \left(\frac{x - \mu_2}{\sigma_2} \right)^2} \quad (2.52)$$

2.4.2 Limites de l'algorithme HSD

- *Cas d'un fort RSB* : si le signal est reçu avec un bon RSB, les performances du test cyclique seront idéales (P_{fa_g} proche de zéro et P_{da_g} proche de un, ou P_{fa_g} et P_{da_g} sont respectivement les probabilités observées de fausse alarme et de bonne détection du bloc cyclostationnaire). Donc, les valeurs sauvegardées dans chaque buffer sont de la même population (signal dans $buffer_2$ et le bruit dans $buffer_1$). Donc les variables ξ_2 et ξ_1 ne se croiseront qu'avec une très faible probabilité et donc la valeur de ξ_1 sera toujours plus petite que celle de ξ_2 . Cela est dû au fait que le signal est bien séparé du bruit comme le montre la figure 2.11, qui représente la variation des fonctions de




FIGURE 2.11 – Les variations de la densité de probabilité de ξ_1 (resp. ξ_2) sous H_0 (resp. H_1) pour différents nombres d'itérations à $RSB = 0$ dB, tracées à l'aide de (2.51) (resp. (2.52)).




FIGURE 2.12 – L'esperance de ξ_1 (resp. ξ_2) sous H_0 (resp. H_1) en fonction du nombre d'itérations n à 0 dB, tracées à l'aide de (2.51) (resp. (2.52)).

densités de probabilités de ξ_1 et ξ_2 pour différents nombres d'itérations à $RSB = 0$ dB.

La figure 2.12 représente les moyennes des distributions de ξ_1 sous H_0 et de ξ_2 sous H_1 en fonction du nombre d'itérations (obtenues à l'aide de (2.51) et (2.52)). Il est clair que ξ_1 et ξ_2 ne vont pas se rencontrer, même après un énorme nombre d'itérations (10^9 itérations, cf. figure 2.12). Ensuite après la convergence de l'algorithme HSD, le bloc cyclique sera très rarement utilisé car il sera très rare que la statistique $\mathcal{T}_{DE,i}$ tombe entre ξ_1 et ξ_2 conduisant à la complexité du radiomètre avec des décisions parfaites.

- *Cas d'un faible RSB* : si le signal arrive avec un faible *RSB*, il est très proche du niveau du bruit, donc ξ_2 sera plus faible que ξ_1 après un certain nombre d'itérations comme nous pouvons voir dans la figure 2.13. En effet, lors d'un faible *RSB*, le

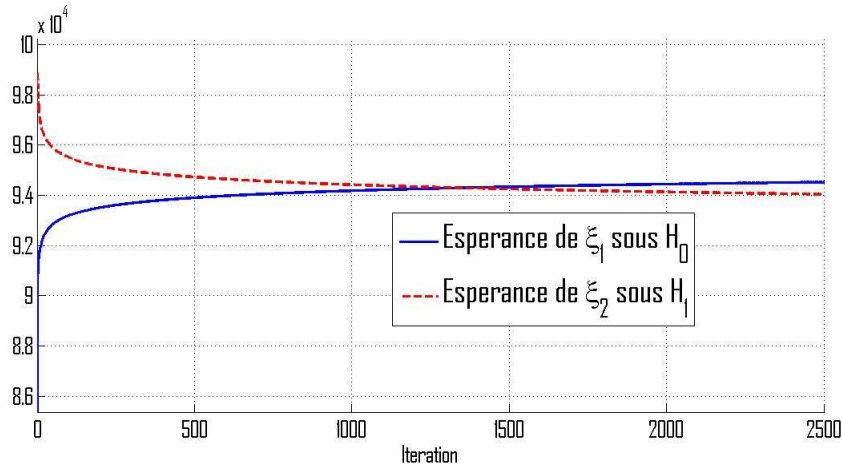


FIGURE 2.13 – L'esperance de ξ_1 (resp. ξ_2) sous H_0 (resp. H_1) en fonction du nombre d'itérations n à -10 dB, tracées à l'aide de (2.51) (resp. (2.52)). Nous pouvons observer que ξ_2 devient inférieur à ξ_1 après un certain nombre d'itérations sous faible *RSB*.

test cyclique peut ne pas toujours détecté, (*miss detection*) (les valeurs enregistrées dans les mémoires tampons (buffers) peuvent ne pas être de la même population). Dans ce cas, ξ_1 est modifié au lieu de ξ_2 . Ce qui induit une forte dégradation de la performance de détection. Lorsque ξ_1 devient supérieur à ξ_2 , l'algorithme HSD fixera $\xi_1 = \xi_2$ et mettra fin à son évolution. Dans ce cas, l'algorithme HSD a atteint sa limite de détection.

2.4.3 Résultats de simulation de l'HSD

Dans les simulations, nous avons utilisé une modulation de type 4-PSK à 20 kHz, $\alpha = \frac{1}{T_s}$ est la fréquence cyclique utilisée dans le détecteur cyclostationnaire, connue *a priori*, avec $T_s = 20T_e$ la période symbole de la 4-PSK. On rappelle que le niveau du bruit N_0 est supposé invariant dans le temps. Nous avons fixé N_1 et N_2 égaux à 30 dans la simulation de l'algorithme HSD. Le produit de TB est égal à 4500 et un environnement équiprobable ($P(H_0) = P(H_1) = 0,5$) a été utilisé. On note que les simulations de l'architecture sont exécutées pendant 10^4 itérations.

La figure 2.14 illustre l'évolution de ξ_1 et ξ_2 au cours des itérations de l'algorithme HSD à *RSB* = -5 dB.

Nous avons fixé ξ_G pour garantir une probabilité de fausse alarme à moins de 1%. Chaque marque sur les courbes dans la figure 2.14 indique une modification de ξ_1 ou ξ_2 . Nous pouvons observer qu'il y a beaucoup de marques au début, ce qui signifie que le test cyclostationnaire est fréquemment utilisé à ce stade, mais après un certain temps, il est




FIGURE 2.14 – La variation de ξ_1 et ξ_2 à -5 dB en utilisant l’HSD, avec $N_1 = 30$, et $N_2 = 30$. Chaque marque sur les courbes indique une modification de ξ_1 ou ξ_2 . On peut remarquer que le test cyclostationnaire est de moins en moins utilisé, quand le nombre d’itérations augmente, induisant une plus faible complexité.

beaucoup moins sollicité diminuant la complexité.

Afin de comparer les performances de détection des différentes techniques mentionnées ci-dessus, nous simulons la variation de la probabilité de détection en fonction du RSB, pour l’HSD, en utilisant la même $P_{fa,des} = 1\%$. On compare aussi ces résultats obtenus avec les courbes représentant les performances du test cyclique et du radiomètre. Les résultats sont présentés sur la figure 2.15, où l’on peut observer que les performances de l’algorithme HSD sont proches des performances du détecteur cyclostationnaire, ce qui signifie que l’HSD atteint les performances du test cyclique avec la complexité du radiomètre.




FIGURE 2.15 – Probabilité de détection simulée en fonction du RSB, de l’architecture HSD (avec $N_1 = N_2 = 30$), pour une $P_{fa,des}$ fixée à 1%, comparées aussi au test cyclostationnaire et au radiomètre théorique dans les mêmes conditions.

2.5 Version améliorée de l’algorithme HSD (EHSD)

Une version améliorée de l’architecture HSD, l’EHSD (*Enhanced HSD*) peut être étudiée afin d’améliorer la détection à plus faible RSB . L’EHSD se base aussi sur l’architecture hybride de l’HSD mais avec des modifications sur l’algorithme de fonctionnement. En effet l’EHSD fait une estimation du niveau du bruit N_0 (supposé constant par rapport au temps) directement à partir du $buffer_1$ contenant toutes les réalisations de la v.a. X (\mathcal{T}_{DE}), dont le paquet correspondant a été sélectionné par le détecteur cyclostationnaire comme provenant de H_0 . L’avantage par rapport à l’HSD est qu’au lieu de choisir la valeur de \mathcal{T}_{DE} qui est plus grande que la moyenne de $buffer_1$ pour la sauvegarder dans ce dernier, on estime N_0 d’une manière directe en utilisant toutes les valeurs de \mathcal{T}_{DE} dont le paquet correspondant est sélectionné par le détecteur cyclostationnaire comme provenant de H_0 , et donc une plus petite incertitude sera obtenue sur l’estimation de N_0 .

On garde le même algorithme de l’architecture HSD, mais avec juste quelques modifications : N_1 la taille de $buffer_1$, sera choisi grand pour faire une bonne estimation du niveau du bruit N_0 car l’estimation est directement faite à partir du $buffer_1$, et non plus d’une manière itérative comme dans le cas de l’HSD. En outre, on garde ξ_2 dans l’architecture afin de réduire la complexité de détection autant que possible. Dès que $buffer_1$ est plein, on calcule sa moyenne $\hat{\mu}_1$. Ensuite, l’EHSD utilise l’équation suivante (obtenue à partir de (2.3) sous H_0) pour estimer N_0 :

$$\hat{N}_0 = \frac{\hat{\mu}_1}{BT}$$

Avec l’utilisation de l’estimation \hat{N}_0 , on peut estimer $\hat{\xi}_0$ qui garantit la $P_{fa,des}$ à partir de l’équation :

$$\hat{\xi}_0 = G(P_{fa,des})\hat{N}_0$$

Dans sa phase transitoire *i.e.*, avant l'estimation de N_0 , l'EHS est un peu plus complexe que l'HSD, parce qu'il a besoin de répéter le test cyclostationnaire N_1 fois pour être en mesure d'estimer N_0 (la taille du $buffer_1$ dans l'algorithme EHS est généralement plus grande que la taille du $buffer_1$ dans l'algorithme HSD et ceci pour faire une bonne estimation du niveau du bruit). La figure 2.16 montre l'organigramme de l'EHS.

2.5.1 Performances de l'EHS

Soit D_0 (resp. D_1) l'événement qui désigne que le détecteur cyclique a choisi H_0 (resp. H_1). Si on suppose que pour un RSB donné, le détecteur cyclique peut faire de fausses alarmes sous H_0 et de bonnes détections sous H_1 indépendamment de la réalisation de la v.a. X (donc de la statistique \mathcal{T}_{DE} du signal reçu), alors nous pouvons écrire :

$$E(X|H_0, D_0) = \mu_1 \quad (2.53)$$

et

$$E(X|H_1, D_0) = \mu_2 \quad (2.54)$$

où $E(\cdot)$ désigne l'opérateur d'espérance.

Rappelons le théorème de partition en probabilité indiqué ci-dessous :

$$E(X|D_0) = E(X|H_1, D_0)P(H_1|D_0) + E(X|H_0, D_0)P(H_0|D_0)$$

En utilisant les hypothèses de (2.53) et (2.54), nous pouvons écrire :

$$E(X|D_0) = P(H_1|D_0)\mu_2 + P(H_0|D_0)\mu_1 \quad (2.55)$$

en appliquant l'égalité de Bayes, nous pouvons écrire :

$$P(H_1|D_0) = \frac{P(D_0|H_1)P(H_1)}{P(D_0)} \quad (2.56)$$

et

$$P(H_0|D_0) = \frac{P(D_0|H_0)P(H_0)}{P(D_0)} \quad (2.57)$$

Nous pouvons exprimer la probabilité que le détecteur cyclique choisit H_0 en fonction de $P(H_1)$, $P(H_0)$, P_{fa_g} , et P_{dg} :

$$P(D_0) = (1 - P_{fa_g})P(H_0) + (1 - P_{dg})P(H_1) \quad (2.58)$$

on considère maintenant la définition suivante :

$$\gamma = \frac{P(H_0)}{P(H_1)} = \frac{1 - P(H_1)}{P(H_1)} = \frac{1}{P(H_1)} - 1$$

où γ représente la caractéristique de l'environnement (libre ou occupé).




FIGURE 2.16 – L'organigramme de l'EHSD.

En utilisant (2.56), (2.57) et (2.58), l'équation (2.55) s'écrit :

$$E(X|D_0) = (1 - \delta)\mu_2 + \delta\mu_1 \quad (2.59)$$

où

$$\delta = \frac{1 - P_{fa_g}}{1 - P_{fa_g} + \frac{1 - P_{d_g}}{\gamma}}$$

Or pour tout δ on a :

$$(1 - \delta)\mu_2 + \delta\mu_1 \geq \mu_1$$

Par conséquent, nous concluons que :

$$E(X|D_0) \geq \mu_1$$

Cela signifie que nous avons toujours une surestimation du niveau du bruit N_0 ($\hat{\xi}_0 \geq \xi_0$), ce qui implique que la contrainte de fausse alarme sera toujours respectée dans la méthode EHSD (la probabilité de fausse alarme observée est alors inférieure ou égale à la fausse alarme souhaitée). En utilisant (2.59) nous pouvons trouver une approximation théorique pour l'expression de l'erreur relative $Erreur_{rel}$ sur le seuil estimé $\hat{\xi}_0$, en fonction du RSB . Cette erreur relative est définie par :

$$Erreur_{rel} = \frac{\hat{\xi}_0 - \xi_0}{\xi_0} \quad (2.60)$$

Pour N_1 large, la moyenne du $buffer_1$ peut être approximée par :

$$\hat{\mu}_1 \approx E(X|D_0)$$

donc :

$$\hat{N}_0 \approx \frac{E(X|D_0)}{TB}$$

En utilisant le résultat donné par (2.59) on peut écrire :

$$\hat{N}_0 \approx \frac{(1 - \delta)\mu_2 + \delta\mu_1}{TB}$$

en remplaçant ξ_0 par GN_0 et $\hat{\xi}_0$ par $G\hat{N}_0$, $Erreur_{rel}$ peut être approximée par :

$$Erreur_{rel} \approx \frac{\frac{G}{TB}((1 - \delta)\mu_2 + \delta\mu_1) - \frac{G}{TB}\mu_1}{\frac{G}{TB}\mu_1}$$

après simplification on obtient :

$$Erreur_{rel} \approx \frac{RSB}{\gamma \frac{1 - P_{fa_g}}{1 - P_{d_g}} + 1} \quad (2.61)$$

En observant la courbe de la figure 2.17, qui représente l'expression de l' $Erreur_{rel}$ en fonction du RSB obtenue en simulant (2.61) pour $\gamma = 1$, nous pouvons vérifier que pour un grand RSB (quand le test cyclique est parfait), le terme $1 - P_{d_g}$ tend vers zéro ainsi que l'expression globale de $Erreur_{rel}$. Dans ce cas, une excellente estimation de ξ_0 peut être faite. Pour les plus faibles valeurs de RSB , le terme $1 - P_{d_g}$ n'est plus nul parce que le test cyclostationnaire n'est plus un test idéal ce qui induit une erreur sur l'estimation de ξ_0 . Cette erreur atteint son maximum avant qu'elle ne commence à diminuer car le terme RSB dans (2.61) devient très faible. Physiquement cette réduction d'erreur est due au fait que le signal est trop faible et donc proche du niveau du bruit.




FIGURE 2.17 – L'approximation théorique de l'erreur relative sur le seuil ξ_0 en fonction du RSB , obtenue en simulant (2.61) pour $\gamma = 1$.

2.5.2 Résultats de simulations, discussions et comparaisons

Dans les simulations on utilise les mêmes conditions de simulation de la section 2.4.3 (4-PSK, N_0 invariant dans le temps, $BT = 4500$ etc). Nous avons fixé N_1 et N_2 égaux à 30 dans la simulation de l'algorithme HSD, tandis que pour l'algorithme EHSD, nous avons utilisé $N_1 = 100$ et $N_2 = 30$. Un environnement équiprobable a été utilisé ($\gamma = 1$), sauf indication contraire dans les simulations des différentes architectures.

Afin de comparer les performances de détection des différentes techniques mentionnées ci-dessus, nous simulons la variation de la probabilité de détection en fonction du RSB , pour l'HSD et l'EHSD, en utilisant la même $P_{fa,des} = 1\%$. On compare aussi ces résultats obtenus avec les courbes représentant les performances du test cyclique et du radiomètre sans et avec incertitude ($U = 0.5$ dB et $U = 1$ dB, avec U l'incertitude pic-à-pic sur l'estimation de N_0 donnée par (2.16)). Les résultats sont présentés sur la figure 2.18, où l'on peut observer que les performances de l'algorithme HSD sont proches des performances du détecteur cyclostationnaire, ce qui signifie que l'HSD atteint les performances du test cyclique avec la complexité du radiomètre. On observe aussi que les performances de l'HSD sont meilleures que les performances du radiomètre avec $U = 1$ dB. Maintenant, si on regarde les performances de l'EHSD, qui a aussi une complexité d'un radiomètre en régime permanent, nous pouvons voir qu'il est capable de détecter à 100%, avec une P_{fa} observée inférieure à 1% à partir de -8 dB, contre -3 dB pour le test cyclique, et ainsi l'EHSD réalise un gain de 5 dB en termes de RSB par rapport au test cyclique. On observe aussi que les performances de l'EHSD sont meilleures que les performances du radiomètre avec $U = 0.5$ dB. Il convient de noter que l'algorithme EHSD est un peu plus complexe que le HSD au début du processus de détection, car il a besoin d'un $buffer_1$ de plus grande taille afin de parvenir à une bonne estimation de N_0 .

La figure 2.19 valide l'approximation donnée en (2.61) de l'erreur relative du seuil $\hat{\xi}_0$ en fonction de la RSB . Cette approximation est très proche des résultats de simulation




FIGURE 2.18 – Probabilité de détection simulée en fonction du RSB, des architectures HSD (avec $N_1 = N_2 = 30$), et EHSD (avec $N_1 = 100$, et $N_2 = 30$) pour une $P_{fa,des}$ fixée à 1%, comparées aussi, au test cyclostationnaire et au radiomètre sans et avec incertitude, dans les mêmes conditions.




FIGURE 2.19 – Résultat de simulation de l'erreur relative sur le seuil estimé $\hat{\xi}_0$ en fonction du RSB en utilisant l'algorithme EHSD, comparée par rapport à l'approximation théorique donnée dans (2.61) pour $\gamma = 1$.

particulièrement pour les faibles et hauts RSB. On peut conclure que lorsque le test de détection cyclostationnaire commence à détecter à 100% ($RSB > -3$ dB), nous pouvons avoir une estimation parfaite de ξ_0 . Une remarque importante est que, par exemple, à -8 dB, nous avons une erreur maximale sur l'estimation du seuil et nous pouvons encore détecter à 99% (*cf.* figure 2.18). Ce fait est expliqué par la figure 2.20, qui montre la densité de probabilité PDF de X sous H_0 et H_1 à -8 dB en utilisant (2.3). En effet nous pouvons observer que ces densités sont encore bien séparées à -8 dB. En conséquence cette erreur d'estimation n'a donc pas un impact significatif sur les performances de détection.




FIGURE 2.20 – Les distributions de la v.a. X sous les deux hypothèses H_0 et H_1 obtenues en utilisant (2.3) à -8 dB. On constate que dans cette situation ξ_0 est situé sur la queue de la densité de X sous H_1 , c'est pourquoi nous pouvons encore obtenir de bonnes performances de détection, même si l'erreur d'estimation sur $\hat{\xi}_0$ est maximale.

En effet, nous pouvons observer que $\hat{\xi}_0$ est situé sur la queue de la PDF de X sous H_1 , c'est pourquoi nous pouvons encore obtenir de bonnes performances de détection, même si l'erreur d'estimation sur $\hat{\xi}_0$ est maximale.

2.5.2.1 L'influence de l'environnement γ sur les performances des algorithmes HSD et EHSD

Comme nous l'avons déjà vu, l'état du canal (libre ou occupé) peut être caractérisé par la variable γ qui est le rapport entre $P(H_0)$ et $P(H_1)$. Si nous regardons de près la figure 2.13, nous notons que le point d'intersection des deux courbes qui présente l'espérance de ξ_1 et ξ_2 , sous respectivement H_0 et H_1 , ne dépend pas uniquement du RSB du signal reçu, mais aussi de la façon dont la séquence des événements *canal libre* et *canal occupé* sont survenus lors de l'utilisation de l'algorithme HSD, et donc de l'environnement γ . Aussi, si nous regardons (2.61) qui donne l'erreur relative sur l'estimation du seuil optimal lorsqu'on utilise l'algorithme EHSD, nous pouvons vérifier que cette erreur dépend aussi de la caractéristique de l'environnement γ . En effet si on regarde le dénominateur de (2.61), on remarque qu'il dépend du terme $\gamma \cdot \frac{1-P_{fa_g}}{1-P_{d_g}}$. Pour les grandes valeurs de RSB on a P_{d_g} qui tend vers 1, et donc le dénominateur tend vers l'infini. Dans le cas des très faibles RSB on a $P_{fa_g} \cong P_{d_g}$, et c'est uniquement la valeur de γ qui contrôle le dénominateur et donc l'*Erreur_{rel}*. Pour le reste des cas du RSB on a $P_{d_g} > P_{fa_g}$, donc le terme $\frac{1-P_{fa_g}}{1-P_{d_g}}$ est supérieur à un. Dans ce dernier cas c'est toujours la valeur de γ qui influence le dénominateur. C'est la raison pour laquelle il est intéressant d'observer l'influence de l'environnement γ sur les performances de nos différentes architectures proposées.

Nous avons utilisé deux environnements de simulations extrêmes afin d'observer la variation des performances du détecteur HSD. Le premier environnement est défini par $\gamma = 99$ ($P(H_0) = 99\%$) et le second par $\gamma = 0,01$. Nous observons sur la figure 2.21 que les performances varient effectivement en fonction de l'environnement γ . Pour $\gamma = 99$, ce qui signifie que 99% du temps la bande est libre, ξ_1 ne cesse d'être modifié (d'augmenter), entraînant une réduction de la performance de détection. Cet environnement ($\gamma \gg 1$)

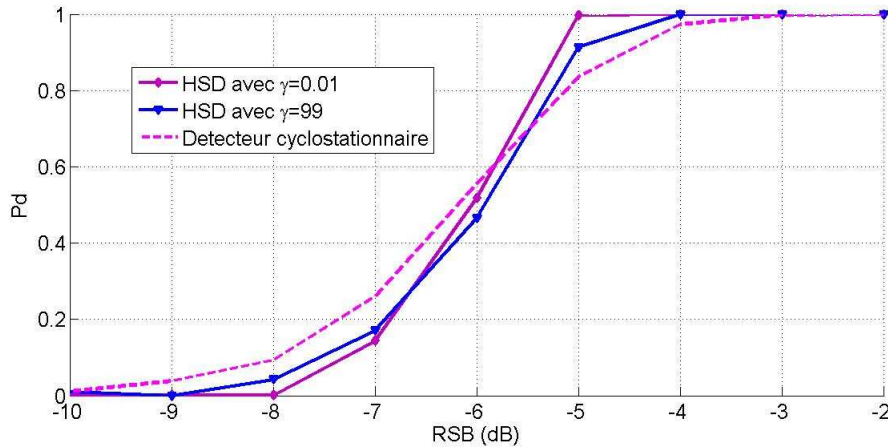


FIGURE 2.21 – La probabilité de détection simulée sous différents RSB, pour l'HSD avec $P_{fa,des}$ fixé à 1% en utilisant $\gamma = 99$ et $\gamma = 0,01$, également comparé par rapport au test de Dandawaté et Giannakis dans les mêmes conditions.

n'est pas très favorable à l'algorithme HSD, car il aura des performances de détection proches du détecteur cyclostationnaire (à -4 dB l'HSD détecte jusqu'à 100% contre -3 dB pour le détecteur cyclique), donc le principal avantage dans ce cas est la plus faible complexité de l'algorithme HSD.

Toutefois, lorsque $\gamma = 0,01$ ($P(H_1) = 99\%$) ξ_2 ne cesse d'être modifié (de baisser), ce qui permet d'avoir de meilleurs résultats de détection. Dans ce cas, un gain de 2 dB est observé par rapport au détecteur cyclique. Par ailleurs l'HSD est encore moins complexe, et détecte mieux que le détecteur cyclostationnaire. Enfin, nous concluons que l'algorithme HSD assure un gain entre un et deux dB sur les performances de détection du détecteur cyclique avec une complexité plus faible.

Maintenant, nous simulons l'architecture EHSD dans les deux environnements, $\gamma = 99$ et $\gamma = 0,01$. Pour $\gamma = 99$, les performances observées dans la figure 2.22 sont proches des performances théoriques du radiomètre. Ce résultat est expliqué dans (2.61) qui montre que l'erreur relative est inversement proportionnelle à γ . Donc, pour $\gamma = 99$ cette erreur est presque nulle pour tous les RSB. Par conséquent le seuil estimé $\hat{\xi}_0$ est très proche du seuil optimal ξ_0 , ce qui explique le résultat obtenu. D'autre part pour $\gamma = 0,01$, la même formule (2.61) montre que l'erreur relative sur l'estimation du seuil optimal est élevée parce que γ est inférieure à 1 donc le dénominateur de (2.61) ne participe pas significativement à la diminution de l'*Erreur_{rel}*. D'autre part, pour une grande valeur du RSB, nous avons P_{dg} proche de 1, ce qui fait tendre l'erreur relative à zéro. En conclusion,

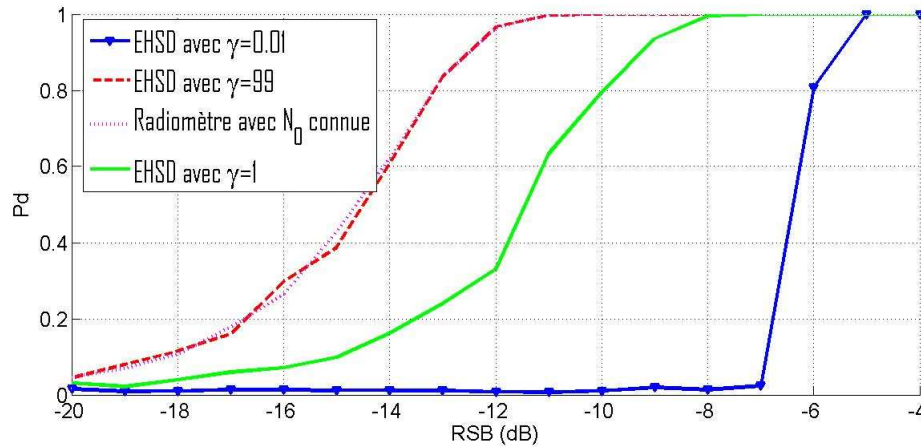


FIGURE 2.22 – La probabilité de détection simulée en fonction du RSB de l’EHSD avec $P_{fa,des}$ fixée à 1% pour $\gamma = 99$ et $\gamma = 0,01$, également comparé par rapport au radiomètre théorique dans les mêmes conditions.

nous pouvons observer que les performances de l’EHSD sont toujours meilleures que celles de l’algorithme HSD. En fait, il y a toujours au moins un gain de 2 dB par rapport au détecteur cyclique, et si l’environnement est favorable ($\gamma \gg 1$) à l’algorithme EHSD, on peut même atteindre les performances théorique du radiomètre.

2.5.2.2 Comparaison des performances en utilisant les courbes de ROC

Une autre façon de comparer les performances des détecteurs consiste à tracer les courbes de ROC déjà définies dans le chapitre 1. Pour $\gamma = \frac{P(H_0)}{P(H_1)} = 1$, nous simulons pour différents RSB les courbes de ROC des deux architectures HSD et EHSD. Pour un $RSB = -5$ dB, on peut vérifier sur la figure 2.23 que les deux architectures présentent les mêmes performances. En diminuant encore le RSB à -10 dB, on observe sur la figure 2.24, la supériorité de l’EHSD sur l’HSD en termes de détection. Bien que les deux architectures EHSD et HSD convergent vers la complexité du radiomètre à l’état stationnaire, l’EHSD présente toujours de meilleures performances que l’HSD. Par conséquent, il est préférable d’utiliser l’EHSD à la place de l’HSD.

2.6 Conclusion

La détection du spectre est soumise à des contraintes du temps. Pour cette raison, nous avons proposé des architectures de détection adaptative, qui combinent deux systèmes. Le premier système est un détecteur à faible complexité, mais il est très sensible à une mauvaise estimation du niveau du bruit. Quant au second, c’est un système plus complexe, fondé sur la détection cyclostationnaire, mais plus résistant à une mauvaise estimation de N_0 . Ces deux nouvelles architectures adaptatives permettent une détection à faible RSB avec une diminution de la complexité. Dans un bruit gaussien les résultats obtenus sont prometteurs comme il a été montré par les simulations réalisées. Il a été aussi montré que




FIGURE 2.23 – Les courbes de ROC de l’HSD et de l’EHSD à -5 dB, pour $\gamma = 1$. Nous observons dans ces conditions que l’HSD et l’EHSD présentent les mêmes performances.




FIGURE 2.24 – Les courbes de ROC de l’HSD et de l’EHSD à -10 dB, pour $\gamma = 1$. On observe que, dans ces conditions l’EHSD présente de meilleures performances de détection par rapport à l’HSD.

les performances des deux architectures proposées dépendent de l’environnement qui a été modélisé par la variable γ . Cependant d’après les résultats de simulations quel que soit la valeur de γ ($\gamma = 99, \gamma = 1$ et $\gamma = 0,01$) les résultats de ces nouvelles architectures restent satisfaisants.

Chapitre 3

Nouvel estimateur du cyclospectre utilisant le compressed sensing

3.1 Introduction

Comme nous l'avons déjà évoqué dans le chapitre 1, les signaux de télécommunications sont des signaux cyclostationnaires, par la suite leurs fonctions d'autocorrelation cyclique prennent des valeurs nuls sauf pour les multiples entiers de la fréquence cyclique fondamentale. Cette particularité rend la fonction d'autocorrelation cyclique (FAC), des signaux de télécommunications, parcimonieuse dans le domaine des fréquences cycliques.

Dans ce chapitre, la propriété parcimonieuse de la FAC va nous permettre de proposer un nouvel estimateur qui se base sur le *compressed sensing* afin d'estimer le vecteur d'autocorrelation cyclique (VAC), qui est un vecteur particulier de la FAC pour un délai τ fixe. Deux métriques vont être utilisées afin d'évaluer cette estimation. La première, l'erreur quadratique moyenne (EQM) compare le VAC estimé avec la référence théorique obtenue en utilisant la FAC. La deuxième métrique, notée EQM_{α_f} , compare la fréquence cyclique estimée à la valeur de la fréquence cyclique théorique. Les résultats de simulation de ce nouvel estimateur montreront de plus faibles valeurs de l' EQM et de l' EQM_{α_f} que celles obtenues avec l'estimateur classique (3.13) utilisé dans [2] dans les mêmes conditions et utilisant le même nombre d'échantillons. Plusieurs cas vont être analysés : avec et sans filtrage à l'émission, à la réception avec filtrage à l'émission et enfin avec l'ajout d'un canal de propagation.

3.2 Parcimonie et compressed sensing

3.2.1 Parcimonie

Avant d'introduire l'approximation parcimonieuse, définissons d'abord le terme parcimonie (*sparse* en anglais). La parcimonie est une propriété mesurable dans un vecteur $\mathbf{v} \in \mathbb{C}^{\tilde{N} \times 1}$. Un vecteur est dit parcimonieux si la plupart de ses éléments sont nuls. Plus exactement, un vecteur de dimension \tilde{N} de $\mathbb{C}^{\tilde{N} \times 1}$, est k -parcimonieux dans une base orthogonale de dimension $\tilde{N} \gg k$, si on peut représenter avec une bonne approximation, ce vecteur à l'aide d'environ k composantes de cette base [129]. Cela signifie que le vecteur est petit, mais ce n'est pas le nombre d'éléments du vecteur qui est important, mais c'est

le nombre d'éléments non nuls dans ce vecteur. Pour cela, la norme l_0 qui représente le nombre d'éléments non nuls présents dans un vecteur, est utilisée pour mesurer la parcimonie d'un vecteur. Mathématiquement la norme l_0 d'un vecteur \mathbf{v} de taille \tilde{N} est définie par :

$$\|\mathbf{v}\|_0 = \text{card}\{\text{supp}(\mathbf{v})\} \quad (3.1)$$

avec

$$\text{supp}(\mathbf{v}) = \{k; v_k \neq 0, k = 1, \dots, \tilde{N}\}$$

Dans la pratique plusieurs avantages existent dans l'utilisation des vecteurs parcimonieux comme par exemple : les calculs impliquant la multiplication d'un vecteur par une matrice sont beaucoup moins complexes en général, si le vecteur est parcimonieux. Les vecteurs parcimonieux nécessitent moins d'espace quand ils sont stockés sur un ordinateur sachant que seulement la position et la valeur des éléments non nuls sont requises pour faire l'enregistrement. La parcimonie est exploitée dans de nombreux domaines : le traitement d'image (les techniques de codage d'images, compression, *impainting*, *denoising*, ainsi que dans l'imagerie médicale), la détection, l'estimation et dans le développement des convertisseurs analogiques [129]...

3.2.2 Compressed sensing

Compressed sensing est une technique d'acquisition et de reconstruction d'un signal qui utilise la connaissance préalable que ce signal est parcimonieux. Plus précisément, si \mathbf{v} est un vecteur de dimension \tilde{N} du signal parcimonieux avec k éléments non nuls, soit \mathbf{y} , le vecteur de dimension n , ($k < n < \tilde{N}$), appeler le vecteur de mesure satisfaisant la relation suivante :

$$\mathbf{y} = \mathbf{A}\mathbf{v} \quad (3.2)$$

où : \mathbf{A} représente la matrice de mesure (aussi appelé dictionnaire⁽¹⁾) qui définit la relation entre \mathbf{v} et \mathbf{y} . Les colonnes du dictionnaire \mathbf{A} sont constituées d'un vaste ensemble de signaux élémentaires et redondant, appelés atomes (terminologie introduite par Mallat et Zhang [130]). Les atomes linéairement combinés entre eux, formeront la représentation parcimonieuse du signal \mathbf{y} . Notons bien qu'une représentation parcimonieuse n'est qu'une représentation approximative du signal, donc une erreur de reconstruction existe. L'objectif reste néanmoins l'obtention de la solution la plus parcimonieuse, parmi celles ayant la même erreur de reconstruction. En effet, la convergence vers la dite solution optimale peut s'avérer complexe dans le cas de signaux bruités. Cette problématique a fait l'objet de plusieurs études [131, 132, 133], notamment dans le cadre de la détection de signal.

Comme \mathbf{v} a juste quelques composantes non nulles, il est possible de récupérer la valeur de \mathbf{v} à partir de la connaissance de \mathbf{y} . Afin de trouver parmi l'infinité des solutions possibles, une ou bien l'unique solution du problème (3.2), ayant le plus petit nombre possible de composantes différentes de zéro, il faut trouver la solution du problème d'optimisation suivant :

$$\mathcal{P}_0 : \min \|\mathbf{v}\|_0, \text{ sous } \mathbf{A}\mathbf{v} = \mathbf{y} \quad (3.3)$$

(1). Le dictionnaire est aussi appelé base redondante car il contient un nombre d'atomes (ou de colonnes) supérieur au nombre de lignes et donc les atomes sont linéairement dépendants. Ainsi, utiliser le mot base est un abus de langage.

La minimisation exacte de la norme l_0 est un problème NP-complet [134] qui n'a pas de solutions pratiques. Ce problème ne peut donc être résolu qu'en utilisant une approche combinatoire c'est à dire tester systématiquement toutes les combinaisons possibles afin de trouver la solution. Cette approche qui peut être très difficile à résoudre ne peut donc pas être retenue.

Un autre problème plus simple est donc considéré, il s'agit de rechercher la solution la plus parcimonieuse tout en tolérant une erreur admissible de reconstruction, notée ρ :

$$\tilde{\mathcal{P}}_0 : \min \|\mathbf{v}\|_0, \text{ sous } \|\mathbf{A}\mathbf{v} - \mathbf{y}\|_2 \leq \rho \quad (3.4)$$

où $\|\cdot\|_2$ représente la norme euclidienne l_2 .

La solution du problème d'optimisation $\tilde{\mathcal{P}}_0$ est le vecteur parcimonieux \mathbf{v} , dont le nombre de coefficients non-nuls est minimal. Le vecteur \mathbf{v} conduit à une approximation dont l'erreur de reconstruction est inférieure ou égale à ρ .

Certains algorithmes itératifs visent à obtenir la solution du problème $\tilde{\mathcal{P}}_0$. Ces algorithmes ne cherchent pas exactement à résoudre le problème en trouvant l'approximation optimale. Ils raffinent progressivement l'approximation faite du signal par une procédure itérative. Parmi ces algorithmes on cite le matching pursuit (MP) et le orthogonal matching pursuit (OMP). Le MP nommé ainsi par Mallat et Zhang en 1993 [130] est un algorithme glouton, connu pour être une alternative à la recherche de la solution optimale. L'algorithme permet de trouver une approximation sous-optimale du problème $\tilde{\mathcal{P}}_0$. Le principe est donc de sélectionner pas à pas les atomes les plus corrélés avec le signal pour converger vers une approximation de la solution. Cependant, cette simplicité a un inconvénient : il peut falloir un grand nombre d'itérations pour converger vers une solution, ainsi dans certains cas un atome déjà sélectionné peut à nouveau l'être.

Afin de pallier la faille du MP, qui n'empêche pas la sélection multiple d'un même atome l'OMP a été introduit. Il est apparu dans [135] et a été proposé indépendamment dans [136]. L'OMP se base sur le même principe que le MP : sélectionner pas à pas les atomes les plus corrélés au signal pour converger vers une approximation de la solution au problème $\tilde{\mathcal{P}}_0$. La différence réside dans la mise à jour des coefficients. A chaque itération l de l'OMP la solution localement optimale $\hat{\mathbf{v}}_l$ (la valeur de $\hat{\mathbf{v}}$ après l'itération l) est calculé. Cela se fait en trouvant à chaque itération, l'atome \mathbf{a} de \mathbf{A} qui est le plus corrélé avec le vecteur résiduel \mathbf{res}_l .

Le vecteur résiduel est initialisé au début au vecteur qui doit être approximé c.-à-d. $\mathbf{res}_0 = \mathbf{y}$. Le vecteur résiduel est ensuite ajusté après chaque itération en tenant compte de la nouvelle approximation $\hat{\mathbf{v}}_l$ obtenue en utilisant la dernière mise-à-jour de l'ensemble des atomes sélectionnés après l'itération l , (l'entrée d'un nouvel atome dans la décomposition modifie l'espace engendré. Il est donc plus judicieux de projeter le signal \mathbf{y} , non plus sur le seul nouvel atome, mais sur l'ensemble formé des atomes passés auquel s'ajoute le nouvel atome sélectionné).

Afin de faire cette projection une étape de minimisation quadratique est utilisée à chaque itération, cette minimisation quadratique a pour but d'améliorer la nouvelle approximation d'une part, et de mettre à jour le vecteur résiduel \mathbf{res}_l d'une autre part. Ainsi à chaque itération l'OMP recalcule la valeur de l'estimée $\hat{\mathbf{v}}_l$. La reconstruction courante $\hat{\mathbf{v}}_l$ est évaluée à chaque fois, ce qui signifie que l'on recalcule tous les coefficients jusque' alors sélectionnés.

Voici les lignes de l'algorithme de l'OMP :

Entrées :

- Le vecteur signal \mathbf{y} de taille n .
- Le dictionnaire \mathbf{A} de taille (n, \tilde{N}) .
- Le critère d'arrêt (exemple jusqu'à atteindre un niveau de précision ou pour un nombre d'itération fixé).

Sortie :

- Le vecteur d'approximation \mathbf{c} qui représente $\hat{\mathbf{v}}$.

Algorithme :

1. Commencer par initialiser le nombre d'itérations $l = 0$, la valeur du vecteur résidu $\mathbf{res}_l = \mathbf{y}$, et l'ensemble des indices des atomes sélectionnés de \mathbf{A} après chaque itération $V_0 = \Phi$.
2. Soit $v_l = i$ où \mathbf{a}_i est la solution de $\max \langle \mathbf{res}_l; \mathbf{a}_k \rangle$ où \mathbf{a}_k sont les atomes de \mathbf{A} .
3. Mettre à jours l'ensemble V_l avec l'élément v_l : $V_l = V_{l-1} \cup \{v_l\}$.
4. Résoudre le problème quadratique pour trouver \mathbf{c} qui représente $\hat{\mathbf{v}}_l$

$$\min_{\mathbf{c} \in \mathbb{C}^{\tilde{N} \times 1}} \left\| \mathbf{y} - \sum_{j=1}^l \mathbf{c}(v_j) \mathbf{a}_{v_j} \right\|_2 \quad (3.5)$$

5. Calculer le nouveau résidu

$$\mathbf{res}_l = \mathbf{y} - \mathbf{A} \cdot \hat{\mathbf{v}}_l \quad (3.6)$$

6. $l \leftarrow l + 1$

7. Vérifier le critère d'arrêt, si ce n'est pas encore vérifié, retour à l'étape 2.

Un autre type d'algorithmes qui est très utilisé aussi pour résoudre approximativement (3.2), se base sur la minimisation de la norme l_1 , qui est définie par la somme des valeurs absolues des éléments d'un vecteur de taille \tilde{N} :

$$\|\mathbf{v}\|_1 = \sum_{i=1}^{\tilde{N}} |v_i| \quad (3.7)$$

En utilisant la norme l_1 , le problème $\tilde{\mathcal{P}}_0$ peut-être reformulé sous la forme du problème du *basis pursuit denoising* donné par :

$$\tilde{\mathcal{P}}_1 : \min \|\mathbf{v}\|_1, \text{ sous } \|\mathbf{A}\mathbf{v} - \mathbf{y}\|_2 \leq \rho \quad (3.8)$$

Parmi les algorithmes qui utilisent la minimisation l_1 pour résoudre ce genre de problème ou bien des problèmes similaires au *basis pursuit denoising*, on cite les plus connus qui sont le LARS [137] *least angle regression*, LASSO, *least absolute shrinkage and selection operator* introduit en 1996 par Tibshirani [138], le filtre adapté global *global matched filter* [139] qui est un algorithme initialement développé pour résoudre des problèmes de détection et d'estimation, notamment pour des applications sonar. L'avantage de ces algorithmes est qu'ils sont facilement exécutés avec une programmation linéaire et quadratique qui vise à résoudre de manière exacte le problème \mathcal{P}_1 .

Dans ce travail on a choisi de retenir l'OMP comme méthode de reconstruction pour trouver le vecteur $\hat{\mathbf{v}}$ (souvent appelée la reconstruction inverse), à cause de sa faible complexité de calcul comparé aux autres méthodes [140] tout en sachant que la complexité

dans le *spectrum sensing* est un point d'importance majeur. De plus l'OMP offre la possibilité de travailler avec un nombre fixe d'itération, donc un temp de calcul limité, même si on obtient pas une reconstruction complète du VAC. En effet en *spectrum sensing* il est uniquement nécessaire de savoir si la bande contient un signal ou non, (inutile donc de faire une reconstruction complète du VAC). Ce point sera discuté plus en détail dans le chapitre suivant.

3.2.2.1 La propriété d'isométrie restreinte

Une propriété centrale dans la théorie du *compressed sensing* est la propriété d'isométrie restreinte, en anglais *restricted isometry property* (RIP), concept introduit par Emmanuel Candès et Terence Tao dans [141]. Le critère RIP est définie de la façon suivante :

Une matrice \mathbf{A} satisfait la propriété d'isométrie restreinte d'ordre s avec le paramètre $\delta_s \in [0, 1[$ si la condition

$$(1 - \delta_s) \|\mathbf{x}\|_2^2 \leq \|\mathbf{A}\mathbf{x}\|_2^2 \leq (1 + \delta_s) \|\mathbf{x}\|_2^2$$

est satisfaite simultanément pour tout vecteur parcimonieux \mathbf{x} ne comportant pas plus que s entrées non nulles.

Les premiers résultats montrent que la reconstruction du vecteur parcimonieux \mathbf{x} à partir d'un nombre relativement restreint d'observations peut être réalisé, lorsque \mathbf{A} est une matrice qui satisfait le critère RIP. Des résultats similaires sont aussi valables lorsque \mathbf{x} est *pseudo-sparse* ou bien quand les observations sont corrompues par du bruit [142].

Pour utiliser le critère du RIP dans la pratique, il faut déterminer quelles sortes de matrices satisfont les constantes d'isométrie restreinte, et combien de mesures minimales sont nécessaires. Bien qu'il soit très difficile de vérifier si une matrice donnée satisfait à ce critère (RIP), il a été démontré que de nombreuses matrices satisfont la propriété d'isométrie restreinte avec une forte probabilité et peu de mesures [143]. En particulier, il a été montré qu'avec une probabilité exponentiellement élevé, les matrices partielles de Fourier (sous-matrice de la matrice de Fourier \mathbf{F}) satisfont la propriété d'isométrie restreinte [143]. Des résultats analogues sont également valables pour les sous-matrices de la matrice conjuguée de Fourier \mathbf{F}^* [142].

On note finalement que le dictionnaire qui sera utilisé dans le cadre de cette thèse, (qui est une sous-matrice formée par les n premières lignes de \mathbf{F}^*), est le même dictionnaire utilisé pas Fuchs dans [144] pour résoudre le problème d'identification des sinusoides réels dans un bruit Gaussien.

3.3 Cyclospectre et parcimonie

Comme il a été présenté dans le chapitre 1, l'expression théorique de la FAC d'un signal linéairement modulé avec T_s la période symbole et τ un retard donné, est donnée par l'équation (1.42). Une démonstration très similaire qui aboutit au même résultat peut aussi être trouvée dans [145]. Afin de simplifier, on prend σ_d^2 la puissance d'un symbole à l'émission égale à 1, la FAC devient donc :

$$R_{yy}(\alpha, \tau) = \begin{cases} \frac{1}{T_s} e^{-j2\pi\alpha\tau} \int_{-\infty}^{\infty} g(t - \frac{\tau}{2}) g^*(t + \frac{\tau}{2}) e^{-j2\pi\alpha t} dt \\ 0 \text{ pour } \alpha \neq \frac{k}{T_s}, k \in \mathbb{Z} \end{cases} \quad (3.9)$$

On rappelle que ϵ est un retard inconnu, $g(t)$ la réponse impulsionnelle temporelle du filtre d'émission et $g^*(t)$ dénote le complexe conjugué de $g(t)$. D'après l'équation (3.9) il est évident que la FAC est une fonction parcimonieuse dans le domaine des fréquences cycliques α vu qu'elle ne prend des valeurs non nulles que pour des valeurs de α qui sont des multiples entiers de la fréquence cyclique fondamentale.

On peut aussi vérifier la propriété parcimonieuse de la FAC en regardant la figure 3.1 qui illustre la norme de la fonction d'autocorrélation cyclique d'une BPSK pour un délai τ fixe.




FIGURE 3.1 – La norme théorique de la fonction d'autocorrélation cyclique d'une BPSK.

On définit le vecteur d'autocorrélation cyclique (VAC) comme un vecteur particulier issue de la FAC pour un délai fixe $\tau = \tau_0$, et sur un domaine de fréquence cyclique $[\alpha_{min}, \alpha_{max}]$. Le VAC est donné par :

$$\mathbf{r}_{yy}^{(\tau_0)} = [R_{yy}(\alpha_{min}, \tau_0), R_{yy}(\alpha_{min} + \delta_\alpha, \tau_0), \dots, R_{yy}(\alpha_{max}, \tau_0)]^T \quad (3.10)$$

avec δ_α le pas de résolution.

A partir de (3.9) il est facile de dériver l'expression théorique de la norme de la FAC, en utilisant une fenêtre temporelle rectangulaire $g(t)$ à l'émission définie comme suit :

$$g(t) = \begin{cases} 1 & |t| \leq \frac{T_s}{2} \\ 0 & \text{ailleurs} \end{cases}$$

ainsi, le résultat obtenu est le suivant :

$$\|R_{yy}(\alpha, \tau)\|_2 = \begin{cases} \frac{(T_s - \tau)}{T_s} \text{sinc}(\alpha(T_s - \tau)) \\ 0 & \text{pour } \alpha \neq \frac{k}{T_s}, k \in \mathbb{Z} \end{cases} \quad (3.11)$$

L'équation (3.11) va être utilisée comme notre référence théorique dans le calcul de l'EQM du vecteur obtenu en estimant le VAC avec plusieurs techniques dans le reste de ce travail ; on note donc :

$$R_{yy}^{\|\text{ref}\|}(\alpha, \tau) = \|R_{yy}^{\text{ref}}(\alpha, \tau)\|_2 = \|R_{yy}(\alpha, \tau)\|_2 \quad (3.12)$$

3.4 Estimation classique du vecteur d'autocorrelation cyclique

Afin d'estimer le VAC comme défini dans (3.10), on doit d'abord estimer la FAC (cf. chapitre 1), sur les différents couples : $(\alpha_{min}, \tau_0), (\alpha_{min} + \delta_\alpha, \tau_0), \dots, (\alpha_{max}, \tau_0)$. Une estimation classique de la FAC d'un processus $y(t)$ sur un couple (α, τ) peut être faite en utilisant l'estimateur non biaisé utilisé dans [2] (cf. section B.2 de l'annexe B) :

$$\hat{R}_{yy}^{cl}(\alpha, \tau) \cong \frac{1}{N} \sum_{k=0}^{N-1} y(kT_e)y(kT_e + \tau)e^{-j2\pi\alpha kT_e} \quad (3.13)$$

donc le vecteur $\hat{\mathbf{r}}_{yy}^{(\tau_0)}(\alpha)$ de \tilde{N} éléments représente donc l'estimateur classique du VAC est noté $V\hat{A}C_{classique}$ est donné par l'équation(3.14) :

$$V\hat{A}C_{classique} = \hat{\mathbf{r}}_{yy}^{(\tau_0)}(\alpha) = [\hat{R}_{yy}^{cl}(-\alpha_{max}, \tau_0), \hat{R}_{yy}^{cl}(-\alpha_{max} + \delta_\alpha, \tau_0), \dots, \hat{R}_{yy}^{cl}(\alpha_{max}, \tau_0)]^T \quad (3.14)$$

Où $\delta_\alpha = \frac{2 \cdot \alpha_{max}}{\tilde{N}} = \frac{1}{\tilde{N} \cdot T_e}$ représente le pas de résolution.

À noter que $\mathbf{r}_{yy}^{(\tau_0)}(\alpha)$ peut aussi être estimé en utilisant l'opérateur FFT appliqué sur le produit $y(kT_e) \cdot y(kT_e + \tau)$ [146]. En effet, on définit :

$$f_\tau(kT_e) = y(kT_e)y(kT_e + \tau) \quad (3.15)$$

En remplaçant dans (3.13), on peut alors écrire :

$$\hat{R}_{yy}^{cl}(\alpha, \tau) \cong \frac{1}{N} \sum_{k=0}^{N-1} f_\tau(kT_e)e^{-j2\pi\alpha kT_e} \quad (3.16)$$

On définit le vecteur \mathbf{f}_τ comme suit :

$$\mathbf{f}_\tau = [f_\tau(0), f_\tau(1 \cdot T_e), \dots, f_\tau((\tilde{N} - 1) \cdot T_e)]^T \quad (3.17)$$

En observant l'équation (3.16), on peut constater que le vecteur $\hat{\mathbf{r}}_{yy}^{(\tau_0)}(\alpha)$ qui représente l'estimation du VAC du signal $y(t)$, dans le domaine cyclique $[-\alpha_{max}, \alpha_{max}]$ n'est rien d'autre que la transformée de Fourier discrète, en anglais *discrete Fourier transform* (DFT) du vecteur \mathbf{f}_{τ_0} à un facteur $\frac{1}{\tilde{N}}$ près :

$$\hat{\mathbf{r}}_{yy}^{(\tau_0)}(\alpha) = \frac{1}{\tilde{N}} DFT(\mathbf{f}_{\tau_0}) \quad (3.18)$$

donc $\mathbf{r}_{yy}^{\tau_0}(\alpha)$ peut aussi être estimé en utilisant l'opérateur FFT car d'après (3.18) on peut écrire :

$$\hat{\mathbf{r}}^{FFT} = \frac{1}{\tilde{N}} FFT(\mathbf{f}_{\tau_0}) \quad (3.19)$$

Ce dernier estimateur (3.19) ne sera pas utilisé dans nos simulations, car en l'utilisant, le nombre d'échantillons N utilisé pour construire le vecteur \mathbf{f}_{τ_0} , est presque égal au nombre d'éléments \tilde{N} du vecteur estimé $\hat{\mathbf{r}}^{FFT}$, ($N = \tilde{N} + \lceil \tau_0/T_e \rceil \cong \tilde{N}$). Or dans ce chapitre on s'intéresse parfois à faire varier le nombre d'échantillons N pour estimer un vecteur de taille \tilde{N} fixe, ce qui rend l'estimateur $V\hat{A}C_{classique}$ le mieux adapté.

3.5 Estimation aveugle du vecteur de l'autocorrelation cyclique en utilisant le compressed sensing

Dans cette section on introduit un nouveau moyen se basant sur le *compressed sensing* afin d'estimer le VAC d'une manière aveugle sans même la nécessité de connaître *a priori* la valeur de la fréquence cyclique fondamentale recherchée à l'opposition de la méthode classique. De plus en utilisant le même nombre d'échantillons, avec le *compressed sensing* on montrera qu'une meilleure estimation est obtenue.

L'équation (3.18) va être utilisée afin de justifier le choix du dictionnaire \mathbf{A} dans la représentation parcimonieuse du VAC comme il va être expliqué dans la suite.

On propose donc dans ce travail d'exploiter la propriété parcimonieuse du VAC $\mathbf{r}_{yy}^{(\tau_0)}(\alpha)$ vu qu'il ne contient des valeurs non nulles que pour seulement quelques valeurs précises de α . On peut donc reconstruire le vecteur $\hat{\mathbf{r}}_{yy}^{(\tau_0)}(\alpha)$ sur l'intervalle discret de taille \tilde{N} avec un pas δ_α de résolution égal à $\frac{2 \cdot \alpha_{max}}{\tilde{N}}$, en n'utilisant que n échantillons (ou observations) au lieu de \tilde{N} avec la méthode classique donner par (3.18), avec $n < \tilde{N}$.

On propose donc d'appliquer une représentation parcimonieuse qui se base sur la représentation des n premiers éléments de \mathbf{f}_{τ_0} sur une base complexe redondante constituée de \tilde{N} « cisoïdes » équidistantes en fréquence d'un pas δ_α ; ou d'une manière équivalente sur les colonnes (atomes) de la matrice \mathbf{A} qui est une sous-matrice formée par les n premières lignes de \mathbf{F}^* , le complexe conjugué de la matrice carrée de Fourier \mathbf{F} de dimension \tilde{N} , (comme $\hat{\mathbf{r}}_{yy}^{(\tau_0)}(\alpha)$ n'est autre que la DFT à un facteur près de \mathbf{f}_{τ_0} d'après (3.18), \mathbf{A} est alors construite en utilisant les lignes de \mathbf{F}^*). On note aussi que tous les atomes doivent être normalisés à 1, afin qu'ils obtiennent tous la même chance d'être sélectionnés en appliquant n'importe quel algorithme de reconstruction inverse.

On rappelle que l'élément (p, q) de la matrice de Fourier \mathbf{F} d'ordre \tilde{N} est égale à $e^{-2i\pi(p-1)(q-1)/\tilde{N}}$. La matrice \mathbf{F} est une matrice complexe symétrique ($\mathbf{F} = \mathbf{F}^T$). On note aussi que $\mathbf{F}\mathbf{F}^* = \tilde{N}\mathbf{I}_{\tilde{N}}$ avec $\mathbf{I}_{\tilde{N}}$ la matrice identité. Donc la DFT d'un signal \mathbf{y} de dimensions \tilde{N} est donnée par $\bar{\mathbf{y}} = \mathbf{F}\mathbf{y}$, est la transformé de Fourier inverse, *inverse discrete Fourier transform* (IDFT) de $\bar{\mathbf{y}}$ est donnée par $\mathbf{y} = (1/\tilde{N})\mathbf{F}^*\bar{\mathbf{y}}$.

On définit $\mathbf{b}^{(\tau_0)}$ le vecteur constitué des n premiers éléments de \mathbf{f}_{τ_0} , le problème consiste donc à résoudre le problème inverse suivant :

$$\mathbf{A}\mathbf{r}^{(\tau_0)} = \mathbf{b}^{(\tau_0)} \quad (3.20)$$

La solution $\hat{\mathbf{r}}^{(\tau_0)}$ de (3.20), qui est un vecteur de \tilde{N} éléments, représente l'estimation du VAC sur l'intervalle $[-\alpha_{max}, +\alpha_{max}]$. Pour les raisons déjà évoquées l'OMP sera utilisé afin de résoudre le problème (3.20). On note donc le VAC estimé en utilisant le *compressed sensing* par $V\hat{A}C_{CS}$, qui est donc égal à $\hat{\mathbf{v}}_l$ après que l'OMP a exécuté sa dernière itération l et est donné par l'équation suivante :

$$V\hat{A}C_{CS} = \hat{\mathbf{v}}_l \quad (3.21)$$

On note donc que l'estimateur (3.21) est un estimateur aveugle et donc les atomes du dictionnaire ne sont pas nécessairement choisis comme étant un diviseur entier de la fréquence cyclique fondamentale. Une approximation parcimonieuse est donc faite; plus δ_α est faible l'approximation obtenue est meilleure, contrairement à l'estimateur classique $V\hat{A}C_{classique}$ donné par (3.14) qui nécessite une connaissance *a priori* de la valeur de

fréquence cyclique afin d'estimer le VAC sur les valeurs exactes des fréquences cycliques sinon un vecteur composé d'un bruit d'estimation est observé et les raies représentant les fréquences cycliques ne seront pas observées.

3.5.1 Vérification du modèle

On constate que le $V\hat{A}C_{CS}$ de \tilde{N} éléments (obtenu avec l'estimateur (3.21)) peut être reconstruit à partir de seulement $n < \tilde{N}$ échantillons pour un délai τ_0 donné en appliquant la technique du compressed sensing, en effet on trace sur la figure 3.2 le VAC d'une modulation MDP2 sans filtrage à l'émission en utilisant :

- la représentation parcimonieuse en utilisant l'estimateur (3.21) avec un nombre fixe d'itérations, utilisant un dictionnaire \mathbf{A} de taille (n, \tilde{N}) avec $n = 1000$ et $\tilde{N} = 4000$,
- l'estimateur classique (3.14) avec 1000 échantillons,
- la courbe théorique qui représente la norme du VAC donnée par (3.11).

Dans notre exemple on a choisi arbitrairement et sans perte en généralité, $\tau_0 = 3 \cdot T_e$, avec T_e la période d'échantillonnage. La fréquence cyclique fondamentale de la MDP2 utilisée dans les simulation du signal transmis est égale à $\alpha_f = \frac{1}{T_s} = 10^4$ Hz, ou $T_s = 20T_e$ représente la période symbole de la modulation MDP2. On peut observer sur la figure 3.2 que quand on utilise le même nombre d'échantillons (1000) pour estimer le VAC en utilisant l'OMP, on obtient de meilleures estimations qu'avec la courbe obtenue en utilisant (3.14) comparée à la courbe théorique (3.11). En effet on peut vérifier sur la figure 3.3 (une version agrandie de la figure 3.2) le bruit d'estimation sur la courbe obtenue en utilisant (3.14), par contre on n'observe pas de bruit sur la courbe obtenue avec la *compressed sensing*. De plus une très bonne estimation sur la position des raies qui sont situées sur les multiples entiers de la fréquence cycliques fondamentale, est observée en utilisant le *compressed sensing*. Ce résultat valide donc le modèle parcimonieux du VAC pour les signaux de télécommunications.

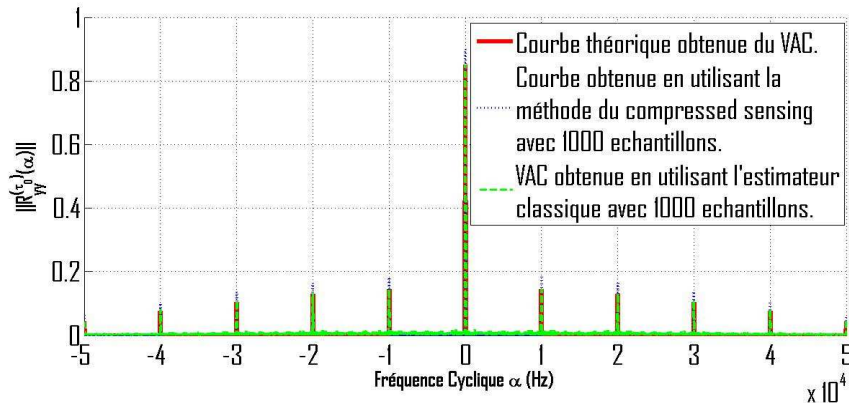


FIGURE 3.2 – La norme du VAC d'un signal modulé en utilisant une MDP2, avec une fréquence cyclique fondamentale $\alpha_f = \frac{1}{T_s} = 10^4$ Hz et $\tau_0 = 3 \cdot T_e$, obtenue en utilisant (3.14), aussi comparée à la courbe théorique (3.11) et à la norme du VAC obtenue après résolution en utilisant l'estimateur (3.21). Pour les deux estimateurs, (3.14) et (3.21), 1000 échantillons on été utilisés.




FIGURE 3.3 – Une version agrandie de la figure 3.2, afin de montrer clairement le bruit d’estimation quand l’estimateur (3.14) est utilisé.

3.6 Analyse des performances de l’estimateur proposé

Dans cette section on définit deux métriques, l’ EQM et l’ EQM_{α_f} afin de pouvoir comparer la qualité de l’estimation entre notre nouvel estimateur proposé $V\hat{A}C_{CS}$ et l’estimateur classique $V\hat{A}C_{classique}$. La première métrique (l’ EQM) compare le VAC estimé avec la référence théorique donnée par l’équation (3.11). La deuxième métrique (l’ EQM_{α_f}) compare la fréquence cyclique estimée avec la valeur de la fréquence cyclique théorique.

Plusieurs cas vont être analysés : avec et sans filtrage à l’émission, à la réception et enfin avec l’ajout d’un canal de propagation. Sauf indication contraire, une MDP2 sera utilisée dans toutes les simulations du signal $y(t)$. Ce signal $y(t)$ a une fréquence cyclique fondamentale $\alpha_f = \frac{1}{T_s} = 10$ kHz, avec $T_s = 20T_e$. Le retard τ_0 sera pris égal à $3T_e$ sans perte de généralité.

3.6.1 Erreur quadratique moyenne (premier critère)

Afin d’évaluer l’erreur de l’estimation du VAC qui est représentée par le vecteur $\hat{\mathbf{r}}_{yy}^{(\tau_0)}(\alpha)$ de \tilde{N} éléments ; un critère est de calculer l’ EQM de $\|\hat{\mathbf{r}}_{yy}^{(\tau_0)}(\alpha)\|_2$ comparer avec les \tilde{N} éléments de la fonction de référence $R_{yy}^{||\text{ref}}||(\alpha, \tau_0)$ défini dans (3.12), ces \tilde{N} éléments correspondent aux valeurs théoriques obtenues en utilisant (3.11). On peut donc écrire :

$$EQM = \frac{1}{\tilde{N}} \sum_{\alpha_i \in \mathcal{B}_\alpha} (\|\hat{\mathbf{r}}_{yy}^{(\tau_0)}(\alpha_i)\|_2 - R_{yy}^{||\text{ref}}||(\alpha_i, \tau_0))^2 \quad (3.22)$$

avec $\mathcal{B}_\alpha = \{\alpha | \alpha = k \cdot \delta_\alpha; \alpha \in [\alpha_{min}, \alpha_{max}]\}$ ce qui veut dire que l’ EQM est calculée sur une fenêtre $\mathbf{w} = [\alpha_{min}, \alpha_{max}]$. On note que dans notre étude $\alpha_{min} = -\alpha_{max}$. On note aussi que le nombre d’atomes \tilde{N} du dictionnaire \mathbf{A} est égal à 4000 dans toutes les simulations de ce chapitre sauf indication contraire.

3.6.1.1 EQM à l'émission sans filtrage

A. Evaluation de l'EQM

On montre dans la figure 3.4 l'EQM entre la courbe de référence (3.11) et entre : la norme du VAC obtenue en utilisant la méthode d'estimation classique (3.14), et celle qui est obtenue en appliquant la technique du *compressed sensing* (3.21). Pour les deux techniques d'estimation on calcule l'EQM en fonction du nombre d'échantillons et sans filtrage à l'émission. On peut donc conclure que la technique utilisant le *compressed sensing* offre de meilleures valeurs d'EQM comparée à la méthode classique.

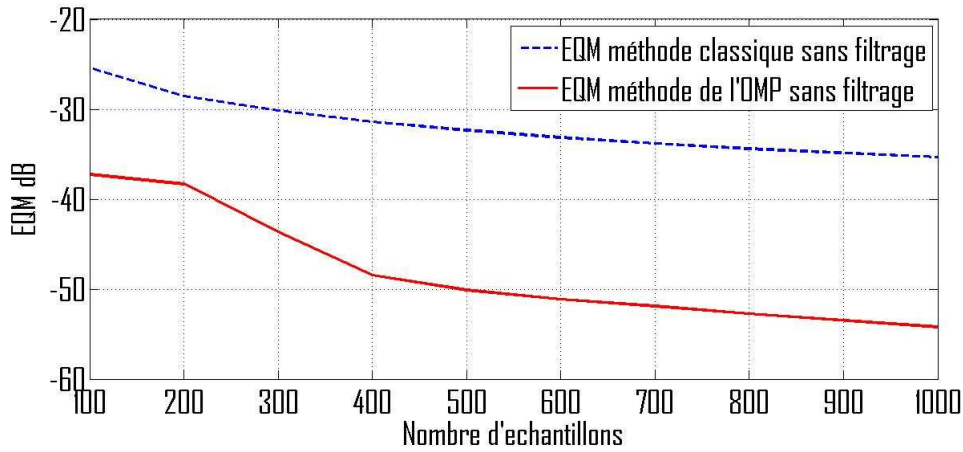


FIGURE 3.4 – Les courbes de l'EQM obtenues avec l'estimateur (3.14) et la méthode du *compressed sensing* en fonction du nombre d'échantillon.

B. Réduire le bruit d'estimation

Afin de réduire le bruit d'estimation, plusieurs essais indépendants peuvent être faits. Après chaque essai i , une estimation $\hat{\mathbf{r}}_{yy}^{(\tau_0, i)}$ du VAC est obtenue. le VAC final $\tilde{\mathbf{r}}_{yy}^{(\tau_0)}$ obtenu est la moyenne de tous ces essais indépendants :

$$\tilde{\mathbf{r}}_{yy}^{(\tau_0)} = \frac{1}{\text{essai}} \sum_{i=1}^{\text{essai}} \hat{\mathbf{r}}_{yy}^{(\tau_0, i)} \quad (3.23)$$

Sur la figure 3.5 on présente la courbe de l'EQM en fonction du nombre d'essais pour 300 échantillons utilisés (pour les deux méthodes d'estimation). Comme prévu, quand le nombre d'essais augmente l'estimateur (classique) peut atteindre la même valeur de l'EQM obtenue avec l'OMP mais au prix d'une plus grande complexité. Comme on peut l'observer, il existe un facteur d'environ 10 pour que la méthode (3.14) atteigne la même valeur d'EQM de l'OMP (10 essais pour l'OMP contre 100 pour la méthode utilisant (3.14)).

De plus on rappelle que l'estimateur qui se base sur le *compressed sensing* est aveugle, tandis que l'estimateur (3.14) ne l'est pas. À noter que le bruit d'estimation est obtenu

avec l'OMP quand un atome ne correspondant pas à un multiple entier de la fréquence cyclique fondamentale est sélectionné dans la représentation parcimonieuse.

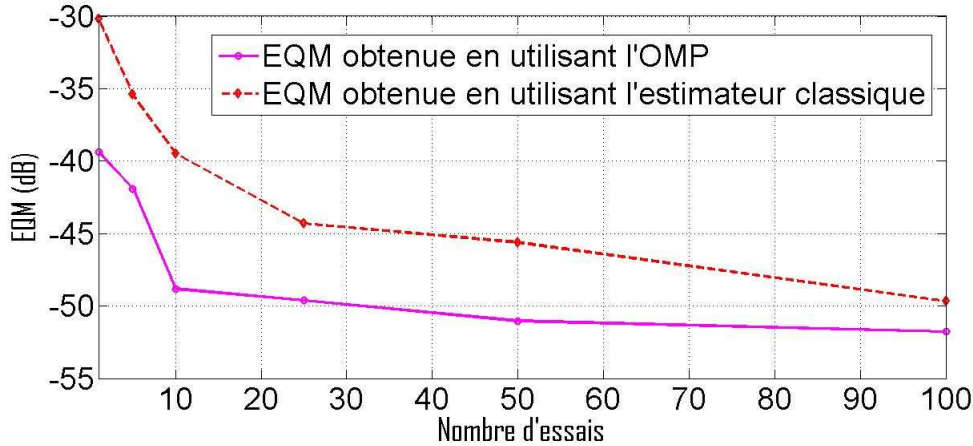



FIGURE 3.5 – l'EQM en fonction du nombre d'essais pour les deux méthodes et pour 300 échantillons.

C. Le choix de la taille du dictionnaire \tilde{N}

Quand on estime le VAC sur un intervalle $[\alpha_{min}, \alpha_{max}]_2$, le pas de résolution δ_α utilisé qui est égal à $\frac{2 \cdot \alpha_{max}}{\tilde{N}}$ devient de plus en plus petit lorsque \tilde{N} augmente, (c.-à-d. le nombre d'atomes de \mathbf{A} augmente). Dans notre problème, si α_f est connue, la meilleure façon pour faire la représentation parcimonieuse du VAC est de choisir δ_α , telle que δ_α , soit un diviseur entier de la fréquence cyclique fondamentale α_f . Par contre si α_f est inconnue (estimation aveugle du VAC) on peut toujours aboutir à une faible EQM (toujours plus petit que l'EQM obtenue avec l'estimateur classique) en choisissant une petite valeur de δ_α . La figure 3.6 montre l'EQM calculée pour quelques valeurs de δ_α pour 1000 échantillons. On peut noter que l'EQM diminue quand le pas δ_α devient de plus en plus petit (la résolution augmente). De plus on remarque que quand δ_α est égal à un diviseur entier de α_f (dans ce cas on n'est plus aveugle), c.-à-d. $\alpha_f = k \cdot \delta_\alpha$, avec $k = 200, \cong 150$, et 100, correspondant respectivement à $\delta_\alpha = 50, \cong 66, 66$, et 100 Hz, l'EQM présente un minimum local. On remarque de plus que en prenant δ_α le moins favorable c.-à-d. δ_α relativement grand et non multiple entier de α_f , la méthode utilisant le *compressed sensing* dépasse toujours la méthode classique qui est toujours non aveugle (cf. la courbe de l'EQM de la méthode classique, sur la figure 3.4 et la courbe de l'EQM sur la figure 3.6). À noter que le nombre d'atomes ne doit pas être très grand pour que le problème inverse à résoudre ne devienne pas très complexe, et pas très petit non plus afin de pouvoir toujours séparer les raies proches dans le cas où il y en a (avoir une bonne résolution).

3.6.1.2 EQM à l'émission avec filtrage

Le filtre d'émission $g(t)$ est un élément essentiel dans une chaîne de communications numériques. La fonction principale du filtre est de limiter la bande du signal émis à la taille

FIGURE 3.6 – l'EQM en fonction du pas de résolution δ_α .

du canal de transmission afin d'éviter de gêner les émetteurs voisins. Toutefois ce filtre ne doit pas introduire d'interférence entre symbole dans le signal reçue par le récepteur on dit alors qu'il satisfait le critère de Nyquist. Un filtre qui est constamment employé en communications numériques est le *cosinus surélevé*. À noter que tous les filtres vérifiant le critère de Nyquist sont appelés *filtres de Nyquist*. En pratique le filtre de réception est adapté au filtre à l'émission, la réponse fréquentielle globale des deux filtres s'écrit donc $Y(f) = |G(f)|^2$, on peut donc résoudre cette équation pour trouver $G(f)$ à l'émission et à la réception donner par $G(f) = \sqrt{Y(f)}$. puisque $Y(f)$ est de Nyquist, le filtre $G(f)$ est appelé filtre en racine de Nyquist.

Dans cette sous section on ajoute un *cosinus surélevé* en racine de Nyquist à l'émission avec un facteur de retombée (*roll off factor*) $\beta = 0,5$. Sur la figure 3.7, qui est obtenue avec l'estimateur classique (3.14), on peut voir l'effet de l'ajout d'un filtre à l'émission. La première chose qui peut être observée est que le filtre élimine les harmoniques de la fréquence cyclique fondamentale et seulement la fréquence cyclique fondamentale sur les positions ($\pm\alpha_f$) peut être observée. Pour cette raison quand on calcule l'EQM en présence d'un filtre à l'émission l'EQM doit être calculée sur une fenêtre réduite $\mathbf{w}' = [-\alpha_f, \alpha_f]$. Le second effet de l'ajout d'un filtre qui peut aussi être observé dans la figure 3.7 obtenue en utilisant l'estimateur classique, est l'augmentation du bruit d'estimation qui génère une augmentation de l'EQM comparée au cas non filtré. Cette augmentation du bruit d'estimation est due au filtre en racine de Nyquist.

Sur la figure 3.8 on trace le VAC estimé en utilisant l'estimateur (3.21) pour 2500 échantillons avec et sans filtrage. On observe sur la figure 3.8 un biais sur la norme du VAC aux fréquences cycliques zéro et $\pm\alpha_f$ avec l'utilisation d'un filtre à l'émission. Un autre point important peut être observé sur la figure 3.8 est l'absence du bruit d'estimation dans le VAC, vu que le VAC estimé est constitué avec un nombre fini d'atomes quand l'OMP est utilisé (ce nombre est égal au nombre d'itérations de l'OMP). On note aussi qu'un biais peut être observé sur la position des raies dans le VAC estimé pour un nombre

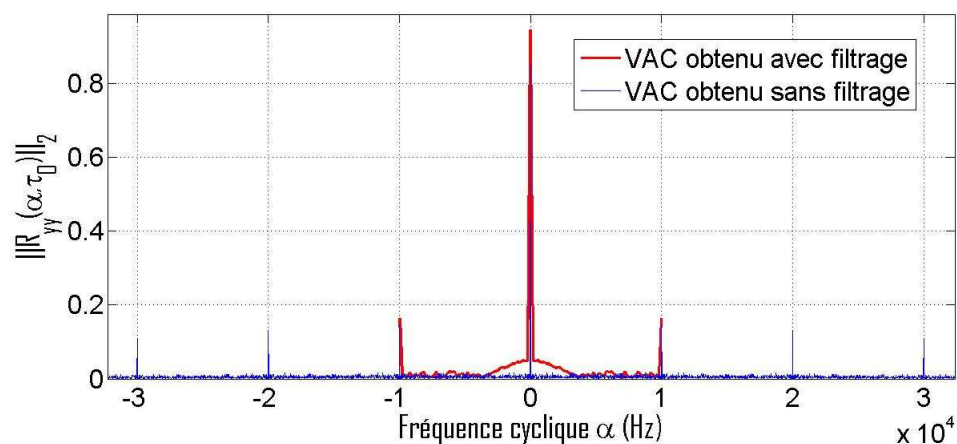


FIGURE 3.7 – Le VAC obtenue avec (3.14) avec et sans filtrage. Il est notable que le filtrage augmente le bruit d'estimation et enlève les harmoniques de la fréquence cyclique fondamentale.

plus faible d'échantillons quand un filtre est ajouté comme le montre la figure 3.9 obtenue en utilisant seulement 300 échantillons (au lieu de 2500) avec filtrage à l'émission.

La figure 3.10 montre l'EQM entre la courbe théorique et la courbe obtenue avec la formule (3.14) d'une part et l'EQM entre la courbe théorique et la courbe obtenue avec la technique du *compressed sensing* d'autre part et ceci pour plusieurs nombres d'échantillons. On peut conclure que en utilisant la technique du *compressed sensing* on obtient toujours une meilleure EQM que celle obtenue avec la méthode classique.




FIGURE 3.8 – La norme du VAC (obtenue avec 2500 échantillons) obtenue en utilisant (3.21) avec et sans filtrage à l'émission.

Sur la figure 3.11 sont tracées les même courbes d'EQM dans les mêmes conditions, avec et sans filtrage à l'émission pour la méthode utilisant l'OMP. Les même courbes sont tracées sur la figure 3.12 mais pour la méthode classique utilisant (3.14). Les deux figures




FIGURE 3.9 – La norme du VAC (centrée autour de $\alpha = \frac{1}{T_s}$) obtenue en utilisant (3.21) avec filtrage à l'émission et en utilisant 300 échantillons.

montrent clairement l'augmentation de l'EQM quand on ajoute une racine de Nyquist à l'émission pour les deux méthodes d'estimation.

3.6.1.3 EQM à la réception

Afin d'observer l'évolution de l'EQM à la réception (avec filtrage à l'émission) en fonction du RSB on a tracé à la figure 3.13 la courbe représentant l'EQM en fonction du RSB pour un nombre fixe d'échantillons égal à 300 en moyennant la valeur de l'EQM sur 1000 essais indépendants et ceci pour les deux méthodes d'estimations. Comme attendu plus le RSB est petit, plus l'EQM augmente quel que soit la méthode d'estimation utilisée. On introduit la valeur ΔEQM définie comme étant la différence entre l'EQM de la méthode classique et l'EQM de la méthode de l'OMP. On constate que sur toutes les valeurs du RSB, ΔMSE est toujours supérieure à 10 dB mettant en évidence l'avantage de l'utilisation de la méthode de représentation parcimonieuse afin d'estimer le VAC en présence du bruit et d'un filtre à l'émission.

3.6.1.4 L'EQM à la réception avec canal de propagation

Dans cette partie le signal après filtrage à l'émission transite à travers un canal de propagation est ensuite entaché d'un bruit additif. Le schéma de la transmission peut s'exprimer par la relation d'entrée sortie du canal qui s'écrit, en notant $C(\cdot)$ la fonction correspondante au canal et \mathbf{b} un bruit blanc Gaussien :

$$\mathbf{y} = C(\mathbf{x}) + \mathbf{b} \quad (3.24)$$

La transformation C , dans notre étude sera prise comme un filtrage linéaire à réponse impulsionnelle fini et invariant dans le temps. Le canal utilisé dans les simulations de ce chapitre, est décrit en détail dans l'annexe C.




FIGURE 3.10 – Les courbes de l’EQM obtenues avec l’estimateur (3.14) et la méthode du *compressed sensing* en utilisant un filtre en racine de Nyquist à l’émission pour les deux méthodes.

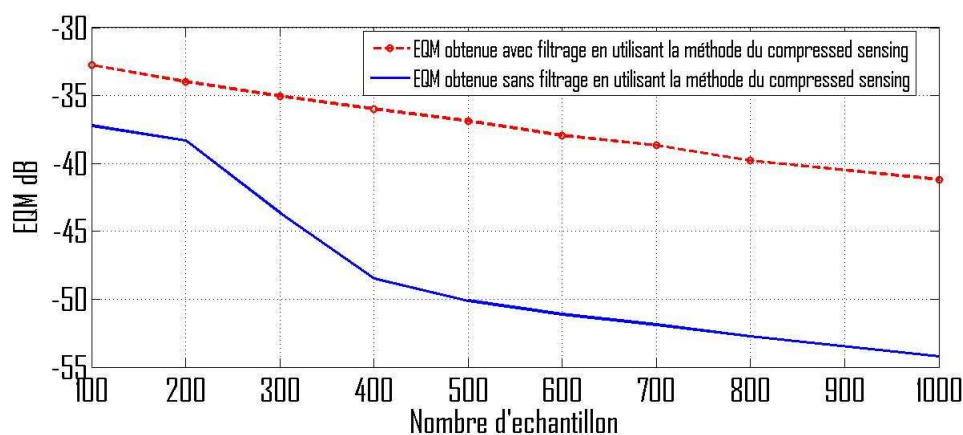


FIGURE 3.11 – Les courbes de l’EQM obtenues en utilisant la méthode du *compressed sensing* avec et sans filtrage à l’émission.

A. Résultats de simulation de l’EQM à la réception avec canal de propagation

Dans cette partie on calcule l’EQM à la réception pour 300 échantillons en utilisant le canal défini dans l’annexe C dans les simulations. Un filtre en racine de Nyquist est utilisé à l’émission avec un facteur de retombée $\beta = 0.5$. Le résultat est montré sur la figure 3.14 pour les deux estimateurs (3.14) et (3.21). Une petite augmentation de l’EQM est observée par rapport à la figure 3.13 où un canal de propagation n’est pas utilisé. Ce résultat est attendu car le canal de propagation est équivalent à un filtrage linéaire, et donc le même effet est observé que celui du cas filtré étudié dans la section 3.6.1.2. De plus on note que notre nouvel estimateur proposé qui se base sur le *compressed sensing* est toujours mieux que l’estimateur classique même dans le cas le plus réaliste.

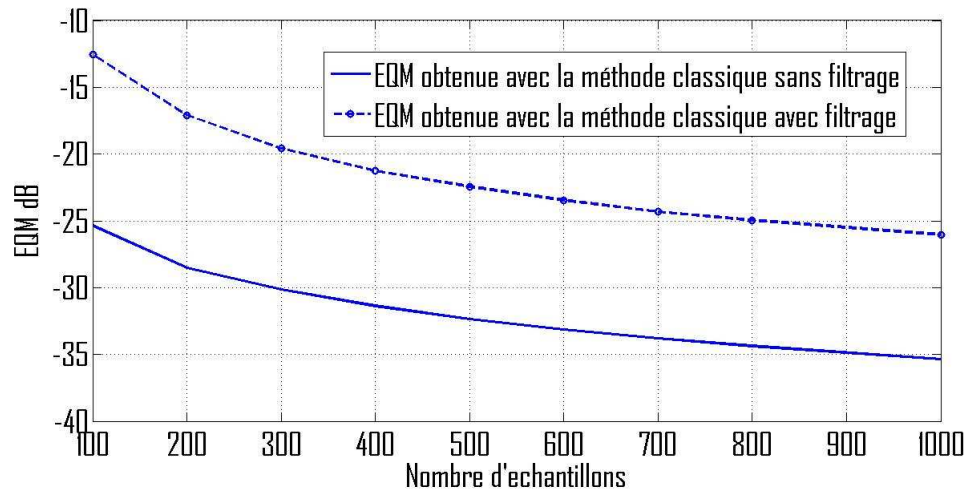


FIGURE 3.12 – Les courbes de l'EQM obtenues en utilisant l'estimateur (3.14), avec et sans filtrage à l'émission.




FIGURE 3.13 – l'EQM à la réception en fonction du RSB pour les deux méthodes en utilisant 300 échantillons.

3.6.2 Analyse de l'erreur sur l'estimation de la position de la fréquence cyclique : l' EQM_{α_f}

L'EQM déjà définie dans la partie précédente peut induire en erreur sur l'évaluation de l'estimation du VAC, en effet après l'obtention du VAC en utilisant l'OMP, ce vecteur obtenu après avoir effectuer un nombre limité d'itérations contient par défaut beaucoup d'éléments nuls, donc ce dernier est très corrélé avec l'équation théorique du VAC qui contient beaucoup d'éléments nuls aussi. Ce grand nombre d'éléments nuls induit donc une EQM faible et ceci indépendamment de la position des raies vu que leur nombre est relativement faible. Afin de résoudre ce problème et pour mieux comparer les différents




FIGURE 3.14 – Les courbes de l' EQM à la réception avec un canal de propagation pour les deux estimateurs (3.14) et (3.21)

estimateurs du VAC d'une manière plus précise, l'erreur d'estimation sur la position de la fréquence cyclique (ou la valeur estimée) doit aussi être évaluée avec et sans filtrage, à l'émission ainsi qu'à la réception et enfin avec l'ajout d'un canal de propagation.

3.6.2.1 Paramètre d'évaluation

Afin d'évaluer l'estimation de la valeur de la fréquence cyclique plusieurs paramètres peuvent être évalués : la moyenne du biais sur les valeurs estimées obtenues après un grand nombre d'essais, l'écart type des ces valeurs estimées et finalement l'erreur quadratique moyenne noté EQM_{α_f} entre la valeur estimée et la valeur théorique de la fréquence cyclique. EQM_{α_f} normalisée est définie comme suit :

$$EQM_{\alpha_f} = \sum_{i=1}^{N_{essais}} \frac{(\hat{\alpha}_i - \alpha_f)^2}{T_s^2 \cdot N_{essais}} \quad (3.25)$$

Un estimateur parfait à une moyenne de biais parfaitement égal à zéro, ainsi qu'un écart type et une EQM_{α_f} nulle. On note qu'un écart type σ_α nul, définit par :

$$\sigma_\alpha = \sqrt{\frac{1}{N_{essais}} \sum_{i=1}^{N_{essais}} (\hat{\alpha}_i - \alpha_{moy})^2} \quad (3.26)$$

avec

$$\alpha_{moy} = \frac{1}{N_{essais}} \sum_{i=1}^{N_{essais}} \hat{\alpha}_i \quad (3.27)$$

veut dire que toutes les estimations sont identiques, mais ce n'est pas suffisant pour en conclure que l'estimation est parfaite pour cela les métriques comme l' EQM_{α_f} ou bien

aussi la moyenne du biais, \tilde{b}_i qui est défini par :

$$\tilde{b}_i = \sqrt{\frac{1}{N_{essais}} \sum_{i=1}^{N_{essais}} (\hat{\alpha}_i - \alpha_f)^2} \quad (3.28)$$

sont nécessaires afin de conclure que l'estimation est parfaite, ou de bonne qualité car ils nous permettent de comparer les estimations avec la référence théorique α_f .

Il faut noter que le biais de l'estimateur (3.21) dépend directement du pas de résolution δ_α , en effet dans le cas le plus favorable (nombre d'échantillons suffisant et sans bruit à la réception) le biais est toujours inférieure à δ_α car les atomes prennent des valeurs discrètes et donc l'estimation est discrète. Donc plus δ_α est petit plus le biais est petit. Dans le cas particulier où δ_α est égal à un diviseur entier de la fréquence cyclique fondamentale on peut atteindre (dans certaines conditions sur le nombre d'échantillons et sur le *RSB*) un biais parfaitement égal à zéro. Dans nos exemples de simulations, afin de faire une comparaison correcte entre les deux méthodes (3.14) et (3.21), le pas δ_α utilisé doit être un diviseur entier de la fréquence cyclique car on se compare à l'estimateur non aveugle (3.14) et donc les atomes choisis doivent correspondre exactement aux valeurs de l'intervalle $I'_{ALPHA} = [\frac{\alpha_f}{2}, \frac{3\alpha_f}{2}]$ qui est centré exactement sur la valeur de la fréquence cyclique. Pour cela on peut atteindre dans certaines conditions des estimations idéales avec un biais parfaitement égale à zéro.

3.6.2.2 Comparaison des différents estimateurs avec l' EQM_{α_f}

Afin de comparer les performances des deux estimateurs (3.14) et (3.21) en utilisant le critère de l' EQM_{α_f} , on réalise plusieurs comparaisons :

- calcul de l' EQM_{α_f} à l'émission ainsi qu'à la réception, en utilisant (3.14) et (3.21), sans filtrage à l'émission.
- calcul de l' EQM_{α_f} à l'émission ainsi qu'à la réception, en utilisant (3.14) et (3.21), avec filtrage à l'émission.
- calcul de l' EQM_{α_f} à la réception, en utilisant (3.14) et (3.21), avec filtrage à l'émission et un canal de propagation (cas le plus réaliste).

Avant de faire ces comparaisons on explique en détails dans 3.6.2.2.A et 3.6.2.2.B comment l'estimation de la fréquence cyclique $\hat{\alpha}$ est faite avec chacune des deux méthodes d'estimation (3.21) et (3.14) respectivement.

A. L'estimation de la fréquence cyclique en utilisant le compressed sensing

Dans cette sous section est décrit comment l'estimation de la fréquence cyclique est faite en utilisant la technique du *compressed sensing* avec (3.21). La fréquence cyclique choisie pour faire cette comparaison est la fréquence cyclique fondamentale $\alpha_f = \frac{1}{T_s} = 10$ kHz, le pas δ_α du dictionnaire A est égal à 50 Hz, le nombre d'atomes du dictionnaire est égal à 4000 qui représentent l'intervalle I_{ALPHA} allant de $\alpha_{min} = -100$ kHz jusqu'à $\alpha_{max} = 100$ kHz. Après la résolution du problème inverse en utilisant un nombre fixe d'itérations de l'OMP, on considère que la valeur $\hat{\alpha}$, qui représente l'estimation de α_f , est la valeur correspondante à l'abscisse de l'atome du $V\hat{A}C_{CS}$ ayant la plus grande norme et situé à l'intérieur de l'intervalle $I'_{ALPHA} = [\frac{\alpha_f}{2}, \frac{3\alpha_f}{2}] = [5000, 15000]$, qui est centrée sur α_f et de largeur α_f . On note que les bornes de l'intervalle I'_{ALPHA} sont $\frac{\alpha_f}{2}$ et $\frac{3\alpha_f}{2}$.

car toutes valeurs à l'extérieur de cet intervalle sera plus proche d'une fréquence cyclique autre que α_f comme par exemple $\alpha = 0, \alpha = 2\alpha_f, \alpha = 3\alpha_f \dots$. Donc il ne convient pas de considérer qu'une valeur à l'extérieur de l'intervalle I'_{ALPHA} représente une estimation de α_f .

À noter que comme la valeur de $\hat{\alpha}$ est situé à l'intérieur de I'_{ALPHA} qui est centrée sur α_f , $\left(\frac{\alpha_f + 3\alpha_f}{2} = \alpha_f\right)$, la moyenne n'est pas prise en compte comme indicateur de la qualité de l'estimation de α_f , car dans ce cas, même si l'estimateur utilisé est très mauvais (donne des valeurs uniformément répartis à l'intérieur de I'_{ALPHA}) la moyenne des estimations obtenues serait au centre de l'intervalle I'_{ALPHA} donc proche de la bonne valeur de la fréquence cyclique α_f . Donc en utilisant la moyenne comme critère d'évaluation de l'estimation seulement, il est impossible de conclure si l'estimateur est de bonne ou de mauvaise qualité.

B. L'estimation en utilisant l'estimateur classique

Pour pouvoir comparer la méthode d'estimation classique (3.14) avec celle qui utilise le *compressed sensing* on applique l'estimateur (3.14) sur le même intervalle discret I'_{ALPHA} utilisé avec (3.21) et ceci pour que les deux méthodes d'estimation aient la même résolution et donc pour faire une comparaison équitable, ensuite l'abscisse de la norme du $V\hat{A}C_{classique}$ estimée ayant une valeur maximale, est considérée comme étant la valeur d'estimation de la fréquence cyclique. En effet, la norme du VAC théorique est maximale sur la position de la fréquence cyclique (est nulle ailleurs). La figure 3.15 illustre comment la fréquence cyclique estimée $\hat{\alpha}_f$ avec (3.14) est choisie à l'intérieur de l'intervalle I'_{ALPHA} . En effet $\hat{\alpha}_f$ correspond à l'abscisse du maximum du VAC estimé. Ces estimations sont répétées sur un grand nombre d'essais afin de pouvoir calculer l' EQM_{α_f} , en utilisant (3.25).




FIGURE 3.15 – Illustration de l'estimation de la fréquence cyclique $\hat{\alpha}_f$, qui est obtenue en prenant l'abscisse de la valeur maximale du VAC en appliquant l'estimateur classique (3.14) sur I'_{ALPHA} . On note que dans cette illustration l'estimation n'est pas idéale car la valeur obtenue avec l'estimation n'est pas la même que la valeur théorique.

3.6.2.3 Sans filtrage à l'émission

A. EQM_{α_f} à l'émission

Afin d'estimer la métrique EQM_{α_f} , 1000 essais indépendants sont réalisés dans le cas de chaque estimateur à l'émission, sans filtrage à l'émission. Sur la figure 3.16 on montre l' EQM_{α_f} en fonction du nombre d'échantillons utilisés à l'émission pour chacun des estimateurs sans filtrage. On note qu'à partir de 350 échantillons l' EQM_{α_f} de l'estimateur utilisant le *compressed sensing* devient parfaitement nul ($-\infty$ en dB) donc l'estimateur devient idéal pour 350 échantillons seulement. En revanche 1100 échantillons sont nécessaires pour que la méthode classique devienne idéale, donc la méthode classique a besoin de 3 fois plus d'échantillons que le nouvel estimateur proposé pour faire une estimation idéale sur la position de la fréquence cyclique. Pour des raisons de présentation on limite la présentation des courbes représentant l' EQM_{α_f} à 300 échantillons sur la figure 3.16 car à partir de 300 échantillons l' EQM_{α_f} de l'estimateur utilisant le *compressed sensing* commence à tendre vers $-\infty$.




FIGURE 3.16 – Les courbes de l' EQM_{α_f} obtenues avec l'estimateur (3.14) et la méthode du *compressed sensing* en fonction du nombre d'échantillons.

B. EQM_{α_f} à la réception

Afin de simuler les résultats à la réception on fixe le nombre total d'échantillons à 150 pour chaque estimateur. 1000 essais indépendants sont réalisés dans le cas de chaque estimateur pour chaque valeur du rapport signal sur bruit RSB . On obtient les courbes représentant l' EQM_{α_f} en fonction du RSB à la figure 3.17. On conclut donc que même avec un bruit additif gaussien l' EQM_{α_f} de la méthode utilisant le *compressed sensing* est toujours inférieure à celle de l'estimateur (3.14) donc l'estimation sur la position est toujours meilleure même dans le cas bruité.




FIGURE 3.17 – Les courbes de l' EQM_{α_f} obtenues avec l'estimateur (3.14) et la méthode du *compressed sensing* pour 150 échantillons en fonction de la *RSB*.

3.6.2.4 Avec filtrage à l'émission

A. EQM_{α_f} à l'émission

Pour pouvoir observer l'effet de la dégradation du caractère cyclostationnaire causé par l'introduction d'un filtre à l'émission sur l'estimation de la fréquence cyclique, on a recalculé l' EQM_{α_f} en simulant 1000 nouveaux essais pour chacun des estimateurs pour différent nombre d'échantillons. Le résultat est affiché dans la figure 3.18. On note que pour atteindre une estimation idéale sur la position de la fréquence cyclique on a besoin de 3000 échantillons pour la méthode classique contre 2500 pour la méthode utilisant l'OMP (pour des raisons de présentation on se limite à 2000 échantillons sur la figure 3.18 car au-delà, l' EQM_{α_f} tend vers $-\infty$). Le rapport en gain diminue entre les deux estimateurs après l'ajout d'un filtre à l'émission, toutefois la méthode utilisant le *compressed sensing* reste toujours meilleure que l'estimateur classique.

B. EQM_{α_f} à la réception

La même simulation est répétée comme dans la sous section précédente avec un l'ajout d'un bruit additif gaussien, on fixe le nombre total d'échantillons à 1000 pour chaque estimateur, on obtient les courbe représentant l' EQM_{α_f} en fonction de la *RSB* à la figure 3.19. On conclut donc que même avec un bruit additif gaussien et un filtrage à l'émission l' EQM_{α_f} de la méthode utilisant le *compressed sensing* reste toujours inférieure à celle de l'estimateur (3.14) donc l'estimation sur la position est toujours meilleure même dans le cas bruité avec filtrage à l'émission.

C. EQM_{α_f} à la réception avec l'ajout d'un canal de propagation

Dans cette partie le signal après filtrage à l'émission transite à travers un canal de propagation est ensuite entaché d'un bruit additif. Le schéma de la transmission peut s'exprimer par la relation d'entrée sortie du canal qui s'écrit, en notant $C(\cdot)$ la fonction




FIGURE 3.18 – Les courbes de l' EQM_{α_f} en fonction du nombre d'échantillon obtenues avec l'estimateur (3.14) et la méthode du *compressed sensing*, en utilisant un filtrage à l'émission.




FIGURE 3.19 – Les courbes de l' EQM_{α_f} obtenues avec l'estimateur (3.14) et la méthode du *compressed sensing* pour 1000 échantillons en fonction du RSB en utilisant un filtrage à l'émission.

correspondante au canal et \mathbf{b} un bruit blanc Gaussien :

$$\mathbf{y} = C(\mathbf{x}) + \mathbf{b} \quad (3.29)$$

La transformation C , dans notre étude sera prise comme un filtrage linéaire à réponse impulsionnelle fini et invariant dans le temps décrit en annexe C. On calcul l' EQM_{α_f} en utilisant un filtre en racine de Nyquist à l'émission avec $\beta = 0,5$ convolué avec le canal défini dans l'annexe C, pour plusieurs RSB , en fixant le nombre d'échantillons à 1000, et ceci pour les deux méthodes d'estimation. Sur la figure 3.20 on observe le résultat des simulations. Une augmentation de l' EQM_{α_f} après l'introduction du canal de propagation comparé aux résultats sans canal de propagation est observé, ce qui est attendu vu que le canal de propagation est un filtre linéaire, le même effet comme dans le cas filtré vu précédemment (section 3.6.2.4.A) est observé. De plus on remarque que

la méthode utilisant le *compressed sensing* reste meilleure que l'estimateur classique ce qui nous laisse conclure que dans le cas le plus réaliste la nouvelle méthode proposée est toujours plus avantageuse que la méthode classique sans oublier que la méthode classique doit être répétée sur plusieurs « candidats » de α_f contre la nouvelle méthode totalement aveugle, qui n'est réalisé qu'une seule fois.




FIGURE 3.20 – Les courbes de l' EQM_{α_f} obtenues avec l'estimateur (3.14) et la méthode du *compressed sensing* pour 1000 échantillons en fonction du RSB en utilisant un filtrage à l'émission et après convolution avec le canal $c(\tau)$.

3.7 Conclusion

Dans ce chapitre, nous avons appliqué la technique du *compressed sensing* pour développer un nouvel estimateur aveugle du VAC parcimonieux dans le domaine des fréquences cycliques. Nous avons également introduit deux métriques $l'EQM$ et $l'EQM_{\alpha_f}$ afin de pouvoir évaluer la qualité de l'estimation du VAC d'une part et de comparer le nouvel estimateur par rapport à l'estimateur classique d'autre part. Dans tous les scénarios possibles : à l'émission (avec et sans filtrage), à la réception, et même en utilisant un canal de propagation avec évanouissement, le nouvel estimateur aveugle donne de meilleurs résultats par rapport à l'estimateur classique et ceci en se basant sur les deux métriques : EQM et EQM_{α_f} . De plus, le nouvel estimateur est aveugle par rapport à l'estimateur classique qui nécessite la valeur de la fréquence cyclique afin d'estimer l'AC. Ce nouvel estimateur présente ainsi de nombreux avantages et peut être utilisé dans de nombreuses applications. Dans le chapitre suivant on utilise ce nouvel estimateur pour développer des nouveaux algorithmes de détection des bandes libres avec un temps d'observation plus court et donc une détection plus rapide.

Chapitre 4

Détection aveugle en utilisant la parcimonie

4.1 Introduction

Dans le chapitre précédent on a introduit un nouvel estimateur de l'autocorrélation cyclique pour un délai donné qui se base sur le *compressed sensing*. On a pu vérifier par simulation que les deux critères déjà définis (EQM et EQM_{α_f}) pour l'évaluation de la qualité de l'estimation du VAC, sont toujours meilleurs pour notre nouvel estimateur par rapport à l'estimateur classique utilisé dans [2], même dans le cas le plus réaliste en utilisant un filtre à l'émission et un canal de propagation. Dans ce chapitre nous allons utiliser l'estimateur que nous avons proposé dans le chapitre précédent. Nous proposons deux détecteurs aveugles utilisant moins d'échantillons que nécessite le détecteur temporel de second ordre de [2] qui se base sur l'estimateur classique de la FAC. Ces deux détecteurs outre qu'ils sont aveugles sont plus performants que le détecteur non aveugle de [2].

4.2 Méthodes de détections

Principalement deux méthodes de détections qui se basent sur le nouvel estimateur vont être proposées, la première se base sur la comparaison des fréquences cycliques obtenues dans deux slots consécutifs, et donc dans ce cas on suppose que les deux slots consécutifs appartiennent tous les deux soit à H_0 soit à H_1 . Cette dernière supposition est réaliste puisque la taille des slots utilisés est très faible. La deuxième méthode de détection, en plus de la propriété de parcimonie de la FAC, va utiliser la propriété de symétrie du cyclopectre. Cette symétrie, exploitée en plus de la parcimonie, va améliorer les performances de détection par rapport à la première méthode qui n'exploite que la propriété de parcimonie.

4.2.1 Méthodes de comparaisons des slots

Afin de choisir entre H_0 et H_1 , la méthode de comparaison des slots (MCS) prend deux slots consécutifs de taille n_s pour chaque slot. On note que cette méthode peut être appliquée en utilisant plusieurs slots, mais pour des raisons de complexité on se limite à 2 slots seulement. Les deux slots sont notés \mathbf{s}_1 et \mathbf{s}_2 avec $\mathbf{s}_1 = [y(0), y(1), \dots, y(n_s - 1)]^T = [y_1(0), y_1(1), \dots, y_1(n_s - 1)]^T$ et $\mathbf{s}_2 = [y(n_s), y(n_s + 1), \dots, y(2n_s - 1)]^T = [y_2(0), y_2(1), \dots, y_2(n_s - 1)]^T$. On suppose que deux slots consécutifs appartiennent à une même hypothèse (les deux sont ou bien à H_0 ou bien à H_1). On note que cette supposition est réaliste car n_s est très petit. L'idée de ce test est d'estimer les VACs $\hat{\mathbf{r}}_{y_1 y_1}^{(\tau_0)}(\alpha)$ et $\hat{\mathbf{r}}_{y_2 y_2}^{(\tau_0)}(\alpha)$ de dimensions $(\tilde{N}, 1)$ en exploitant leur propriété parcimonieuse (en utilisant seulement n_s échantillons pour faire chacune des estimations) ensuite on compare les fréquences cycliques obtenues pour chaque slot (ou d'une manière équivalente, les indices des éléments ayant une norme maximale dans le VAC. On note par indice la position de l'élément dans le VAC qui est un entier entre 1 et la taille maximale du VAC estimé avec le nouvel estimateur). On note que l'indice représentant la fréquence cyclique $\alpha = 0$ n'est pas pris en compte car sous H_0 ou bien sous H_1 , une valeur non nulle va être obtenue pour $\alpha = 0$ car elle représente la valeur de l'autocorrélation classique du signal reçu pour $\tau = \tau_0$ (cf. l'équation (1.32)). Ensuite si les indices des fréquences cycliques obtenues pour $\hat{\mathbf{r}}_{y_1 y_1}^{(\tau_0)}(\alpha)$ et $\hat{\mathbf{r}}_{y_2 y_2}^{(\tau_0)}(\alpha)$ sont identiques ou proches, H_1 est retenue sinon, H_0 sera choisie car le bruit n'a pas de fréquence cyclique.

Pour estimer $\hat{\mathbf{r}}_{y_1 y_1}^{(\tau_0)}(\alpha)$, (resp. $\hat{\mathbf{r}}_{y_2 y_2}^{(\tau_0)}(\alpha)$) il faut résoudre le système $\mathbf{A}\mathbf{r}_1^{(\tau_0)} = \mathbf{b}_1^{(\tau_0)}$ (resp. $\mathbf{A}\mathbf{r}_2^{(\tau_0)} = \mathbf{b}_2^{(\tau_0)}$) donné par (3.20) en utilisant l'OMP. On rappelle que $\mathbf{b}_1^{(\tau_0)}$ (resp. $\mathbf{b}_2^{(\tau_0)}$) est construit avec les n_s premiers éléments du vecteur $\mathbf{f}_{\tau_0}^{(1)}$, (resp. $\mathbf{f}_{\tau_0}^{(2)}$) comme défini dans (3.17) avec les échantillons du slot \mathbf{s}_1 (resp. \mathbf{s}_2). Ensuite après l'obtention de $\mathbf{b}_1^{(\tau_0)}$ et de $\mathbf{b}_2^{(\tau_0)}$ en utilisant les $2n_s$ échantillons des slots \mathbf{s}_1 et \mathbf{s}_2 , on résout les deux problèmes inverses $\mathbf{A}\mathbf{r}_1^{(\tau_0)} = \mathbf{b}_1^{(\tau_0)}$ et $\mathbf{A}\mathbf{r}_2^{(\tau_0)} = \mathbf{b}_2^{(\tau_0)}$ en utilisant l'OMP.

Les vecteurs obtenus $\hat{\mathbf{r}}_1^{(\tau_0)}$ et $\hat{\mathbf{r}}_2^{(\tau_0)}$ qui représentent respectivement $\hat{\mathbf{r}}_{y_1 y_1}^{(\tau_0)}(\alpha)$ et $\hat{\mathbf{r}}_{y_2 y_2}^{(\tau_0)}(\alpha)$ sont comparés ensembles. Plus précisément, ceux qui doivent être comparés sont les positions (ou indices) des éléments des vecteurs $\hat{\mathbf{r}}_1^{(\tau_0)}$ et $\hat{\mathbf{r}}_2^{(\tau_0)}$ correspondants à la fréquence cyclique estimée (l'indice de la fréquence cyclique estimée correspond à l'indice de l'élément du vecteur estimé $\hat{\mathbf{r}}^{(\tau)}$ ayant la plus grande norme. On note $indice_1$ et $indice_2$ les indices correspondants aux fréquences cycliques de $\hat{\mathbf{r}}_1^{(\tau_0)}$ et $\hat{\mathbf{r}}_2^{(\tau_0)}$ respectivement). On rappelle qu'on ne prend pas en compte les indices correspondants à la fréquence cyclique $\alpha = 0$, car quel que soit l'hypothèse (H_0 ou H_1) la fréquence cyclique zéro, représente l'autocorrélation classique du signal reçu et prend donc une valeur non nulle, ce qui rend impossible de faire le test à la fréquence cyclique zéro. Ensuite si $|indice_1 - indice_2| < k$ on considère que \mathbf{s}_1 et \mathbf{s}_2 ont la même fréquence cyclique et par suite la variable booléenne Δ est fixée à 1. Par contre si $|indice_1 - indice_2| \geq k$, Δ sera fixée à zéro. On note que par le choix de la variable k , qui peut prendre une valeur entre 1 et \tilde{N} (la taille du vecteur $\hat{\mathbf{r}}^{(\tau_0)}$), on peut fixer les performances du détecteur en fonction de la fausse alarme. On note que $\hat{\mathbf{r}}_{y_1 y_1}^{(\tau_0)}(\alpha)$ et $\hat{\mathbf{r}}_{y_2 y_2}^{(\tau_0)}(\alpha)$ doivent être estimés pour plusieurs valeurs de τ_i , $i \in \{1, 2, \dots, M\}$ pour augmenter les chances de détecter, car ce n'est pas nécessaire que $R(\alpha, \tau)$ prend une valeur non nulle pour toute valeur de τ , même si α est une fréquence cyclique du signal reçu. En effet si on regarde l'expression de la norme de la FAC donnée par (3.11), on peut conclure que celle-ci est égale à zéro, quel que soit la valeur de α non nulle, pour les

valeurs de τ suivantes :

$$\tau = T_s + \frac{k\pi}{\alpha}, \quad k \in \mathbb{Z} \quad (4.1)$$

En répétant le même test pour plusieurs τ_i (en comparant donc tous les $\hat{\mathbf{r}}_1^{(\tau_i)}$ et $\hat{\mathbf{r}}_2^{(\tau_i)}$ ensembles deux à deux) on obtient M valeurs booléennes $(\Delta_1, \dots, \Delta_M)$, et la décision finale sera prise en utilisant la règle de décision ou :

$$\Gamma = \sum_{i=1}^M \Delta_i \underset{H_1}{\overset{H_0}{\leq}} 1 \quad (4.2)$$

on note aussi que dès qu'une variable booléenne prend la valeur 1 l'algorithme s'arrête et prend une décision, minimisant ainsi la complexité de calcul. Voici les lignes de l'algorithme :

```

s1 ← [y1(0), ..., y1(ns - 1)]T
s2 ← [y2(0), ..., y2(ns - 1)]T
for  $i = 1$  à  $M$  do
  b1( $\tau_i$ ) ← calcul des  $n_s$  éléments de f $\tau_i$ (1)
  b2( $\tau_i$ ) ← calcul des  $n_s$  éléments de f $\tau_i$ (2)
  r1( $\tau_i$ ) ← OMP(A, b1( $\tau_i$ ))
  r2( $\tau_i$ ) ← OMP(A, b2( $\tau_i$ ))
  indice1 ← indice(max(|r1( $\tau_i$ )|))
  indice2 ← indice(max(|r2( $\tau_i$ )|))
  note : indice1 et indice2 sont choisis sans tenir compte des indices de la fréquence cyclique zéro.
  if |indice1 - indice2| <  $k$  then
     $\Delta_i = 1$ 
  else
     $\Delta_i = 0$ 
  end if
   $\Gamma \leftarrow \sum_{l=1}^i \Delta_l$ 
  if  $\Gamma \geq 1$  then
     $H_1$  est choisis
  end if
end for
 $H_0$  est choisis

```

La figure 4.1, montre l'organigramme de la méthode de comparaison des slots MCS.

4.2.1.1 Performance de détection de la MCS

Pour évaluer les performances de la MCS proposée on utilise dans cette partie, une modulation BPSK (mêmes paramètres de simulations de la BPSK utilisée dans le chapitre 3, sauf indication(s) contraire(s), et ceci le long de ce chapitre). On utilise un dictionnaire **A** de taille (200,512) (sauf indication contraire). D'après la taille du dictionnaire on a $n_s = 200$ (donc un total de $2n_s = 400$ échantillons sont utilisés) pour faire la décision entre H_0 et H_1 . Deux ensembles de τ sont utilisés ($M = 2$, et $M = 5$), les ensembles sont respectivement ($\tau_1 = T_e$ et $\tau_2 = 2 \cdot T_e$) et ($\tau_1 = T_e$, $\tau_2 = 2 \cdot T_e$, $\tau_3 = 3 \cdot T_e$, $\tau_4 = 4 \cdot T_e$ et




FIGURE 4.1 – L'organigramme de la Méthode de Comparaison des Slots : MCS.

$\tau_5 = 5 \cdot T_e$). Les courbes de ROC de notre détecteur proposé pour les différentes valeurs de M sont montrées sur la figure 4.2, ces courbes ont été obtenues en modifiant la variable k de 1 à \tilde{N} , pour un $RSB = 0$ dB. La première conclusion qui peut être tirée est que plus le nombre M augmente, plus les performances de détection s'améliorent, ce qui est attendu. D'autres conclusions ainsi qu'une version améliorée de ce détecteur seront présentées dans les sections suivantes.




FIGURE 4.2 – Les courbes de ROC de la MCS pour différentes valeurs de M et pour un $RSB = 0$ dB avec un nombre total d'échantillons égal à 400. On remarque que les performances de détection s'améliorent avec l'augmentation du nombre de retard M .

4.2.2 Méthode de comparaisons des slots version soft

Après l'introduction de la MCS, on propose dans cette section une version améliorée de cette dernière méthode (MCS) qu'on appelle la MCSS (méthode de comparaisons des slots version soft). Aucune modification sur la complexité de calcul par rapport à la MCS ne va être introduite. La seule modification qui va être introduite va être au niveau de la prise de décision. En effet au lieu d'utiliser des variables booléennes Δ_i et de faire le choix H_1 si une de ces variables est « vraie », l'idée de la MCSS est de sauvegarder la différence des indices δ_i des fréquences cycliques entre s_1 et s_2 . Cette différence δ_i sera sauvegardée pour chacun des retards τ_i , avec i allant de 1 à M . Enfin on calcule la valeur moyenne des δ_i en utilisant :

$$\bar{\delta} = \frac{1}{M} \sum_{i=1}^M \delta_i \quad (4.3)$$

et finalement la décision finale H_1 sera prise si $\bar{\delta}$ est inférieure à k , avec k allant de 1 à \tilde{N} . Il est donc évident que plus k est petit plus la p_{fa} est petite et vice versa. Voici les lignes de l'algorithme MCSS :

```

s1 ← [y1(0), ..., y1(ns - 1)]T
s2 ← [y2(0), ..., y2(ns - 1)]T
for i = 1 à M do

```



```

b1(τi) ← calcul des  $n_s$  éléments de  $\mathbf{f}_{\tau_i}^{(1)}$ 
b2(τi) ← calcul des  $n_s$  éléments de  $\mathbf{f}_{\tau_i}^{(2)}$ 
 $\hat{\mathbf{r}}_1^{(\tau_i)}$  ← OMP( $A, \mathbf{b}_1^{(\tau_i)}$ )
 $\hat{\mathbf{r}}_2^{(\tau_i)}$  ← OMP( $A, \mathbf{b}_2^{(\tau_i)}$ )
indice1 ← indice( $\max(|\hat{\mathbf{r}}_1^{(\tau_i)}|)$ )
indice2 ← indice( $\max(|\hat{\mathbf{r}}_2^{(\tau_i)}|)$ )
note : indice1 et indice2 sont choisis sans tenir compte des indices de la fréquence
cyclique zéro.
 $\delta_i$  ←  $|\textit{indice}_1 - \textit{indice}_2|$ 
end for
 $\bar{\delta} \leftarrow \frac{1}{M} \sum_{i=1}^M \delta_i$ 
if  $\bar{\delta} < k$  then
     $H_1$  est choisie
else
     $H_0$  est choisie
end if

```

la figure 4.3 montre l'organigramme de la méthode de comparaison des slots version soft : MCSS.

4.2.2.1 Performance de détection de la MCSS

Afin d'observer le gain en performance de la MCSS par rapport à la MCS, on trace les courbes de ROC sur la figure 4.4 en utilisant le même signal que dans la section 4.2.1.1, avec $M = 5$, $n_s = 200$ (donc $n_{tot} = 2n_s = 400$), et un $RSB = 0$ dB. Le résultat de la figure 4.4 montre nettement l'amélioration des performances de détection en utilisant la méthode « *soft* » contre la méthode « *hard* » (la MCS) tout en gardant la même complexité et toujours la propriété aveugle. Pour ces raisons, dans la suite de ce chapitre, on utilise la MCSS pour le reste des analyses et des comparaisons.

Maintenant on compare notre test proposé (la MCSS) au détecteur de cyclostationarité de second ordre dans le domaine temporel publié dans [2] nécessitant la connaissance *a priori* de la fréquence cyclique du signal transmis (dans notre cas $\alpha_f = \frac{1}{T_s}$). Afin de faire une comparaison équitable on utilise 400 échantillons pour le détecteur cyclostationnaire, aussi on utilise les mêmes ensembles des retards τ_i ($M = 5$). Ensuite on trace sur la même figure 4.5, les résultats obtenus avec le détecteur cyclostationnaire pour le même RSB. La conclusion est que dans les mêmes conditions, sauf que le détecteur cyclostationnaire possède une information supplémentaire qui est la connaissance *a priori* de la fréquence cyclique α_f , notre nouveau détecteur (MCSS) dépasse en performance le détecteur cyclostationnaire. On note que pour une détection robuste le détecteur cyclostationnaire a besoin d'un grand nombre d'échantillons [147], ce qui explique les faibles performances du détecteur cyclostationnaire obtenues avec un faible nombre d'échantillons.

4.2.2.2 Effet du filtrage sur la détection

L'effet du filtrage sur les statistiques cycliques peut être observé à partir de la FAC. Si on applique la transformée de Fourier inverse par rapport à f à la FCS qui est donnée

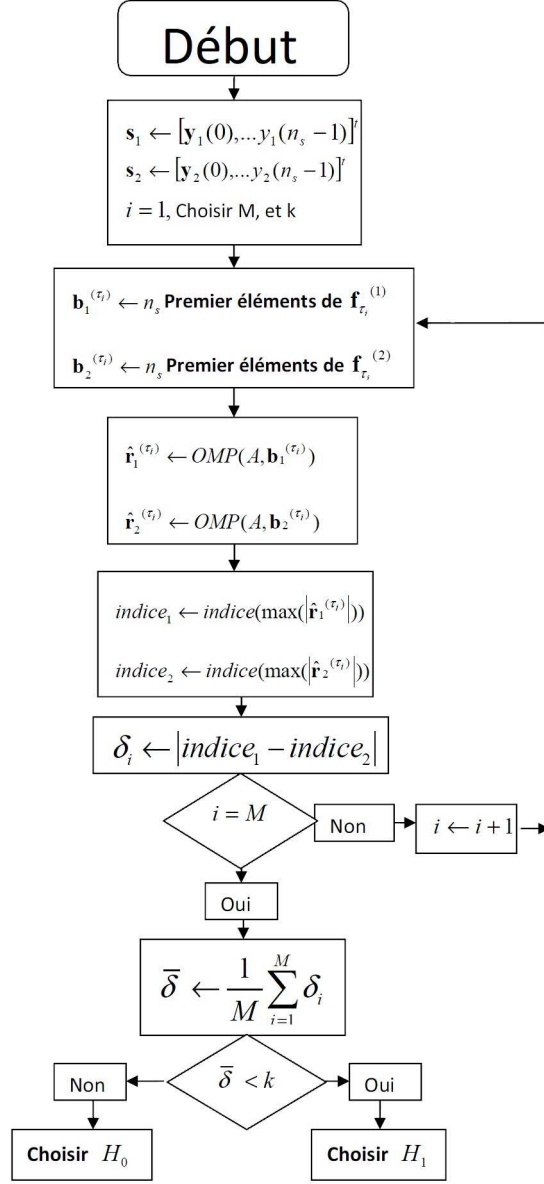


FIGURE 4.3 – L’organigramme de la Méthode de Comparaison des Slots version Soft : MCSS.

par l’équation (1.43), l’expression de la FAC s’écrit sous la forme suivante :

$$R_{yy}(\alpha, \tau) = \begin{cases} \frac{\sigma_d^2}{T_s} e^{-j2\pi\alpha\tau} \int_{-\infty}^{\infty} G(f - \frac{\alpha}{2}) G^*(f + \frac{\alpha}{2}) e^{j2\pi f\tau} df & \alpha = \frac{k}{T_s}, k \in \mathbb{Z} \\ 0 & \text{ailleurs} \end{cases} \quad (4.4)$$

Lorsque $g(t)$ est un filtre en cosinus surélevé, le terme $G(f - \frac{\alpha}{2}) G^*(f + \frac{\alpha}{2})$ sous l’intégrale est nul sauf pour $\alpha = 0$ ou $\alpha = \pm \frac{1}{T_s}$. La figure 4.6 montre le gabarit de ce filtre dans le domaine fréquentiel pour différentes valeurs du facteur de retombée. Dans le cas de $\alpha = \pm \frac{1}{T_s}$, l’intensité de $R_{yy}(|\frac{1}{T_s}|, \tau)$ est fonction de l’aire sous la courbe résultante du produit $G(f -$




FIGURE 4.4 – Les courbes de ROC de la MCS et de la MCSS, pour un nombre total d'échantillons égal à 400 et un $RSB = 0$ dB. On observe de meilleures performances de la MCSS par rapport à la MCS.




FIGURE 4.5 – Les courbes de ROC du détecteur cyclostationnaire comparé à la MCSS. Pour les deux cas un nombre total d'échantillons utilisés est égal à 400 et le RSB est égal à 0 dB. On observe de meilleures performances pour la MCSS.

$\frac{\alpha}{2})G^*(f + \frac{\alpha}{2})$. Cette aire est de plus en plus faible lorsque le facteur β diminue. Elle devient nulle lorsque $\beta = 0$, faisant ainsi perdre au signal $y(t)$ son caractère cyclostationnaire, ce qui provoque une dégradation des performances du détecteur cyclostationnaire après l'ajout d'un filtre à l'émission.

On peut aussi expliquer la dégradation des performances du détecteur de [2] avec l'ajout d'un filtre avec un autre raisonnement. En effet l'estimateur (3.13) utilisé dans le détecteur cyclostationnaire de [2] peut être considéré comme un cas particulier de

l'estimateur classique (3.14) définie dans le chapitre 3 : l'estimateur (3.14) estime un VAC or (3.13) estime seulement la FAC sur un seul point du VAC (la fréquence cyclique). Or on a vu d'après le chapitre 3 que le filtrage dégrade l'estimateur classique du VAC (3.14) (augmentation de l' EQM et de l' EQM_{α_f}) d'où l'explication de la dégradation des performances du détecteur de [2] qui se base sur l'estimateur (3.13).




FIGURE 4.6 – Allure fréquentielle du filtre en cosinus surélevé pour différentes valeurs du facteur de retombée

Afin de mettre en évidence la dégradation des performances du détecteur cyclostationnaire, on présente sur la figure 4.7 les courbes de ROC du détecteur cyclostationnaire dans les deux cas : avec et sans filtrage. Pour les deux cas le RSB est égal à 0 dB, le nombre total des échantillons utilisés est de 400, et $M = 5$. Dans le cas où un filtre en racine de Nyquist est utilisé le facteur de retombée β est égal à 0,5. Comme prévu on observe clairement la dégradation de la détection due à l'ajout du filtrage à l'émission.




FIGURE 4.7 – Les courbes de ROC du détecteur cyclostationnaire avec et sans filtrage à l'émission. Pour les deux cas un nombre total d'échantillons utilisés est égal à 400 et le RSB utilisé est égal à 0 dB

Pour évaluer les performances de la MCSS proposée on utilise dans cette partie, une modulation BPSK avec une racine de Nyquist avec un facteur de retombé $\beta = 0,5$. À l'inverse du détecteur cyclostationnaire on observe dans la figure 4.8 une amélioration des performances de détection après l'ajout d'un filtrage à l'émission. L'importance de ce résultat est que plus on est dans un environnement réaliste (avec filtrage) plus la MCSS s'améliore tandis que la méthode de détection cyclostationnaire se dégrade. Bien que l'estimation du VAC se dégrade en utilisant un filtre à l'émission (cf. chapitre 3) (EQM et EQM_{α_f} augmente avec le filtrage), on observe une amélioration des performances de détection. L'explication de ce résultat non intuitif sera donnée dans la section suivante.




FIGURE 4.8 – Les courbes de ROC de la MCSS avec et sans filtrage. Pour les deux cas un nombre total d'échantillons utilisés est égal à 400 et le RSB est égal à 0 dB. On observe de meilleures performances pour la MCSS dans le cas où un filtre à l'émission est utilisé.

À la figure 4.9 on montre simultanément les courbes de ROC du détecteur cyclostationnaire classique avec et sans filtrage ainsi que la MCSS. On note que pour une probabilité de fausse alarme égale à 0,1 le gain en détection entre les deux méthodes est $\Delta P_d = 0,25$ avant filtrage et $\Delta P_d = 0,65$ après filtrage. Cette différence en détection qui n'est pas négligeable montre l'intérêt de la MCSS par rapport au détecteur cyclostationnaire classique. L'explication de cette amélioration de performance va être exposée dans la sous-section-suivante.

A. L'explication de l'amélioration des performances de la MCSS avec filtrage

Comme on l'a déjà vu dans le chapitre précédent, le filtrage élimine les harmoniques de la fréquence cyclique fondamentale et uniquement les fréquences cycliques fondamentales ($\pm\alpha_f$) restent présentes dans le cyclopectre. Ce qui fait qu'au moment de la résolution du problème inverse sous H_1 en utilisant l'OMP, la probabilité que les atomes choisis (constituant le VAC) tombent à l'intérieur de l'intervalle $I_\alpha = [-\alpha_f, \alpha_f] = [-\frac{1}{T_s}, \frac{1}{T_s}]$ est plus grande si un filtre est utilisé à l'émission car dans ce cas il n'y a pas d'harmoniques de la fréquence cyclique. D'autre part si aucun filtre n'est pas utilisé à l'émission la probabilité que les atomes choisis tombent à l'intérieur de l'intervalle $I_\alpha = [-\frac{1}{T_s}, \frac{1}{T_s}]$ est plus faible car il y a une probabilité que des atomes qui représentent les harmoniques de la fréquence cyclique et qui sont à l'extérieur de $I_\alpha = [-\frac{1}{T_s}, \frac{1}{T_s}]$ soient choisis.




FIGURE 4.9 – Les courbes de ROC de la MCSS et du détecteur cyclostationnaire, avec et sans filtrage. Pour les quatre cas un nombre total d'échantillons utilisés est égal à 400 et le RSB est égal à 0 dB. On observe de meilleures performances pour la MCSS dans le cas où un filtre à l'émission est utilisé, par contre une dégradation des performances de la méthode cyclostationnaire due au filtrage est observée.

Donc même si la qualité de l'estimation est meilleure sans filtrage, il y a un risque que les fréquences cycliques estimées pour deux slots consécutifs s_1 et s_2 ne présentent pas la même fréquence cyclique; par exemple il est probable que la fréquence cyclique estimée de s_1 soit égale à $\frac{1}{T_s}$ et celle de s_2 soit égale à $\frac{2}{T_s}$ (l'harmonique de la fondamentale) et donc dans ce cas il n'y a pas de détection sachant qu'on est sous H_1 . Ce problème ne se pose pas dans le cas filtré car les harmoniques de la fréquence cyclique n'existent plus.

Dans ce qui suit on montre par simulation que la probabilité que les q premiers atomes choisis, constituant le VAC tombent à l'intérieure de I_α est plus grande quand un filtre est utilisé. Soit E l'événement que les q premiers atomes choisis après q itérations de l'OMP tombent dans l'intervalle $I_\alpha = [-\frac{1}{T_s}, \frac{1}{T_s}]$. Le but donc est de montrer que $P(E|H_1, W) > P(E|H_1, \bar{W})$, avec W l'événement qu'un filtre à l'émission est utilisé et \bar{W} l'événement opposé. Aucune analyse pour H_0 est faite car aucun filtre n'intervient sur le bruit reçu sous H_0 , car dans ce cas aucun signal filtré n'est envoyé.

Le but est de montrer par simulation que $P(E|H_1, W) > P(E|H_1, \bar{W})$, pour cela on choisit un dictionnaire de taille (300, 4000), donc le signal reçu est composé de 300 échantillons et doit être présentée ensuite après $q = 3$ itérations de l'OMP en utilisant q atomes choisis parmi les 4000 atomes composants le dictionnaire. On fait pour cela 3000 essais indépendants sous un RSB égal à 0 dB. Après ces 3000 essais on calcule la densité de probabilité de l'ensemble des atomes sélectionnés. Le résultat est présenté pour chacun des cas : sachant \bar{W} , et sachant W , sur les figures 4.10 et 4.11 respectivement.

D'après les figures 4.10 et 4.11 il est clair que :

$$P(E|H_1, W) > P(E|H_1, \bar{W}) \quad (4.5)$$

en effet on trace sur les figures 4.12 et 4.13 les fonctions de répartitions relatives respectivement aux densités présentées par les figures 4.10 et 4.11. On note la fonction de

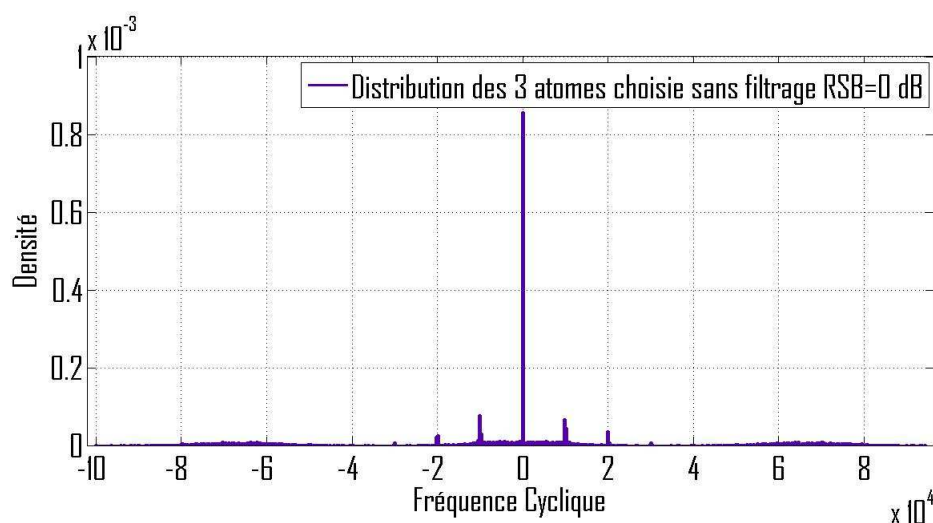


FIGURE 4.10 – La densité de probabilité obtenue par simulation (3000 essais) de la distribution des 3 premiers atomes choisis parmi initialement 4000 atomes sous H_1 et un $RSB = 0$ dB, sans l'utilisation d'un filtrage à l'émission.




FIGURE 4.11 – La densité de probabilité obtenue par simulation (3000 essais) de la distribution des 3 premiers atomes choisis parmi initialement 4000 atomes sous H_1 et un $RSB = 0$ dB, avec l'utilisation d'un filtrage à l'émission.

répartition correspondant à la figure 4.10, $F_{\bar{W}}(x)$ (cas non filtré) et on appelle la fonction de répartition correspondant à la figure 4.11, $F_W(x)$. On peut écrire donc :

$$P(E|H_1, W) = F_W\left(\frac{1}{T_s}\right) - F_W\left(-\frac{1}{T_s}\right) \quad (4.6)$$

d'après la figure 4.13 on a $F_W\left(\frac{1}{T_s}\right) = 0,957$ et $F_W\left(-\frac{1}{T_s}\right) = 0,04133$ en substituant donc les valeurs obtenues de $F_W\left(\frac{1}{T_s}\right)$ et $F_W\left(-\frac{1}{T_s}\right)$ dans l'équation (4.6) on obtient $P(E|H_1, W) \cong$

92%. Aussi on peut écrire :

$$P(E|H_1, \bar{W}) = F_{\bar{W}}\left(\frac{1}{T_s}\right) - F_{\bar{W}}\left(-\frac{1}{T_s}\right) \quad (4.7)$$

d'après la figure 4.12 on a $F_{\bar{W}}\left(\frac{1}{T_s}\right) \cong 0,76$ et $F_{\bar{W}}\left(-\frac{1}{T_s}\right) \cong 0,22$ en substituant donc les valeurs obtenues de $F_{\bar{W}}\left(\frac{1}{T_s}\right)$ et $F_{\bar{W}}\left(-\frac{1}{T_s}\right)$ dans l'équation (4.7) on obtient $P(E|H_1, \bar{W}) \cong 54\%$.

De plus, sur la figure 4.11 (avec filtrage), on observe une concentration de la densité de probabilité dans l'intervalle I_α (92%) et une très faible partie (le reste qui représente $100 - 92 = 8\%$) de la densité est à l'extérieur de cet intervalle. D'une autre part à la figure 4.10 on observe moins de concentration de la distribution dans l'intervalle I_α (54%) et le reste ($100 - 54 = 46\%$) est réparti sur les harmoniques.




FIGURE 4.12 – La fonction de repartions de la densité de probabilité de la distribution des 3 premiers atomes sous H_1 et un $RSB = 0$ dB sans l'utilisation d'un filtre à l'émission.

À partir des valeurs de $P(E|H_1, W)$ et de $P(E|H_1, \bar{W})$ on peut conclure donc que la probabilité que les fréquences cycliques de deux *slots* indépendants s_1 et s_2 appartenant à H_1 obtenue après reconstruction inverse soit dans l'intervalle I_α si un filtrage est appliqué à l'émission et de $0,92 \times 0,92 \cong 0,85$ contre seulement $0,54 \times 0,54 \cong 0,29$ si aucun filtrage n'est appliqué. Cela revient à dire que la distance entre les fréquences cycliques de deux *slots* indépendants s_1 et s_2 appartenant à H_1 obtenue après reconstruction inverse est probablement plus faible que la distance du cas non filtré et ceci est du à cause de la taille de l'intervalle I_α qui est 10 fois plus petite que celle de l'intervalle $[\alpha_{min}, \alpha_{max}]$ d'une part, et que dans le cas filtré, les fréquences cycliques estimées sont concentrées dans I_α d'une autre part.

À l'inverse, dans le cas non filtré les fréquences cycliques estimées ne sont pas concentrées dans un intervalle spécifique, et donc la distance entre les fréquences cycliques de deux *slots* s_1 et s_2 appartenant à H_1 est probablement plus large.

À partir de cette observation le résultat d'obtenir une plus grande détection quand on applique le critère de la MCSS (comparaison de la distance entre les fréquences cycliques obtenues) avec filtrage est justifié.




FIGURE 4.13 – La fonction de répartition de la densité de probabilité de la distribution des 3 premiers atomes sous H_1 et un $RSB = 0$ dB avec l'utilisation d'un filtre à l'émission.

4.2.2.3 Effet du Canal de Propagation

Afin d'étudier l'impact du canal de propagation sur les performances de la MCSS et sur le détecteur cyclostationnaire on évalue les performances de ces deux détecteurs en fonction du RSB , avec et sans canal de propagation. On note que dans les deux cas un filtre à l'émission est utilisé afin d'être dans une situation réaliste. On choisit de voir l'impact du canal de Rayleigh de variance unitaire (chaque échantillon est multiplié par un coefficient qui suit une loi de Rayleigh de variance unitaire et les coefficients sont i.i.d., ce modèle de canal de Rayleigh est utilisé le long de ce chapitre). Le canal de Rayleigh est choisi puisque c'est un canal très sévère qui est normalement utilisé pour représenter, en communications numériques, les situations où l'émetteur n'est pas en vision directe avec le récepteur. Sur la figure 4.14 on trace la probabilité de bonne détection pour une fausse alarme fixée à 10% en fonction du RSB pour la MCSS, et le détecteur de cyclostationarité en utilisant un total de 400 échantillons et $M = 5$ pour les deux méthodes. On observe une dégradation des deux méthodes de détection après l'introduction du canal de Rayleigh notamment une perte de 4 dB en RSB est observée pour la MCSS. En effet avant l'introduction du canal la probabilité de détection à 100% est atteinte pour un RSB de 4 dB, et après son introduction cette probabilité est atteinte pour un RSB de 8 dB. En ce qui concerne la méthode de cyclostationarité une légère dégradation est observée, d'ailleurs le détecteur cyclostationnaire est déjà dégradé à cause du filtrage à l'émission et du faible nombre d'échantillons utilisés.

4.2.2.4 Analyse de complexité et temps d'observation

La complexité du nouveau détecteur MCSS, est la même que celle de l'OMP qui est donnée dans [148], multipliée par $2 \cdot M$, vu que l'OMP est utilisé $2 \cdot M$ fois. On note que la complexité de l'OMP est égale à $O(l_1 \cdot l_2 \cdot l_3)$, avec l_1 , l_2 , et l_3 le nombre de lignes du dictionnaire, le nombre d'atomes, et le nombre d'itérations respectivement. On trouve




FIGURE 4.14 – La probabilité de détection en fonction du RSB pour une fausse alarme fixée à 10%, pour la MCSS et le détecteur cyclostationnaire. On considère les deux cas : avec et sans canal de propagation pour chacune des deux méthodes de détection.

donc que la complexité du MCSS est donc égale à $O(2 \cdot n_s \cdot M \cdot S \cdot \tilde{N})$, avec S le nombre d'itérations utilisées par l'OMP. En pratique S est égale à 3, car après filtrage seulement la fréquence cyclique zéro et les deux fréquences cycliques fondamentales $\pm\alpha_f$ apparaissent dans la fonction d'autocorrélation cyclique pour un délai donné τ .

On calcule la complexité du détecteur de cyclostationnarité de second ordre dans le domaine temporel [2] on trouve que le résultat est égal à $O(M \cdot N' \cdot (L + 1) + 4 \cdot M \cdot L^2 + 8 \cdot M^3 + 6 \cdot M^2 + 2 \cdot M) \cong O(M \cdot N' \cdot (L + 1) + 4 \cdot M \cdot L^2)$, où L est la taille (impair) de la fenêtre spectrale utilisée dans le test cyclique (on note que dans toutes les simulations de ce chapitre L est égale à 41) et N' représente le nombre total d'échantillons utilisé par le détecteur de cyclostationnarité. La figure 4.15 montre la probabilité de détection en fonction du nombre total d'échantillons utilisés pour les deux méthodes MCSS et la méthode proposée par [2] avec et sans canal (de Rayleigh) pour un $RSB = 0$ dB et une P_{fa} égale à 10%. On utilise le même nombre et les mêmes valeurs des délais pour les deux méthodes ($M = 5$).

On peut observer que sans canal de propagation, pour atteindre une probabilité de détection égale à 0,85 avec une fausse alarme P_{fa} égale à 10% le détecteur de cyclostationnarité a besoin de $N' = 2695$ échantillons et donc $\approx 6 \times 10^5$ opérations sont nécessaires. Cependant $\approx 2,3 \times 10^6$ opérations sont nécessaires pour la MCSS avec seulement un nombre total d'échantillons nécessaires $n_{tot} = 2 \cdot n_s = 300$ pour atteindre les mêmes performances. On peut donc conclure que la MCSS est plus complexe que la méthode proposée par [2] (3,8 fois plus complexe) mais nécessite un temps d'observation plus petit (≈ 9 fois plus petit) et ceci pour atteindre les mêmes performances tout en étant une méthode de détection aveugle.

D'autre part, après l'ajout d'un canal de Rayleigh, les performances des deux détecteurs se dégradent. La MCSS atteint une limite de détection inférieure au cas, sans canal. La MCSS garde toujours un temps d'observation plus court mais la complexité relative par rapport au détecteur cyclostationnarité augmente. En effet si on considère le point de




FIGURE 4.15 – La probabilité de détection P_d pour une fausse alarme fixée à 10% et un $RSB = 0$ dB, en fonction du nombre d'échantillons (temps d'observation) et ceci pour la MCSS et le détecteur de cyclostationarité. Deux cas sont considérés : avec et sans canal de propagation.

performance $(P_d, P_{fa}) = (0,6; 0,1)$, la MCSS a besoin d'un total de 500 échantillons donc approximativement $3,84 \times 10^6$ opérations. Pour ce même point la méthode de cyclostationarité a besoin de 2100 échantillons donc approximativement $4,75 \times 10^5$ opérations. Le temps d'observation de la MCSS par rapport au détecteur de cyclostationarité est donc réduit de 9 à 4,2 fois d'une part, et la complexité de calcul par rapport aussi au détecteur de cyclostationarité a augmenté de 3,8 fois à 8 fois.

Les tables 4.1 et 4.2 montrent une comparaison entre la complexité (nombre d'opérations) et le nombre d'échantillons correspondant à chacune des deux méthodes sans et avec canal de propagation. On peut finalement conclure que la MCSS est plus complexe que le détecteur de cyclostationarité proposé dans [2], mais nécessite un temps d'observation plus petit pour détecter, sachant que les performances de la MCSS sont dégradées avec le canal de Rayleigh. De plus la MCSS est une méthode aveugle à la différence de la méthode de [2] qui nécessite la fréquence cyclique comme information *a priori*.

4.2.2.5 Conclusion sur la MCSS

On conclut donc que la MCSS est une méthode relativement plus complexe que le détecteur temporel de second ordre proposé dans [2], mais nécessite un temps d'observation nettement plus petit pour atteindre la même performance de détection (Ou d'une manière équivalente, la MCSS dépasse en performance le détecteur cyclostationnaire en utilisant le même nombre d'observations). Cette plus grande complexité de la MCSS peut être compensée par le fait que la MCSS est une méthode aveugle et ne nécessite pas la connaissance *a priori* de la fréquence cyclique du signal reçu. De plus on montre que lorsqu'un filtrage est utilisé, les performances de la méthode MCSS s'améliorent contrairement au détecteur cyclostationnaire qui ce dégrade.

	MCSS	Détecteur Cyclostationnaire
Complexité	$O(2 \cdot M \cdot n_s \cdot S \cdot \tilde{N})$	$O(M \cdot N'(L+1) + 4 \cdot M \cdot L^2)$
Nombre d'échantillons pour $(P_{fa}, P_d) = (0, 1; 0, 85)$	300	2695
$\text{Log}(\text{Nombre d'opération})$	6, 36	5, 77
information <i>a priori</i>	Méthode aveugle	$\alpha_f = \frac{1}{T_s}$

TABLE 4.1 – Comparaison du nombre d'échantillons et des complexités entre la MCSS proposé et le détecteur cyclostationnaire de Giannakis pour exactement la même performance $(P_{fa}, P_d) = (0, 1; 0, 85)$ sans canal de propagation.

	MCSS	Détecteur Cyclostationnaire
Complexité	$O(2 \cdot M \cdot n_s \cdot S \cdot \tilde{N})$	$O(M \cdot N'(L+1) + 4 \cdot M \cdot L^2)$
Nombre d'échantillons pour $(P_{fa}, P_d) = (0, 1; 0, 6)$	500	2100
$\text{Log}(\text{Nombre d'opération})$	6, 58	5, 67
information <i>a priori</i>	Méthode aveugle	$\alpha_f = \frac{1}{T_s}$

TABLE 4.2 – Comparaison du nombre d'échantillons et de la complexité entre la MCSS proposée et le détecteur cyclostationnaire pour exactement les mêmes performances $(P_{fa}, P_d) = (0, 1; 0, 6)$ avec un canal de Rayleigh.

4.2.3 Méthodes de symétrie

Dans cette partie on propose une autre méthode aveugle de détection basée non seulement sur la propriété parcimonieuse de la FAC mais aussi sur ses propriétés de symétrie par rapport à α pour un τ donné.

4.2.3.1 Propriété de symétrie

On rappelle d'après (1.33) que pour les valeurs réelle de $y(t)$, $R_{yy}(\alpha, \tau)$ présente les propriétés de symétries suivantes :

$$R_{yy}(\alpha, -\tau) = R_{yy}(\alpha, \tau) \quad (4.8)$$

$$R_{yy}(-\alpha, \tau) = R_{yy}^*(\alpha, \tau) \quad (4.9)$$

avec $R_{yy}^*(\alpha, \tau)$ représente le complexe conjugué de $R_{yy}(\alpha, \tau)$. En prenant la norme des deux membres de l'équation (4.9) on obtient :

$$\|R_{yy}(-\alpha, \tau)\|_2 = \|R_{yy}(\alpha, \tau)\|_2 \quad (4.10)$$

On peut aussi vérifier la propriété de l'équation (4.10) en regardant la figure 4.16 qui représente la norme de la fonction d'autocorrélation cyclique d'une BPSK. On peut observer sur la figure 4.16 qu'il existe une symétrie autour de $\alpha = 0$.




FIGURE 4.16 – La norme théorique de la fonction d'autocorrélation cyclique d'une BPSK. On note la symétrie de cette norme par rapport à l'axe $\alpha = 0$.

L'idée principale de ce détecteur est de reconstruire partiellement le VAC en utilisant peu d'échantillons avec l'OMP. Après la reconstruction partielle du VAC, la propriété de symétrie autour de $\alpha = 0$ est testée. Si le VAC obtenu vérifie approximativement (4.10) alors H_1 est choisie, sinon c'est H_0 qui est retenue. Il est important de noter que sous H_0 le VAC est théoriquement aussi symétrique et vérifie donc la propriété (4.10) car $y(t)$ est réelle sous H_1 et H_0 , mais sous H_0 , quand on utilise peu d'itérations pour la reconstruction du VAC avec l'OMP, la probabilité d'obtenir un VAC symétrique est très faible. Cette dernière remarque va être expliquée en détails dans la suite.

4.2.3.2 La nouvelle méthode de symétrie MS

Soit $\mathbf{b}^{(\tau_0)}$ le vecteur défini précédemment (cf. section 4.2.1), construit à partir des n premiers éléments reçus de $y(t)$. On fixe l (impair) le nombre d'itérations de l'OMP afin de résoudre $\mathbf{b}^{(\tau_0)} = \mathbf{A}\mathbf{r}^{(\tau_0)}$. Ensuite après l'obtention du vecteur solution $\mathbf{r}_l^{(\tau_0)}$, il sera composé d'éléments nuls à l'exception de l éléments non nuls (le nombre d'éléments est égal au nombre d'itérations de l'OMP). On définit par $IND_{sym}^{(\tau_0)}$ l'indice de symétrie du vecteur $\mathbf{r}_l^{(\tau_0)}$. Pour calculer l'indice $IND_{sym}^{(\tau_0)}$ on ignore l'élément de $\mathbf{r}_l^{(\tau_0)}$ correspondant à $\alpha = 0$ (donc ayant la plus grande amplitude), ensuite $IND_{sym}^{(\tau_0)}$ est obtenue en calculant la valeur moyenne des abscisses des $l - 1$ éléments restants. Plus $IND_{sym}^{(\tau_0)}$ est proche de zéro plus la symétrie est considérée idéale. Une symétrie idéale est obtenue quand l'estimation est parfaite donc pour $IND_{sym}^{(\tau_0)} = 0$. $IND_{sym}^{(\tau_0)}$ est obtenue en utilisant l'équation suivante :

$$IND_{sym}^{(\tau_0)} = \frac{1}{l-1} \sum_{j=2}^l \alpha_j \quad (4.11)$$

La figure 4.17 illustre un exemple de calcul de $IND_{sym}^{(\tau_0)}$ pour un délai τ_0 donné et pour $l = 3$. On a dans ce cas idéal $IND_{sym}^{(\tau_0)} = \frac{1}{2}(\alpha_2 + \alpha_3) = 0$.




FIGURE 4.17 – Exemple de calcul de $IND_{sym}^{(\tau)}$ pour un délai τ et un nombre d'itérations $l = 3$. On obtient dans ce cas idéal $IND_{sym}^{(\tau)} = \frac{1}{2}(\alpha_2 + \alpha_3) = 0$.

Avant de prendre la décision finale on note que $\mathbf{r}_l^{\tau_i}$ doit être estimé sur différentes valeurs de τ_i , $i \in \{1, 2, \dots, M\}$, et ceci pour augmenter la probabilité de détecter car ce n'est pas nécessaire que $R(\alpha, \tau)$ soit non nulle pour toute valeur de τ même si α est une fréquence cyclique du signal reçu (cf. équation (4.1)). L'algorithme doit donc calculer M différentes valeurs de $IND_{sym}^{(\tau_i)}$ (en utilisant donc M fois l'algorithme de l'OMP) et la décision finale sera faite en utilisant l'indice équivalent obtenu en combinant tous les indices obtenus faisant ainsi une décision souple :

$$IND_{sym}^{(equ)} = \frac{1}{M} \sum_{i=1}^M |IND_{sym}^{(\tau_i)}| \quad (4.12)$$

finalement $IND_{sym}^{(equ)}$ sera comparé à un seuil positif ξ afin de décider entre H_0 et H_1 ($IND_{sym}^{(equ)} \underset{H_0}{\leq} \xi$). On note que plus ξ est large plus les probabilités de détection et de fausse alarme sont grandes et vice versa. La figure 4.18 montre l'organigramme de la méthode de symétrie MS.

4.2.3.3 Le choix du nombre d'itération

L'objectif de l'algorithme de détection n'est pas de faire une reconstruction complète du VAC. Le but est uniquement de détecter l'existence d'un signal dans la bande. Pour cette raison il est judicieux de choisir l afin de maximiser les performances de détection et de minimiser la complexité de l'algorithme à la fois. Dans les sous sections suivantes on va expliquer en détails pourquoi il est judicieux de choisir un nombre impair d'itérations l d'une part ainsi qu'un nombre minimal d'itérations l d'autre part.

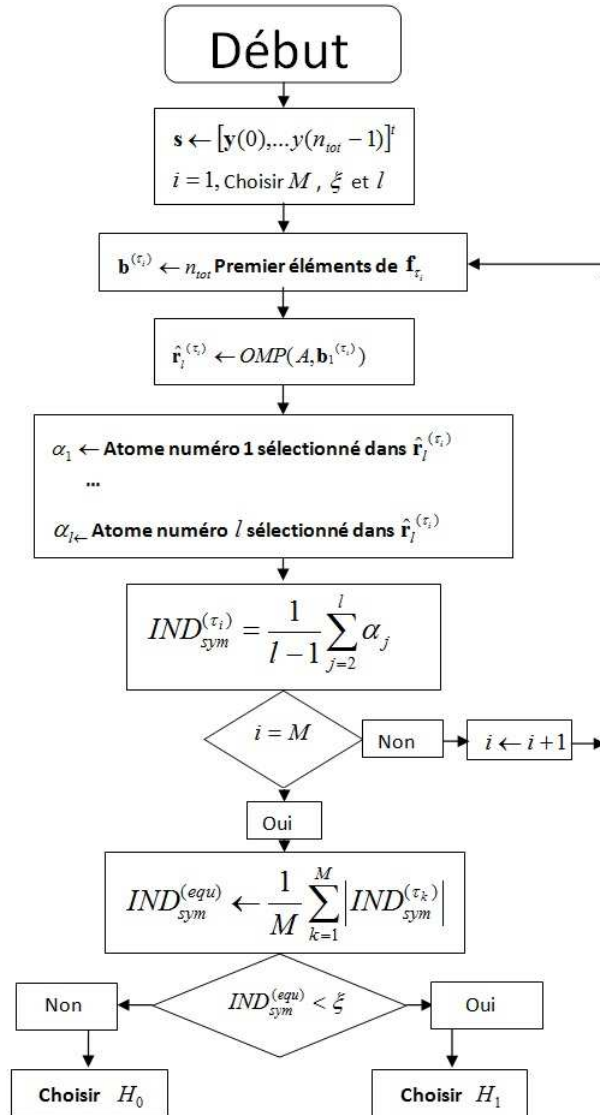


FIGURE 4.18 – L’organigramme de la Méthode de Symétrie MS.

A. Un nombre impair d’itérations

Le nombre d’itérations l doit être un nombre impair afin d’évaluer correctement $|IND_{sym}^{\tau_0}|$, car comme on l’a déjà mentionné précédemment l’algorithme a besoin de vérifier la symétrie autour de l’axe $\alpha = 0$. L’élément dans \mathbf{r}_l^{τ} ayant la plus grande amplitude correspond à $\alpha = 0$, et il est obtenu avec forte probabilité après la première itération de l’OMP (car pour $\alpha = 0$, le VAC a la plus grande amplitude cf. (3.11)). Ensuite les $l - 1$ (pair) éléments non nuls restants qui représentent les fréquences cycliques qui sont théoriquement deux à deux symétriques par rapport à $\alpha = 0$. En effet pour chaque raie sur la fréquence cyclique α doit correspondre une autre raie sur la fréquence cyclique $-\alpha$ et ayant la même norme.

B. Un nombre minimal d'itérations

Deux raisons majeures rendent judicieux de choisir un nombre minimal d'itérations ($l = 3$). La première raison est liée à la complexité de l'OMP qui dépend directement du nombre d'itérations l , et donc choisir un l minimal revient à minimiser la complexité de l'algorithme de détection. On note que la complexité de cet algorithme est la même que celle de l'OMP qui est donnée par [148], multipliée par M , et elle est donnée par $O(M \cdot n_{tot} \cdot l \cdot \tilde{N})$, avec n_{tot} le nombre total d'échantillons utilisés pour détecter, et \tilde{N} le nombre total d'atomes utilisés pour définir le dictionnaire.

La seconde raison majeure de choisir un l minimal est de minimiser les fausses alarmes. Bien que l'équation (4.10) est vérifiée sous H_0 et H_1 la méthode de symétrie peut toujours être utilisée pour distinguer entre H_0 et H_1 ; en effet sous H_1 quand l'OMP est appliqué, il est fort probable que des atomes symétriques à $\alpha = 0$ et proches de la valeur de la fréquence cyclique fondamentale vont être sélectionnés consécutivement suite à des itérations consécutives comme ils ont la même norme (à cause de la symétrie) qui est différente de zéro (par définition l'OMP sélectionne les atomes les plus corrélés avec le vecteur résiduel après chaque itération). Par opposition, sous H_0 le VAC est nul, car le bruit n'a pas de fréquences cycliques à l'exception de $\alpha = 0$ (prend la valeur de l'autocorrélation classique). Pour cette raison sous H_0 les atomes ne seront pas sélectionnés avec un ordre spécifique minimisant ainsi la probabilité d'avoir un vecteur reconstruit \mathbf{r}_l^T symétrique pour une faible valeur de l . On note que sous H_0 , plus le nombre d'itérations l augmente, une reconstruction plus complète de \mathbf{r}_l^T sera faite et la probabilité d'obtenir un vecteur symétrique augmente générant ainsi plus de fausses alarmes.

Pour ces différentes raisons il est souhaitable de travailler avec un nombre minimal d'itérations l afin de minimiser la complexité et de maximiser les performances à la fois.

4.2.3.4 Résultats de simulations

Dans cette section on utilise la même modulation BPSK utilisée précédemment. Un petit dictionnaire \mathbf{A} de taille (160, 512) est utilisé (donc $n_{tot} = 160$). Le nombre d'itérations l est fixé à 3 pour les raisons mentionnées précédemment. On compare les performances de ce détecteur avec la MCSS déjà proposée dans la section 4.2.2. La figure 4.19 montre la probabilité de détection en fonction du RSB pour une fausse alarme fixée à 15% et en utilisant un nombre d'échantillons total égal à 160 pour les deux méthodes afin de faire une comparaison juste. Deux ensembles différents de retard τ_i sont utilisés dans les simulations et ceci pour les deux méthodes de détection. Le premier ensemble est constitué seulement de deux valeurs de τ ($M = 2$), tandis que l'autre ensemble est constitué de cinq valeurs différentes ($M = 5$). On peut conclure premièrement que quel que soit l'ensemble des retards utilisé ($M = 2$ ou $M = 5$) la MS dépasse en performance la MCSS. On peut aussi vérifier que quand le nombre des retards M augmente les performances de détection s'améliorent pour les deux méthodes comme prévues. Finalement on peut observer que pour $M = 5$, la MS détecte à 90% contre seulement 42% pour la MCSS, et ceci évidemment dans les mêmes conditions et pour la même complexité de calcul.

La figure 4.20 montre les courbes de ROC des trois méthodes de détection : détecteur de cyclostationarité, la MS et la MCSS. Le nombre total des échantillons est égal à $n_{tot} = 200$ pour toutes les méthodes de détections. Le RSB est égal à 0 dB. On remarque que la MS, qui exploite simultanément la propriété de symétrie et de parcimonie de la FAC donne les

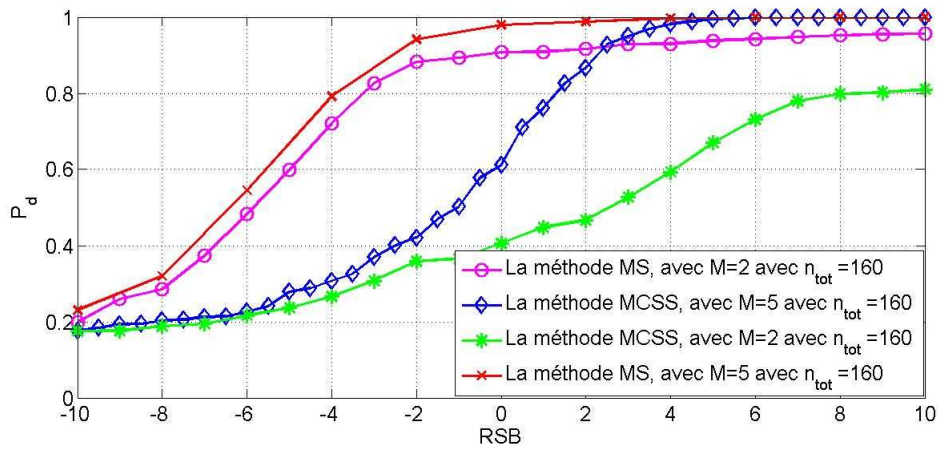


FIGURE 4.19 – La probabilité de détection en fonction du RSB pour une fausse alarme fixée à 15% avec un nombre total d'échantillons égal à 160, pour la MCSS et la MS. On considère les deux cas : $M = 2$ et $M = 5$ pour chacune des deux méthodes de détection. On remarque que la MS dépasse en détection la MCSS d'une part, et que les performances de détection s'améliorent avec M et ceci pour les deux méthodes de détection d'autre part.

meilleures performances de détection. En particulier on remarque une détection égale à 0,74 pour une fausse alarme parfaitement nulle. Cette particularité peut être intéressante surtout dans des applications très sensibles qui n'acceptent aucune fausse alarme.




FIGURE 4.20 – Les courbes de ROC des trois méthodes de détection : détecteur de Cyclostationarité, la MS et la MCSS. Le nombre total des échantillons est égal à 200 pour toutes les méthodes de détections. Le RSB est égal à 0 dB.

Comme on l'a déjà évoqué dans la section précédente, le but de l'algorithme MS proposé n'est pas de faire une reconstruction complète du VAC mais de savoir si un signal existe dans la bande. Afin de montrer qu'on obtient les meilleures performances quand le

nombre d'itérations l est minimal, on a simulé pour un $RSB = 0$ dB, et pour un total de 160 échantillons, la probabilité de fausse alarme P_{fa} en fonction du nombre d'itérations l prenant les valeurs impaires entre 3 et 21 pour une probabilité de détection fixée à 0,9. Le résultat de la simulation est montré sur la figure 4.21. Le résultat valide que la probabilité de fausse alarme minimale ($P_{fa} = 1,6\%$) est obtenue pour le minimum d'itérations ($l = 3$) et augmente avec le nombre d'itérations pour atteindre $P_{fa} = 50\%$ pour 21 itérations.




FIGURE 4.21 – Probabilité de fausse alarme en fonction du nombre d'itérations l (impair) pour une probabilité de détection fixe $P_d = 0,9$ et un $RSB = 0$ dB.

On simule maintenant en utilisant la MS (utilisée avec $l = 3$ itérations) et pour un $RSB = 0$ dB, la probabilité de fausse alarme P_{fa} en fonction du nombre total d'échantillons et ceci pour une probabilité de détection fixée à 0,9. Le résultat de la simulation est montré sur la figure 4.22. Comme prévu on observe que la probabilité de fausse alarme diminue avec le nombre d'échantillons pour atteindre une très faible valeur qui est égale à 0,002 pour 500 échantillons.

4.2.3.5 Influence du filtrage

Dans cette section on étudie l'influence de l'introduction d'un filtrage à l'émission sur la détection en utilisant la MS. Pour cela on se réfère aux densités de probabilités simulées de la distribution des 3 premiers atomes choisis par l'OMP sous H_1 sans et avec filtrage. Ces densités sont données respectivement par les figures 4.10 et 4.11, pour un RSB égal à 0 dB. La première observation est qu'avec filtrage la densité de probabilité conserve la propriété de symétrie par rapport à l'axe $\alpha = 0$, et donc le critère de symétrie n'est pas affecté par le filtrage.

On remarque sur la figure 4.11, que avec filtrage la probabilité que les 3 premiers atomes choisis par l'OMP tombent à l'intérieur de I_α est égale à 92% (cf. la fonction de répartition correspondante figure 4.13). On observe donc, avec filtrage, la présence d'une concentration de la densité dans l'intervalle $I_\alpha = [-\frac{1}{T_s}, \frac{1}{T_s}]$. Cependant dans le cas non filtré, la probabilité que les 3 premiers atomes choisis par l'OMP tombent à l'intérieur de I_α est égale seulement à 54% (cf. la fonction de répartition correspondante figure 4.12). On conclut donc que sans filtrage, la concentration de la densité de probabilité de la




FIGURE 4.22 – Probabilité de fausse alarme en fonction du nombre d'échantillons pour une probabilité de détection fixe $P_d = 0,9$ et un $RSB = 0$ dB.

distribution des 3 premiers atomes choisis par l'OMP sous H_1 , est plus faible par rapport au cas filtré dans l'intervalle $I_\alpha = [-\frac{1}{T_s}, \frac{1}{T_s}]$. Donc dans le cas filtré cette augmentation de la concentration de la densité (tout en conservant la symétrie) à l'intérieur de l'intervalle I_α rend naturellement les indices $IND_{sym}^{(\tau_i)}$ plus petits en moyenne car pour la majorité des cas les atomes vont se trouver à l'intérieur de I_α , donc la moyenne algébrique des fréquences cycliques, représentées par les atomes sélectionnés, sera plus proche de zéro minimisant ainsi la valeur de $IND_{sym}^{(equ)}$, ce qui augmente la probabilité de détection pour la même fausse alarme fixée par la valeur du seuil ξ .

Sur la figure 4.23 on montre que les courbes de ROC obtenues avec et sans filtrage à l'émission pour la MS, avec un nombre total d'échantillons n_{tot} utilisés égal à 300 et un $RSB = 0$ dB. On note aussi sur la figure 4.23 que l'amélioration introduite par le filtrage est une amélioration légère. Cette légère amélioration est expliquée par le fait que les densités de probabilité avec et sans filtrage sont symétriques par rapport à l'axe $\alpha = 0$, et donc la variable $IND_{sym}^{(\tau_i)}$ sous H_1 est dans les deux cas proche de zéro et résulte une bonne détection, sauf que le filtre améliore encore d'une manière légère cette détection comme on a déjà expliqué dans le paragraphe précédant.

4.2.3.6 Influence du canal de transmission

Pour étudier l'impact du canal de propagation sur les performances de la MS on évalue les performances de cette dernière méthode en fonction du RSB, avec et sans canal de propagation. On note que dans les deux cas un filtre à l'émission est utilisé afin d'être dans une situation réaliste. On choisit le même canal utilisé dans la section 4.2.2.3, qui est un canal de Rayleigh avec une variance unitaire. Sur la figure 4.24 on trace la probabilité de bonne détection pour une fausse alarme fixée à 10% en fonction du RSB pour la MS avec et sans canal de propagation, en utilisant un total de 160 échantillons où $M = 5$ pour les deux cas. On observe une dégradation de la MS après l'introduction du canal de Rayleigh notamment une perte de 2 dB en RSB est observée pour la MS. En effet, avant

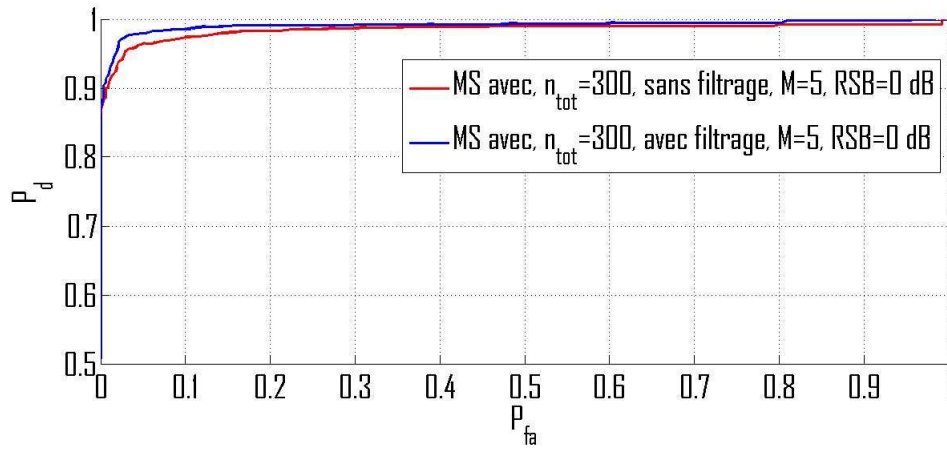


FIGURE 4.23 – Les courbes de ROC de la MS avec un nombre d'échantillons total égal à 300 et un $RSB = 0$ dB. On distingue les deux cas : avec et sans filtrage.

l'introduction du canal la probabilité de détection à 100% est atteinte pour un RSB de 4 dB, et après son introduction cette probabilité est atteinte pour un RSB de 6 dB.




FIGURE 4.24 – La probabilité de détection de la MS en fonction du RSB pour une fausse alarme égale à 10% et un nombre d'échantillons total égal à 160. On distingue les deux cas : avec et sans canal de propagation.

4.2.3.7 Analyse de la complexité et du temps d'observation

Dans cette section on analyse la complexité et le temps d'observation de la MS. Ensuite ces résultats vont être comparés à la MCSS d'une part et au détecteur de cyclostationarité de [2] d'une autre part.

A. Comparaison entre la MS et la MCSS

Dans cette sous section une comparaison va être faite entre la MS et la MCSS notamment sur le nombre d'opérations et le temps d'observation nécessaires pour atteindre une performance donnée. On rappelle que la complexité de la MS donnée dans 4.2.3.3.A, n'est autre que la complexité de l'OMP, multipliée par M , car l'OMP est appelé M fois avant de choisir entre H_0 et H_1 . Donc la complexité de la MS est donnée par $O(M \cdot n_{tot} \cdot \tilde{N} \cdot l)$, avec \tilde{N} le nombre d'atomes total utilisé dans le dictionnaire afin de résoudre le problème inverse et l le nombre d'itérations de l'OMP. Donc les expressions des complexités de la MS et de la MCSS sont les mêmes. Mais pour comparer d'une manière plus exacte les complexités des deux méthodes il est nécessaire de prendre en compte aussi le nombre d'opérations pour une performance donnée. Dans la figure 4.25 on trace pour une fausse alarme égale à 10% et un $RSB = 0$ dB la probabilité de détection en fonction du temps d'observation (nombre total d'échantillons utilisés pour la détection) pour les deux méthodes la MS et la MCSS. On utilise des filtres à l'émission pour chacune des deux méthodes afin d'avoir des résultats plus réalistes. De plus deux cas sont à distinguer pour chacune des deux méthodes : avec et sans canal de propagation (le canal utilisé et le canal de Rayleigh de variance unitaire).




FIGURE 4.25 – La probabilité de détection P_d pour une fausse alarme fixée à 10% et un $RSB = 0$ dB, en fonction du nombre d'échantillons (temps d'observation) et ceci pour la MS et la MCSS. Deux cas sont considérés : avec et sans canal de propagation.

On peut observer sur la figure 4.25 que sans canal de propagation, pour atteindre une probabilité de détection égale à 0,91 avec une fausse alarme P_{fa} égale à 10% la MS a besoin seulement de $n_{tot} = 100$ échantillons et donc $\approx 768 \times 10^3$ opérations nécessaires. Après une approximation à partir du résultat de la figure 4.25, la MCSS a besoin d'environ $n_{tot} \cong 1125$ échantillons pour atteindre les mêmes performances ($P_d = 0,91, P_{fa} = 0,1$) donc $\approx 864 \times 10^4$ opérations sont nécessaires pour la MCSS. On peut donc conclure que la MS est $\cong 11$ fois moins complexe que la MCSS et nécessite aussi un temps d'observation plus petit (aussi ≈ 11 fois plus petit) et ceci pour atteindre les mêmes performances sachant que les deux méthodes la MS et la MCSS sont toutes les deux des méthodes aveugles.

La table 4.3 montre une comparaison entre les complexités (nombre d'opérations) et le nombre d'échantillons correspondant aux méthodes MS et MCSS sans canal de propagation. On peut conclure que la MS est environ 11 fois moins complexe que la MCSS déjà proposée, et nécessite aussi un temps d'observation 11 fois plus petit pour détecter. Cette amélioration en complexité et en temps d'observation par rapport à la MCSS, résulte de l'exploitation de la propriété de symétrie de la FAC.

	MCSS	MS
Complexité	$O(2 \cdot M \cdot n_s \cdot S \cdot \tilde{N})$	$O(M \cdot n_{tot} \cdot l \cdot \tilde{N})$
Nombre d'échantillons pour $(P_{fa}, P_d) = (0, 1; 0, 91)$	1125	100
$\text{Log}(\text{Nombre d'opération})$	6,93	5,88
information <i>a priori</i>	Méthode aveugle	Méthode aveugle

TABLE 4.3 – Comparaison du nombre d'échantillons et de la complexité entre la MS proposée et la MCSS pour exactement les mêmes performances $(P_{fa}, P_d) = (0, 1; 0, 91)$ sans canal de propagation.

Nous observons sur la figure 4.25 que avec canal de Rayleigh, pour atteindre une probabilité de détection égale à 0,67 avec une fausse alarme P_{fa} égale à 10% la MS a besoin de seulement $n_{tot} = 100$ échantillons et donc $\approx 768 \times 10^3$ opérations sont nécessaires. Après une interpolation linéaire à partir du résultat de la figure 4.25, la MCSS a besoin d'environ $n_{tot} \cong 3362$ échantillons pour atteindre les mêmes performances $(P_d = 0,67, P_{fa} = 0,1)$ donc $\approx 25,82 \times 10^6$ opérations sont nécessaires pour la MCSS. On peut donc conclure que la MS est $\cong 33$ fois moins complexe que la MCSS et nécessite aussi un temps d'observation plus petit (≈ 33 fois plus petit) et ceci pour atteindre les mêmes performances, ce qui nous laisse conclure que la MS est nettement plus résistante par rapport à un canal de Rayleigh que la MCSS.

La table 4.4 montre une comparaison entre la complexité (nombre d'opérations) et le nombre d'échantillons correspondant aux méthodes MS et MCSS avec canal de propagation. On peut conclure que la MS est environ 33 fois moins complexe que la MCSS déjà proposée, et nécessite aussi un temps d'observation 33 fois plus petit pour détecter. Cette grande amélioration en complexité et en temps d'observation par rapport à la MCSS montre que la MS est plus résistante à un canal sévère comme le canal de Rayleigh que la MCSS.

	MCSS	MS
Complexité	$O(2 \cdot M \cdot n_s \cdot S \cdot \tilde{N})$	$O(M \cdot n_{tot} \cdot l \cdot \tilde{N})$
Nombre d'échantillons pour $(P_{fa}, P_d) = (0, 1; 0, 67)$	3362	100
$\text{Log}(\text{Nombre d'opération})$	7,41	5,88
information <i>a priori</i>	Méthode aveugle	Méthode aveugle

TABLE 4.4 – Comparaison du nombre d'échantillons et de la complexité entre la MS proposée et la MCSS pour exactement les mêmes performances $(P_{fa}, P_d) = (0, 1; 0, 91)$ avec un canal de Rayleigh.

B. Comparaison entre la MS et le détecteur de cyclostationarité

Dans cette sous section on compare la complexité et le temps d'observation de la MS, avec le détecteur de cyclostationarité de [2] dans les mêmes conditions. Pour cela on trace sur la figure 4.26 la probabilité de détection pour une fausse alarme fixée à 10%, en fonction du nombre d'échantillons utilisés pour faire la détection (le temps d'observation). Pour chacune des deux méthodes on distingue les deux cas : avec et sans canal de propagation (canal de Rayleigh de variance unitaire). Dans les deux cas un filtre à l'émission est utilisé pour être dans des conditions réalistes.

On peut observer que sans canal de propagation, pour atteindre une probabilité de détection égale à 0,95 avec une fausse alarme P_{fa} égale à 10% le détecteur de cyclostationarité a besoin de $N' = 3795$ échantillons et donc ≈ 830570 opérations sont nécessaires. D'autre part ≈ 1190400 opérations sont nécessaires pour la MS avec seulement un nombre total d'échantillons nécessaires $n_{tot} \cong 154$ pour atteindre les mêmes performances. On peut donc conclure que dans ces conditions la MS est un peu plus complexe que la méthode proposée par [2] (1,43 fois plus complexe) mais nécessite un temps d'observation nettement plus petit ($\approx 24,6$ fois plus petit) et ceci pour atteindre les mêmes performances tout en étant une méthode de détection aveugle.

La table 4.5 montre une comparaison entre les complexités (nombre d'opérations) et le nombre d'échantillons correspondants aux méthodes MS et du détecteur de cyclostationarité sans canal de propagation. On peut conclure que dans ces conditions ($RSB = 0$ dB, $P_d = 0,95$, $P_{fa} = 0,1$) la MS est environ 1,43 fois plus complexe que la méthode cyclostationnaire, et nécessite aussi un temps d'observation $\approx 24,6$ fois plus petit pour détecter. Cette amélioration notamment en temps d'observation de la MS par rapport au détecteur cyclostationnaire, résulte de l'exploitation de la propriété de symétrie de la FAC en plus de l'exploitation de sa propriété de parcimonie.

On peut observer sur la figure 4.26 que avec canal de Rayleigh, pour atteindre une probabilité de détection égale à 0,95 avec une fausse alarme P_{fa} égale à 10% la MS a besoin seulement de $n_{tot} = 196,9$ échantillons et donc $\approx 151 \times 10^4$ opérations sont nécessaires. D'autre part la méthode de cyclostationarité a besoin d'environ $n_{tot} \cong 4834$ échantillons pour atteindre les mêmes performances ($P_d = 0,95$, $P_{fa} = 0,1$) donc $\approx 104 \times 10^4$ opérations sont nécessaires pour la méthode de cyclostationarité. On peut donc




FIGURE 4.26 – La probabilité de détection P_d pour une fausse alarme fixée à 10% et un $RSB = 0$ dB, en fonction du nombre d'échantillons (temps d'observation) et ceci pour la MS et le détecteur de cyclostationarité. Deux cas sont considérés : avec et sans canal de propagation.

	MS	Détecteur Cyclostationnaire
Complexité	$O(n_{tot} \cdot M \cdot l \cdot \tilde{N})$	$O(M \cdot N' \cdot (L+1) + 4 \cdot M \cdot L^2)$
Nombre d'échantillons pour $(P_{fa}, P_d) = (0, 1; 0, 95)$	155	3795
$\text{Log}(\text{Nombre d'opération})$	6,07	5,91
information <i>a priori</i>	Méthode aveugle	$\alpha_f = \frac{1}{T_s}$

TABLE 4.5 – Comparaison du nombre d'échantillons et des complexités entre la MS proposée et le détecteur de cyclostationarité pour exactement les mêmes performances $(P_{fa}, P_d) = (0, 1; 0, 95)$ sans canal de propagation.

conclure que dans ces conditions ($P_d = 0,95$, $P_{fa} = 0,1$, $RSB = 0$ dB, canal de Rayleigh) la MS est légèrement plus complexe ($\cong 1,45$) que la méthode de cyclostationarité mais par contre elle nécessite un temps d'observation plus petit ($\approx 24,5$ fois plus petit) et ceci pour atteindre les mêmes performances.

La table 4.6 montre une comparaison entre les complexités (nombre d'opérations) et le nombre d'échantillons correspondants aux méthodes MS et de cyclostationarité avec canal de propagation.

C. Comparaison entre la MS, MCSS et le détecteur de cyclostationarité

La figure 4.27 montre la probabilité de détection pour une P_{fa} égal à 10% sous un RSB de 0 dB en fonction du nombre total d'échantillons pour les trois détecteurs (la

	MS	Détecteur Cyclostationnaire
Complexité	$O(M \cdot n_s \cdot l \cdot \tilde{N})$	$O(M \cdot N' \cdot (L+1) + 4 \cdot M \cdot L^2)$
Nombre d'échantillons pour $(P_{fa}, P_d) = (0, 1; 0, 95)$	196, 9	4834
$\text{Log}(\text{Nombre d'opération})$	6, 17	6, 01
information <i>a priori</i>	Méthode aveugle	$\alpha_f = \frac{1}{T_s}$

TABLE 4.6 – Comparaison du nombre d'échantillons et de la complexité entre la MS proposée et du détecteur de cyclostationarité pour exactement les mêmes performances $(P_{fa}, P_d) = (0, 1; 0, 95)$ avec un canal de Rayleigh.

MS, MCSS et le détecteur de cyclostationarité) dans les mêmes conditions en utilisant un filtre à l'émission. Il est clair que la MS dépasse les deux autres méthodes et que la MCSS dépasse le détecteur de cyclostationarité. Par exemple, pour une probabilité de détection égale à 90% la MS atteint un gain en temps d'observation égal à 12 par rapport à la MCSS, et un gain égal à 31 par rapport au détecteur de cyclostationarité.

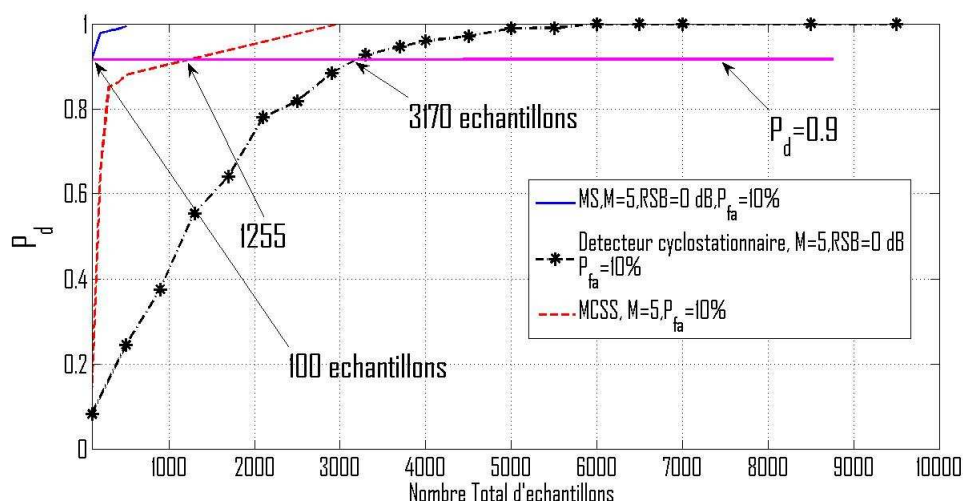


FIGURE 4.27 – La probabilité de détection P_d pour une fausse alarme fixée à 10% sous un $RSB = 0$ dB, en fonction du nombre d'échantillons (temps d'observation) en utilisant un filtrage à l'émission et ceci pour les méthodes MS, MCSS, et le détecteur de cyclostationarité.

4.2.3.8 Conclusion sur la MS

On conclut finalement que la MS est une méthode qui n'est pas plus complexe que la MCSS. Elle exploite, en plus de la propriété de parcimonie, la propriété de symétrie du VAC. Cette propriété supplémentaire exploitée (la symétrie) par la MS, laisse cette

dernière dépasser en performance le détecteur MCSS, qui dépasse à son tour le détecteur de cyclostationarité. Donc Finalement la MS dépasse à la fois les deux détecteurs, le MCSS et le détecteur de cyclostationarité. D'une manière équivalente la MS a besoin d'un temps d'observation plus petit que les autres méthodes de détections pour atteindre les mêmes performances. On note aussi que la MS est une méthode aveugle comme la MCSS à la différence du détecteur de cyclostationarité temporel de second ordre proposé dans [2]. De plus on montre que lorsqu'un filtrage est utilisé, les performances de la méthode MS s'améliorent contrairement au détecteur cyclostationnaire qui se dégrade.

4.3 Conclusion

La détection du spectre est soumise à des contraintes de temps. Pour cette raison dans ce chapitre on a proposé deux détecteurs aveugles qui nécessitent un petit temps d'observation et ayant une complexité relativement faible. Ces détecteurs aveugles utilisent l'estimateur (3.21) proposé dans le chapitre 3 se basant sur le *compressed sensing* afin d'estimer le VAC qui est un vecteur parcimonieux. Pour de faibles observations la version souple du premier détecteur (MCSS) dépasse en performance les performances du détecteur de cyclostationarité proposé dans [2] dans toutes les conditions de simulations.

On note que le gain en temps d'observation du détecteur MCSS par rapport au détecteur cyclostationnaire peut atteindre le rapport 10. Le second détecteur proposé (MS), exploite en plus de la parcimonie la propriété de symétrie du VAC aboutissant encore à de meilleures performances pour de faibles observations sans augmentation de la complexité comparée à la complexité de MCSS. On note que le gain en temps d'observation du détecteur MS par rapport au détecteur cyclostationnaire peut atteindre le rapport 30. De plus on montre que lorsqu'un filtrage est utilisé, les performances des méthodes MCSS et MS s'améliorent contrairement au détecteur cyclostationnaire qui ce dégrade.

Conclusions et Perspectives

Dans ce travail, nous avons abordé le problème de détection des bandes libres dans le contexte de la radio intelligente. Le but est de proposer des détecteurs qui sont utilisés par les terminaux des US qui leur permettent de détecter rapidement la présence des UP même à faible rapport signal à bruit, avec un minimum d'information *a priori* et une complexité minimale.

Nous avons proposé deux architectures de détections hybrides, qui combinent deux détecteurs complémentaires. Le premier détecteur est le radiomètre, son avantage est qu'il ne nécessite aucune information sur le signal à détecter d'une part, et qu'il est une méthode de détection à très faible complexité d'autre part. L'inconvénient du radiomètre est qu'il est très sensible à une mauvaise estimation du niveau du bruit, ce qui le rend moins utilisable dans le contexte de la radio intelligente. Quant au second détecteur utilisé, c'est le détecteur cyclostationnaire, qui a besoin d'une information *a priori* sur la fréquence cyclique du signal reçu et qui est plus complexe que le radiomètre mais plus résistant vis-à-vis d'une incertitude sur le niveau du bruit.

La première architecture corrige itérativement les seuils d'un radiomètre à double seuils, qui converge vers les performances du détecteur cyclostationnaire. La seconde architecture utilise le détecteur de cyclostationnarité afin d'estimer directement le niveau de bruit, qui est ensuite utilisé pour fixer le seuil du radiomètre. Ces architectures profitent des avantages de ces deux méthodes de détections à la fois pour aboutir à des architectures qui ont une complexité égale à celle du radiomètre avec des performances au moins égales à celle du détecteur de cyclostationnarité. A l'instant initial, la détection est partagée entre le radiomètre et le détecteur cyclostationnaire, puis avec le temps, cette détection tend vers un caractère énergétique. De plus on a montré aussi que les performances de ces architectures dépendent aussi de l'environnement, i.e. de $P(H_0)$ et $1 - P(H_0)$ dans la phase d'apprentissage avant de fixer les seuils du radiomètre à double seuils.

Il serait important d'étudier ces architectures hybrides dans le cas d'un niveau de bruit variable, et dans un contexte multi-antennes. De plus il serait aussi intéressant d'évaluer le temps de convergence de ces architectures en fonction de l'environnement. Enfin il serait aussi important d'étudier les performances de ces architectures avec un canal de propagation, avec et sans mobilité.

Dans la deuxième partie de ce travail, on a proposé un nouvel estimateur qui estime le vecteur d'autocorrelation cyclique du signal reçu. Ce nouvel estimateur utilise le *compressed sensing* pour faire son estimation. En effet il exploite la propriété de parcimonie du

vecteur d'autocorrelation cyclique sur les fréquences cycliques. On a défini deux métriques pour pouvoir évaluer la qualité d'estimation de cet estimateur. La première métrique calcule l'erreur quadratique moyenne entre le vecteur d'autocorrelation cyclique estimé et sa valeur théorique correspondante. La deuxième métrique calcule l'erreur quadratique moyenne sur la position de la fréquence cyclique estimée dans le vecteur d'autocorrelation cyclique. On utilise ces deux métriques afin de faire la comparaison de notre nouvel estimateur proposé avec l'estimateur classique non biaisé du vecteur d'autocorrelation cyclique.

Dans les différents cas de simulations, à l'émission sans filtrage, à l'émission avec filtrage, à la réception, et en utilisant un canal de propagation à la réception, notre nouvel estimateur a obtenu de meilleures performances d'estimation que l'estimateur classique non biaisé.

On note en plus que le nouvel estimateur proposé se basant sur le *compressed sensing* est un estimateur aveugle n'ayant pas besoin de la connaissance *a priori* de la valeur de la fréquence cyclique du signal reçu à l'opposition de l'estimateur classique non biaisé.

Dans le futur, il serait intéressant de calculer analytiquement l'expression de la Fonction d'Autocorrelation Cyclique (FAC) après l'introduction du filtrage à l'émission. De plus, il serait intéressant de calculer théoriquement les valeurs de ces nouvelles métriques pour les différents estimateurs en fonction du nombre d'échantillons et du RSB. Aussi, il serait intéressant de calculer l'expression analytique de la borne de Cramér-Rao de notre nouvel estimateur.

Dans le dernier chapitre de ce travail on a proposé deux types de détecteurs aveugles qui se basent sur notre nouvel estimateur du vecteur d'autocorrelation cyclique. Le premier détecteur, le MCSS prend deux slots consécutifs de mêmes tailles en supposant que ces deux slots appartiennent à la même hypothèse. Ensuite à partir de ces deux slots on estime en utilisant le nouvel estimateur aveugle les deux vecteurs d'autocorrelation cyclique correspondants. Ensuite en comparant ces deux vecteurs, si les fréquences cycliques qu'ils contiennent sont les mêmes on déclare que la bande est occupée, dans le cas contraire on la déclare libre car le bruit ne contient pas de fréquences cycliques. Le deuxième détecteur, le MS; en plus de sa propriété parcimonieuse, utilise la propriété de symétrie du vecteur d'autocorrelation cyclique. Le MS estime le vecteur d'autocorrelation cyclique avec le nouvel estimateur en utilisant l'Orthogonal Matching Pursuit (OMP). Finalement si le vecteur estimé présente une symétrie autour de l'axe $\alpha = 0$, la bande est déclarée occupée.

Pour un faible nombre d'échantillons, les performances du MCSS, ont dépassées celles du détecteur (qui est non aveugle) temporel du second ordre proposé dans [2] et ceci dans toutes les conditions de simulations (avec filtrage, et avec canal de propagation). Aussi pour une même performance de détection le MCSS peut atteindre un temps d'observation 10 fois plus petit que celui de [2] avec une complexité légèrement supérieure. Pour le MS, pour un faible nombre d'échantillons, on a montré qu'il n'est pas plus complexe que le MCSS. De plus le MS dépasse en performance le MCSS (donc aussi dépasse le détecteur de [2]) et ceci dans toutes les conditions de simulations. Les meilleures performances du MS

par rapport au MCSS sont dues à l'utilisation de la propriété de symétrie qui est utilisée comme information *a priori* supplémentaire par le MS. On a vu que le MS peut atteindre un gain en temps d'observation égal à 30 par rapport au détecteur cyclostationnaire [2].

On a aussi montré qu'avec filtrage, les performances des détecteurs, MS et MCSS s'améliorent, contrairement au détecteur cyclostationnaire. Les détecteurs MS et MCSS ont donc encore plus d'intérêt dans des cas réalistes.

Dans ce chapitre, nous nous sommes concentrés à l'évaluation du temps d'observation dans différents environnements de simulations et à l'analyse de la complexité des nouvelles méthodes aveugles proposées. Dans les prochains travaux, il serait utile de trouver des expressions explicites des seuils de détection en fonction de la probabilité de fausse alarme souhaitée. De plus il serait très important d'implémenter ces architectures et de les tester sur des signaux réels afin d'évaluer la consommation de ces détecteurs et de comparer leurs temps d'exécution total (qui est égal au temps de calcul plus le temps d'observation), avec le temps d'exécution total du détecteur cyclostationnaire. Aussi, il serait intéressant d'étudier ces nouveaux détecteurs dans un contexte MIMO en utilisant plusieurs antennes par détecteur secondaire. Également l'aspect collaboratif utilisant ces nouveaux détecteurs doit aussi être étudié. Il serait aussi utile dans le future de proposer de nouveaux algorithmes de détection, basés sur le nouvel estimateur du chapitre 3.

Annexe

Annexe A

Annexe relative au chapitre 1

A.1 Le Standard IEEE 802.22

Le standard IEEE 802.22 [149, 150] est connu en tant que *le standard de la radio intelligente* en raison des caractéristiques intelligentes qu'il contient. La norme est encore en cours de développement. Le groupe de travail IEEE 802.22 travaille sur le développement des couches physiques (PHY) et *medium access control* (MAC) du réseau régional *wireless regional area network* (WRAN) à l'usage des dispositifs exempts de licence dans le spectre qui sont actuellement affectés à la télévision numérique (TV).

Le projet actuel du 802.22 est fondé sur la modulation OFDMA pour les liaisons ascendantes et descendantes avec quelques améliorations technologiques. Les réseaux WRAN sont caractérisés par de longs retards de propagations (de $25\mu s$ allant à $50\mu s$) dans les régions métropolitaines. Cela requiert l'utilisation d'un préfixe cyclique de l'ordre de $40\mu s$. Afin de réduire l'impact de l'entête dû au cyclique préfixe, environ 2K sous porteuses sont utilisées dans un canal TV. Le standard 802.22 doit également fournir une grande flexibilité en termes de modulation et de codage, en effet, l'OFDMA répond parfaitement à ces exigences comme elle permet une répartition efficace des sous-porteuses. Une proposition consiste à diviser les sous-porteuses à 48 sous-canaux. Les régimes de modulation sont QPSK, 16-QAM, 64 QAM avec un taux de codage égal à $\frac{1}{2}, \frac{3}{4}, \frac{2}{3}$. Il en résulte un débit de données qui commence à partir de quelques kbit/s par sous canal jusqu'à 19 Mbit/s pour chaque chaîne TV, offrant suffisamment de flexibilité.

L'une des caractéristiques les plus distinctives de la norme IEEE 802.22 est la nécessité d'utiliser la détection du spectre [15]. Les dispositifs IEEE 802.22 WRAN performant la détection sur les canaux TV, et identifient la possibilité de transmission. Les exigences fonctionnelles du standard nécessitent au moins une probabilité de détections de 90% et au plus une probabilité de fausses alarmes de 10% pour les signaux TV avec un niveau de puissance de 116 dBm ou au-dessus [151].

La détection est prévue pour être sur deux étapes : détection rapide et détection fine [152]. Dans la phase de détection rapide, un algorithme de détection grossière est utilisé, par exemple, le détecteur d'énergie. L'étape de détection fine est déclenchée sur la base des résultats de la détection rapide. La détection fine implique une analyse plus détaillée

de détection où des méthodes plus puissantes sont utilisées. Plusieurs techniques qui ont été proposées sont incluses dans le projet de la norme comprenant la détection d'énergie, détection de forme d'ondes, détection des caractéristiques cyclostationnaires et le filtrage adapté. Une station de base (SB) peut répartir la charge de détection entre les stations d'abonnés (SS) ou US. Les résultats sont retournés à la SB qui utilise ces résultats pour la gestion des transmissions. Par conséquent, c'est un exemple concret de collaboration centralisée introduite dans le Chapitre 1.

Une autre approche pour la gestion du spectre dans la norme IEEE 802.22 est basée sur un système centralisé. Les stations de base seraient équipées d'un système de positionnement (GPS) qui permettrait à ces positions d'être signalées. Les informations de localisation pourraient alors être utilisées pour obtenir des informations sur les canaux de télévision disponibles par un serveur central.

Annexe B

Annexe relative au chapitre 2

B.1 Test statistique de présence de la cyclostationnarité de Dandawaté-Giannakis

Soient $x(k)$ un processus aléatoire à temps discret et de moyenne nulle, et α une fréquence quelconque. Le test proposée par Dandawaté-Giannakis [2] permet de vérifier si $x(k)$ est cyclostationnaire à la fréquence α . ceci est équivalent à résoudre le test d'hypothèses suivant :

$$\begin{aligned} H_0 & R_{xx}(\alpha, \tau) = 0 \quad \forall \tau \\ H_1 & R_{xx}(\alpha, \tau) \neq 0 \quad \text{pour quelques valeurs de } \tau \end{aligned} \quad (\text{B.1})$$

avec H_0 est l'hypothèse nulle correspondant à un processus $x(k)$ non cyclostationnaire sur α et H_1 est l'hypothèse alternative correspondant à un processus $x(k)$ cyclostationnaire sur α .

Afin d'estimer la FAC $R_{xx}(\alpha, \tau)$, les auteurs utilisent l'estimateur non biaisé suivant :

$$\hat{R}_{xx}^{(T)}(\alpha, \tau) = \frac{1}{T} \sum_{k=0}^{T-1} x(kT_e)x(kT_e + \tau)e^{-j\alpha kT_e} \quad (\text{B.2})$$

En outre, ont établi que cet estimateur suit une loi asymptotiquement gaussienne dont les covariances sont données par :

$$\lim_{T \rightarrow \infty} T \text{cov}\{\hat{R}_{xx}^{(T)}(\alpha, \tau), \hat{R}_{xx}^{(T)}(\alpha, \rho)\} = S_{2f_{\tau, \rho}}(2\alpha; \alpha) \quad (\text{B.3})$$

$$\lim_{T \rightarrow \infty} T \text{cov}\{\hat{R}_{xx}^{(T)}(\alpha, \tau), \hat{R}_{xx}^{*(T)}(\alpha, \rho)\} = S_{2f_{\tau, \rho}}^{(*)}(0; -\alpha) \quad (\text{B.4})$$

avec

$$S_{2f_{\tau, \rho}}(\alpha; \omega) \triangleq \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{k=0}^{T-1} \sum_{\xi=-\infty}^{\infty} \text{cov}\{f(kT_e; \tau), f(kT_e + \xi; \rho)\} e^{-j\omega\xi} e^{-j\alpha kT_e} \quad (\text{B.5})$$

$$S_{2f_{\tau, \rho}}^{(*)}(\alpha; \omega) \triangleq \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{k=0}^{T-1} \sum_{\xi=-\infty}^{\infty} \text{cov}\{f(kT_e; \tau), f^*(kT_e + \xi; \rho)\} e^{-j\omega\xi} e^{-j\alpha kT_e} \quad (\text{B.6})$$

et

$$f(k; \tau) \triangleq x(k)x(k + \tau) \quad (\text{B.7})$$

On peut interpréter $S_{2f_{\tau,\rho}}(\cdot; \cdot)$ et $S_{2f_{\tau,\rho}}^{(*)}(\cdot; \cdot)$ comme des « intercorrélations spectrales » d'ordre 2 du processus $f(k; \tau)$.

Soit $F_{T,\tau}(\omega) = \sum_{k=0}^{T-1} x(kT_e)x(kT_e+\tau)e^{-j\omega kT_e}$. Des estimateurs convergents de $S_{2f_{\tau,\rho}}(2\alpha; \alpha)$ et $S_{2f_{\tau,\rho}}^{(*)}(0; -\alpha)$ sont données par :

$$\hat{S}_{2f_{\tau,\rho}}^{(T)}(2\alpha; \alpha) = \frac{1}{TL} \sum_{s=-(L-1)/2}^{(L-1)/2} W^{(T)}(s) \times F_{T,\tau} \left(\alpha - \frac{2\pi s}{T} \right) F_{T,\rho} \left(\alpha + \frac{2\pi s}{T} \right) \quad (\text{B.8})$$

$$\hat{S}_{2f_{\tau,\rho}}^{(*T)}(0; -\alpha) = \frac{1}{TL} \sum_{s=-(L-1)/2}^{(L-1)/2} W^{(T)}(s) \times F_{T,\tau}^* \left(\alpha + \frac{2\pi s}{T} \right) F_{T,\rho} \left(\alpha + \frac{2\pi s}{T} \right) \quad (\text{B.9})$$

avec $W^{(T)}$, une fenêtre de pondération spectrale de largeur L impaire.

Algorithme

1. Calculer le vecteur $\hat{\mathbf{r}}_{xx}$ donné par :

$$\hat{\mathbf{r}}_{xx} = [\Re\{\hat{R}_{xx}^{(T)}(\alpha, \tau_1)\}, \dots, \Re\{\hat{R}_{xx}^{(T)}(\alpha, \tau_N)\}, \Im\{\hat{R}_{xx}^{(T)}(\alpha, \tau_1)\}, \dots, \Im\{\hat{R}_{xx}^{(T)}(\alpha, \tau_N)\}]$$

2. Calculer la matrice de covariance Σ du vecteur $\hat{\mathbf{r}}_{xx}$ donnée par :

$$\Sigma = \begin{pmatrix} \Re\left\{\frac{Q+Q^{(*)}}{2}\right\} & \Im\left\{\frac{Q-Q^{(*)}}{2}\right\} \\ \Im\left\{\frac{Q+Q^{(*)}}{2}\right\} & \Re\left\{\frac{Q^{(*)}-Q}{2}\right\} \end{pmatrix}$$

avec

$$\begin{aligned} Q(m, n) &= S_{2f_{\tau,\rho}}(2\alpha; \alpha) \\ Q^{(*)}(m, n) &= S_{2f_{\tau,\rho}}^{(*)}(0; -\alpha) \end{aligned}$$

3. Calculer la statistique de test suivante :

$$\mathcal{Z}_G = T \hat{\mathbf{r}}_{xx} \Sigma^{-1} \hat{\mathbf{r}}_{xx}^T$$

avec $\hat{\mathbf{r}}_{xx}^T$, le vecteur transposé de $\hat{\mathbf{r}}_{xx}$.

Cette statistique suit une loi du chi-deux à $2N$ degrés de libertés (χ_{2N}^2) centrée lorsque α est une fréquence cyclique et non centrée sinon.

4. Pour une probabilité de fausse alarme désirée $P_{fa,des}$ donnée, calculer le seuil de détection ξ_G tel que $P_{fa,des} = P\{\chi_{2N}^2 \geq \xi_G\}$.
5. Déclarer que la fréquence α est cyclique si $\mathcal{Z}_G \geq \xi_G$. Autrement, déclarer que α n'est pas une fréquence cyclique.

B.2 Démonstration que l'estimateur (3.13) est non biaisé

On rappelle l'estimateur donné par l'équation (3.13) :

$$\hat{R}_{xx}^{(N)}(\alpha, \tau) \cong \frac{1}{N} \sum_{k=0}^{N-1} x(kT_e)x(kT_e + \tau)e^{-j2\pi\alpha kT_e} \quad (\text{B.10})$$

sachant que pour un processus $x(k)$ à temps discret, $R_{xx}(\alpha, \tau)$ s'écrit :

$$R_{xx}(\alpha, \tau) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=0}^{N-1} r_{xx}(k, \tau)e^{-j2\pi\alpha kT_e} \quad (\text{B.11})$$

Il est simple de montrer que l'estimateur (3.13) est non biaisé. En effet à partir de (B.10) et (B.11) on peut écrire :

$$\begin{aligned} \lim_{N \rightarrow \infty} E\{\hat{R}_{xx}^{(N)}(\alpha, \tau)\} &= \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=0}^{N-1} E\{x(kT_e)x(kT_e + \tau)e^{-j2\pi\alpha kT_e}\} \\ &= \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{k=0}^{N-1} r_{xx}(k, \tau)e^{-j2\pi\alpha kT_e} \\ &= R_{xx}(\alpha, \tau) \end{aligned}$$

Annexe C

Annexe relative au chapitre 3

C.1 Modèle du canal de propagation

Cette section s'occupera de décrire un peu plus en détail, notamment en donnant les coefficients, la réponse en amplitude et en phase, ainsi que les zéros qui représentent souvent mieux la sévérité du canal utilisé dans les simulations du chapitre 3.

Une façon de représenter la réponse impulsionnelle d'un canal à trajets multiples, est par un nombre discret d'impulsions comme suit :

$$c(t, \tau) = \sum_{i=1}^l a_i(t) \delta(\tau - \tau_i) \quad (\text{C.1})$$

ou $a_i(t)$ est l'atténuation à l'instant t du trajet i , et τ_i représente le retard du trajet i . Pour un canal invariant dans le temps cette réponse s'écrit :

$$c(\tau) = \sum_{i=1}^l a_i \delta(\tau - \tau_i) \quad (\text{C.2})$$

avec les coefficients a_i invariant dans le temps. Dans nos simulations les retards et les atténuations (coefficients a_i) utiliser sont donnés dans la table (C.1). D'après la table

Trajet	1	2	3	4	5	6
Atténuation en dB	0	-1	-9	-10	-15	-20
Retard en T_e	0	4	6	8	14	20

TABLE C.1 – Atténuation et retard des trajets du canal h

(C.1) on peut en déduire la réponse impulsionnelle du canal qui donnée par :

$$C(z) = 1 + 0.79 \cdot z^{-4} + 0.12 \cdot z^{-6} + 0.1 \cdot z^{-8} + 0.03 \cdot z^{-14} + 0.01 \cdot z^{-20} \quad (\text{C.3})$$

Sur la figure C.1 on trace la réponse impulsionnelle du canal. Le module et la phase du canal sont donnés par la figure C.2, on observe que malgré ses coefficients réels, la phase n'est pas linéaire et 2 évanouissements sont à déplorer en milieu de bande, sur la figure C.3 on trace la carte des pôles et des zéros de $C(z)$, on observe 20 zéros à l'intérieur du cercle unité et un pôle à l'origine.




FIGURE C.1 – La réponse impulsionnelle du canal $c(\tau)$ utilisé.


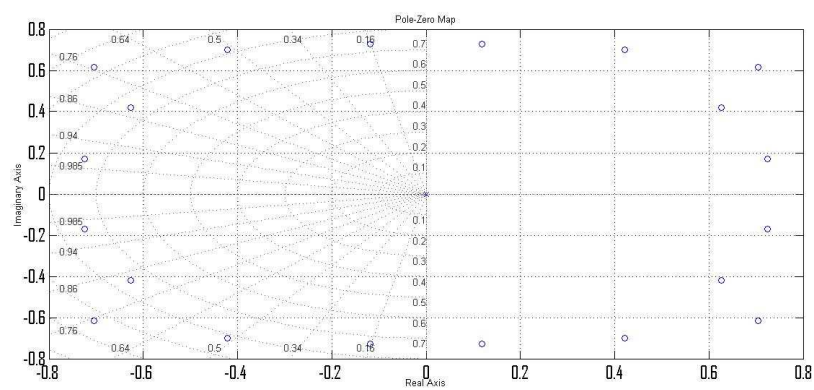


FIGURE C.2 – Le module et la phase du canal $c(\tau)$ utilisé.

FIGURE C.3 – La carte des pôles et des zéros de $C(z)$.

Notations et abréviations

Notations

i.i.d.	indépendants et identiquement distribués
v.a.	variable aléatoire
N_0	la densité spectrale de puissance mono-latérale du bruit blanc Gaussien
$r_{xx}(t, \tau)$	fonction d'autocorrélation variant dans le temps
$R_{xx}(\alpha, \tau)$	fonction d'autocorrélation cyclique
$S_{xx}(t, f)$	densité spectrale instantanée
$\tilde{S}_{xx}(\alpha, f)$	fonction de corrélation spectrale
\mathcal{A}_α	ensemble des fréquences cycliques
$F\{\cdot\}$	transformée de Fourier
$F^{-1}\{\cdot\}$	transformée de Fourier inverse
$F/\tau\{\cdot\}$	transformée de Fourier par rapport à τ
$\bar{\mathbf{x}}$	transformée de Fourier de \mathbf{x}
$\Re\{\cdot\}$	partie réelle
$\Im\{\cdot\}$	partie imaginaire
$\langle \cdot, \cdot \rangle$	produit scalaire
$\langle \cdot \rangle_t$	moyenne temporelle
$E\{\cdot\}$	moyenne statistique
$cov\{\cdot\}$	covariance
$cum\{\cdot\}$	cumulant
$P(r)$	probabilité de r
$p(r)$	densité de probabilité de r
$F(r)$	fonction de répartition de la densité $p(r)$
P_d	probabilité de détection
P_m	probabilité de non-détection
P_{fa}	probabilité de fausse alarme
$P_{fa,des}$	probabilité de fausse alarme désirée
$P_{fa,ef}$	probabilité de fausse alarme effective
$\mathcal{N}(\mu, \sigma)$	la loi de distribution normale de moyenne μ et de variance σ
χ_n^2	la loi de distribution chi-deux à n degrés de liberté
$\chi_n^2(\gamma)$	la loi de distribution χ_n^2 non centrée de coefficient de décentrage γ
$\stackrel{m.g.}{\underset{=}{\triangle}}$	convergence en moyenne quadratique
\triangleq	par définition

\mathbb{N}	ensemble des entiers naturels
\mathbb{N}^*	ensemble des entiers naturels non nuls
\mathbb{Z}	ensemble des entiers relatifs
\mathbb{Z}^*	ensemble des entiers relatifs non nuls
\mathbb{R}^*	ensemble des nombres réels
\mathbb{C}	ensemble des nombres complexes
$x(t)$	le signal à l'émission
$y(t)$	le signal reçu
$b(t)$	le bruit qui est supposé être blanc gaussien sauf indication contraire
\mathbf{H}	la matrice canal
$C(\cdot)$	la transformation linéaire correspondante au canal
σ^2	la variance du bruit

Abréviations

AC	Autocorrélation Cyclique
AIC	Akaike Information Criterion
AWGN	Bruit additif Gaussien blanc (Additive White Gaussian Noise)
BP	Basis Pursuit
BPc	Bande Passante du canal
BPSK	Binary Phase Shift Keying
CAF	Cyclic Autocorrelation Function
CAV	Cyclic Autocorrelation Vector
CDMA	Code Division Multiple Access
COR	Caractéristiques Opérationnelles du Récepteur
CR	Cognitive Radio
CWN	Cognitive Wireless Networks
DFT	Discrete Fourier Transform
DS-CDMA	Direct Sequence CDMA
DSA	Dynamic Spectrum Access
DSP	Densité Spectrale de Puissance
DVB-T	Digital Video Broadcasting Terrestrial
ED	Energy Detector
EEG	Electroencephalography
EGC	Equal Gain Combining
EM	Expectation-Maximisation
EQM	Erreur Quadratique Moyenne
EQM_{α_f}	Erreur Quadratique Moyenne sur l'estimation de la fréquence cyclique α_f
FAC	Fonction d'Autocorrélation Cyclique
FBMC	Filter Bank based MultiCarrier
FCC	Federal Communications Commission
FCS	Fonction de Corrélation Spectrale
FFT	Fast Fourier Transform
GLRT	Generalised Likelihood Ratio Test
GPS	Global Positioning System
GSM	Global System for Mobile communications
IDFT	Inverse Discrete Fourier Transform
IFFT	Inverse Fast Fourier Transform
ITC	Information Theoretic Criteria
LARS	Least Angle Regression
LASSO	Least Absolute Shrinkage and Selection Operator
LBT	Listen-Before-Talk
LRT	Likelihood Ratio Test
MAC	Media Access Control
MDL	Minimum Description Length
MDP2	Modulation par Déplacement de Phase à deux états
MDP4	Modulation par Déplacement de Phase quatre états
MIMO	Multiple Input Multiple Output
MP	Matching Pursuit

OFDM	Orthogonal Frequency Division Multiplexing
OMP	Orthogonal Matching Pursuit
OQAM	Offset Quadrature Amplitude Modulation
PDF	Probability Density Function
PFB	Polyphase Filter Bank
PIC	Pilot Induced Cyclostationarity
PSE	Periodogram Spectrum Estimator
PSW	Prolate Sequence Window
RBF	Radial Basis Function
RF	Radio Fréquence
RI	Radio Intelligente
RIP	Restricted Isometry Property (Propriété d'isométrie restreinte)
RO	Radio Opportuniste
ROC	Receiver Operational Characteristic
RSB	Rapport Signal à Bruit
SB	Station de Base
TV	Télévision
UMTS	Universal Mobile Telecommunications System
UP	Utilisateur Primaire
US	Utilisateur Secondaire
VAC	Vecteur d'Autocorrelation Cyclique
WARC	World Administrative Radio Conference
WIMAX	Worldwide Interoperability for Microwave Access
WRAN	Wireless Regional Area Network

Matrices, et normes

Symboles en gras et minuscules	Vecteurs e.g. \mathbf{v}
Symboles en gras et majuscules	Matrices e.g. \mathbf{M}
$\mathbf{M}(i, j)$	Composante (i, j) d'une matrice \mathbf{M}
$\det(\mathbf{M})$	Déterminant d'une matrice \mathbf{M}
$\text{rang}(\mathbf{M})$	Rang d'une matrice \mathbf{M}
\mathbf{M}^*	le conjuguée de \mathbf{M}
\mathbf{M}^T	la transposée \mathbf{M}
\mathbf{M}^+	Pseudo-inverse de \mathbf{M}
\mathbf{I}_n	Matrice identité de dimension n
\mathbf{F}	Matrice de Fourier
$\ \cdot\ _p$	$p \geq 1$, norme ℓ_p d'un vecteur

Table des figures

1.1	La classification des méthodes de détections utilisée dans l'état de l'art de ce chapitre	10
1.2	Exemple de courbe ROC montrant la probabilité de détection P_d en fonction de la probabilité de fausse alarme P_{fa}	13
1.3	Les relations de transformées de Fourier entre les différentes fonctions de corrélations et de spectres en temporel et fréquentiel	21
1.4	Module théorique de la FCS d'un signal linéairement modulé définie en (1.39) avec une mise en forme des symboles de types rectangulaires . . .	22
1.5	Module théorique de la FAC d'un signal linéairement modulé définie en (1.39) avec une mise en forme de symboles de types rectangulaires	23
1.6	AIC d'un slot temporelle UMTS occupé : $q = 300$. Figure extraite de [38].	25
1.7	AIC d'un slot temporelle UMTS vacant : $p = 1000$. Figure extraite de [38].	26
1.8	L'architecture de base de détection multi-bandes	28
1.9	Quelques ondelettes courantes : (a) l'ondelette de Coiflet (b) l'ondelette de Daubechies (c) l'ondelette de Morlet et (d) Mexican hat ou l'ondelette de Paul. Figure extraite de [47].	29
1.10	N bandes de fréquences avec une DSP lisse par morceaux. Figure extraite de [44]	30
1.11	Génération de signatures cyclostationnaires par répétition des symboles. Figure extraite de [43]	37
1.12	Scénario de détections collaboratives avec RX_1, RX_2, \dots, RX_K le réseau secondaire. Figure extraite de [19], avec l'accord de l'auteur.	40
1.13	Le support de la loi Marchenko-Pastur sous H_0 . Figure extraite de [94], avec l'accord de l'auteur.	41
1.14	Le support de la loi Marchenko-Pastur sous H_1 . Figure extraite de [94], avec l'accord de l'auteur.	42
2.1	Schéma bloc du détecteur d'énergie.	48
2.2	La variation du rapport signal à bruit minimal RSB_m en fonction du produit BT , lorsque le niveau de bruit N_0 est parfaitement connu. On note que RSB_m diminue linéairement avec l'augmentation du produit BT	50
2.3	Erreur de décision dans le cas d'une sous-estimation du niveau du bruit N_0 . Dans ce cas il en résulte la déclaration d'une bande occupée alors qu'elle est libre, provoquant une augmentation de la probabilité de fausse alarme.	51

2.4	Erreur de décision dans le cas d'une surestimation du niveau du bruit N_0 . Dans ce cas la bande testée est déclarée libre, alors qu'elle est occupée, provoquant ainsi des interférences sur les UP.	51
2.5	Lorsque la valeur de U est différente de zéro (la présence d'incertitude), la valeur de RSB_m diminue avec l'augmentation du produit BT , et tend asymptotiquement vers sa limite $U - 1$	53
2.6	Comparaison des performances du test proposé (TPC) et d'un deuxième test donné dans [2]. Le signal détecté utilise une forme d'onde rectangulaire des symboles de données. Figure extraite de [30] avec l'accord de l'auteur.	59
2.7	Comparaison des performances du test proposé (TPC) et d'un deuxième test donné dans [2]. Le signal détecté utilise une forme d'onde du type cosinus-surélevé. Figure extraite de [30] avec l'accord de l'auteur.	60
2.8	Architecture de détection hybride des bandes libres	62
2.9	La règle de décision de l'architecture HSD	63
2.10	Organigramme de l'architecture HSD	64
2.11	Les variations de la densité de probabilité de ξ_1 (resp. ξ_2) sous H_0 (resp. H_1) pour différents nombres d'itérations à $RSB = 0$ dB, tracées à l'aide de (2.51) (resp. (2.52)).	66
2.12	L'esperance de ξ_1 (resp. ξ_2) sous H_0 (resp. H_1) en fonction du nombre d'itérations n à 0 dB, tracées à l'aide de (2.51) (resp. (2.52)).	66
2.13	L'esperance de ξ_1 (resp. ξ_2) sous H_0 (resp. H_1) en fonction du nombre d'itérations n à -10 dB, tracées à l'aide de (2.51) (resp. (2.52)). Nous pouvons observer que ξ_2 devient inférieur à ξ_1 après un certain nombre d'itérations sous faible RSB.	67
2.14	La variation de ξ_1 et ξ_2 à -5 dB en utilisant l'HSD, avec $N_1 = 30$, et $N_2 = 30$. Chaque marque sur les courbes indique une modification de ξ_1 ou ξ_2 . On peut remarquer que le test cyclostationnaire est de moins en moins utilisé, quand le nombre d'itérations augmente, induisant une plus faible complexité.	68
2.15	Probabilité de détection simulée en fonction du RSB, de l'architecture HSD (avec $N_1 = N_2 = 30$), pour une $P_{fa,des}$ fixée à 1%, comparées aussi au test cyclostationnaire et au radiomètre théorique dans les mêmes conditions.	69
2.16	L'organigramme de l'EHSD.	71
2.17	L'approximation théorique de l'erreur relative sur le seuil ξ_0 en fonction du RSB, obtenue en simulant (2.61) pour $\gamma = 1$	73
2.18	Probabilité de détection simulée en fonction du RSB, des architectures HSD (avec $N_1 = N_2 = 30$), et EHSD (avec $N_1 = 100$, et $N_2 = 30$) pour une $P_{fa,des}$ fixée à 1%, comparées aussi, au test cyclostationnaire et au radiomètre sans et avec incertitude, dans les mêmes conditions.	74
2.19	Résultat de simulation de l'erreur relative sur le seuil estimé $\hat{\xi}_0$ en fonction du RSB en utilisant l'algorithme EHSD, comparée par rapport à l'approximation théorique donnée dans (2.61) pour $\gamma = 1$	74

2.20	Les distributions de la v.a. X sous les deux hypothèses H_0 et H_1 obtenues en utilisant (2.3) à -8 dB. On constate que dans cette situation $\hat{\xi}_0$ est situé sur la queue de la densité de X sous H_1 , c'est pourquoi nous pouvons encore obtenir de bonnes performances de détection, même si l'erreur d'estimation sur $\hat{\xi}_0$ est maximale.	75
2.21	La probabilité de détection simulée sous différents RSB, pour l'HSD avec $P_{fa,des}$ fixé à 1% en utilisant $\gamma = 99$ et $\gamma = 0,01$, également comparé par rapport au test de Dandawaté et Giannakis dans les mêmes conditions. .	76
2.22	La probabilité de détection simulée en fonction du RSB de l'EHSd avec $P_{fa,des}$ fixée à 1% pour $\gamma = 99$ et $\gamma = 0,01$, également comparé par rapport au radiomètre théorique dans les mêmes conditions.	77
2.23	Les courbes de ROC de l'HSD et de l'EHSd à -5 dB, pour $\gamma = 1$. Nous observons dans ces conditions que l'HSD et l'EHSd présentent les mêmes performances.	78
2.24	Les courbes de ROC de l'HSD et de l'EHSd à -10 dB, pour $\gamma = 1$. On observe que, dans ces conditions l'EHSd présente de meilleures performances de détection par rapport à l'HSD.	78
3.1	La norme théorique de la fonction d'autocorrélation cyclique d'une BPSK.	84
3.2	La norme du VAC d'un signal modulé en utilisant une MDP2, avec une fréquence cyclique fondamentale $\alpha_f = \frac{1}{T_s} = 10^4$ Hz et $\tau_0 = 3 \cdot T_e$, obtenue en utilisant (3.14), aussi comparée à la courbe théorique (3.11) et à la norme du VAC obtenue après résolution en utilisant l'estimateur (3.21). Pour les deux estimateurs, (3.14) et (3.21), 1000 échantillons ont été utilisés.	87
3.3	Une version agrandie de la figure 3.2, afin de montrer clairement le bruit d'estimation quand l'estimateur (3.14) est utilisé.	88
3.4	Les courbes de l'EQM obtenues avec l'estimateur (3.14) et la méthode du <i>compressed sensing</i> en fonction du nombre d'échantillon.	89
3.5	l'EQM en fonction du nombre d'essais pour les deux méthodes et pour 300 échantillons.	90
3.6	l'EQM en fonction du pas de résolution δ_α	91
3.7	Le VAC obtenue avec (3.14) avec et sans filtrage. Il est notable que le filtrage augmente le bruit d'estimation et enlève les harmoniques de la fréquence cyclique fondamentale.	92
3.8	La norme du VAC (obtenue avec 2500 échantillons) obtenue en utilisant (3.21) avec et sans filtrage à l'émission.	92
3.9	La norme du VAC (centrée autour de $\alpha = \frac{1}{T_s}$) obtenue en utilisant (3.21) avec filtrage à l'émission et en utilisant 300 échantillons.	93
3.10	Les courbes de l'EQM obtenues avec l'estimateur (3.14) et la méthode du <i>compressed sensing</i> en utilisant un filtre en racine de Nyquist à l'émission pour les deux méthodes.	94
3.11	Les courbes de l'EQM obtenues en utilisant la méthode du <i>compressed sensing</i> avec et sans filtrage à l'émission.	94
3.12	Les courbes de l'EQM obtenues en utilisant l'estimateur (3.14), avec et sans filtrage à l'émission.	95
3.13	l'EQM à la réception en fonction du RSB pour les deux méthodes en utilisant 300 échantillons.	95

3.14	Les courbes de l' EQM à la réception avec un canal de propagation pour les deux estimateurs (3.14) et (3.21)	96
3.15	Illustration de l'estimation de la fréquence cyclique $\hat{\alpha}_f$, qui est obtenue en prenant l'abscisse de la valeur maximale du VAC en appliquant l'estimateur classique (3.14) sur I'_{ALPHA} . On note que dans cette illustration l'estimation n'est pas idéale car la valeur obtenue avec l'estimation n'est pas la même que la valeur théorique.	98
3.16	Les courbes de l' EQM_{α_f} obtenues avec l'estimateur (3.14) et la méthode du <i>compressed sensing</i> en fonction du nombre d'échantillons.	99
3.17	Les courbes de l' EQM_{α_f} obtenues avec l'estimateur (3.14) et la méthode du <i>compressed sensing</i> pour 150 échantillons en fonction du RSB	100
3.18	Les courbes de l' EQM_{α_f} en fonction du nombre d'échantillon obtenues avec l'estimateur (3.14) et la méthode du <i>compressed sensing</i> , en utilisant un filtrage à l'émission.	101
3.19	Les courbes de l' EQM_{α_f} obtenues avec l'estimateur (3.14) et la méthode du <i>compressed sensing</i> pour 1000 échantillons en fonction du RSB en utilisant un filtrage à l'émission.	101
3.20	Les courbes de l' EQM_{α_f} obtenues avec l'estimateur (3.14) et la méthode du <i>compressed sensing</i> pour 1000 échantillons en fonction du RSB en utilisant un filtrage à l'émission et après convolution avec le canal $c(\tau)$	102
4.1	L'organigramme de la Méthode de Comparaison des Slots : MCS.	106
4.2	Les courbes de ROC de la MCS pour différentes valeurs de M et pour un $RSB = 0$ dB avec un nombre total d'échantillons égal à 400. On remarque que les performances de détection s'améliorent avec l'augmentation du nombre de retard M	107
4.3	L'organigramme de la Méthode de Comparaison des Slots version Soft : MCSS.	109
4.4	Les courbes de ROC de la MCS et de la MCSS, pour un nombre total d'échantillons égal à 400 et un $RSB = 0$ dB. On observe de meilleures performances de la MCSS par rapport à la MCS.	110
4.5	Les courbes de ROC du détecteur cylostationnaire comparé à la MCSS. Pour les deux cas un nombre total d'échantillons utilisés est égal à 400 et le RSB est égal à 0 dB. On observe de meilleures performances pour la MCSS.	110
4.6	Allure fréquentielle du filtre en cosinus surélevé pour différentes valeurs du facteur de retombée	111
4.7	Les courbes de ROC du détecteur cylostationnaire avec et sans filtrage à l'émission. Pour les deux cas un nombre total d'échantillons utilisés est égal à 400 et le RSB utilisé est égal à 0 dB	111
4.8	Les courbes de ROC de la MCSS avec et sans filtrage. Pour les deux cas un nombre total d'échantillons utilisés est égal à 400 et le RSB est égal à 0 dB. On observe de meilleures performances pour la MCSS dans le cas ou un filtre à l'émission est utilisé.	112

4.9	Les courbes de ROC de la MCSS et du détecteur cyclostationnaire, avec et sans filtrage. Pour les quatre cas un nombre total d'échantillons utilisés est égal à 400 et le RSB est égal à 0 dB. On observe de meilleures performances pour la MCSS dans le cas où un filtre à l'émission est utilisé, par contre une dégradation des performances de la méthode cyclostationnaire due au filtrage est observée.	113
4.10	La densité de probabilité obtenue par simulation (3000 essais) de la distribution des 3 premiers atomes choisis parmi initialement 4000 atomes sous H_1 et un $RSB = 0$ dB, sans l'utilisation d'un filtrage à l'émission.	114
4.11	La densité de probabilité obtenue par simulation (3000 essais) de la distribution des 3 premiers atomes choisis parmi initialement 4000 atomes sous H_1 et un $RSB = 0$ dB, avec l'utilisation d'un filtrage à l'émission.	114
4.12	La fonction de repartitions de la densité de probabilité de la distribution des 3 premiers atomes sous H_1 et un $RSB = 0$ dB sans l'utilisation d'un filtre à l'émission.	115
4.13	La fonction de repartitions de la densité de probabilité de la distribution des 3 premiers atomes sous H_1 et un $RSB = 0$ dB avec l'utilisation d'un filtre à l'émission.	116
4.14	La probabilité de détection en fonction du RSB pour une fausse alarme fixée à 10%, pour la MCSS et le détecteur cyclostationnaire. On considère les deux cas : avec et sans canal de propagation pour chacune des deux méthodes de détection.	117
4.15	La probabilité de détection P_d pour une fausse alarme fixée à 10% et un $RSB = 0$ dB, en fonction du nombre d'échantillons (temps d'observation) et ceci pour la MCSS et le détecteur de cyclostationarité. Deux cas sont considérés : avec et sans canal de propagation.	118
4.16	La norme théorique de la fonction d'autocorrélation cyclique d'une BPSK. On note la symétrie de cette norme par rapport à l'axe $\alpha = 0$	120
4.17	Exemple de calcul de $IND_{sym}^{(\tau)}$ pour un délai τ et un nombre d'itérations $l = 3$. On obtient dans ce cas idéal $IND_{sym}^{(\tau)} = \frac{1}{2}(\alpha_2 + \alpha_3) = 0$	121
4.18	L'organigramme de la Méthode de Symétrie MS.	122
4.19	La probabilité de détection en fonction du RSB pour une fausse alarme fixée à 15% avec un nombre total d'échantillons égal à 160, pour la MCSS et la MS. On considère les deux cas : $M = 2$ et $M = 5$ pour chacune des deux méthodes de détection. On remarque que la MS dépasse en détection la MCSS d'une part, et que les performances de détection s'améliorent avec M et ceci pour les deux méthodes de détection d'autre part.	124
4.20	Les courbes de ROC des trois méthodes de détection : détecteur de Cyclostationarité, la MS et la MCSS. Le nombre total des échantillons est égal à 200 pour toutes les méthodes de détections. Le RSB est égal à 0 dB.	124
4.21	Probabilité de fausse alarme en fonction du nombre d'itérations l (impair) pour une probabilité de détection fixe $P_d = 0,9$ et un $RSB = 0$ dB.	125
4.22	Probabilité de fausse alarme en fonction du nombre d'échantillons pour une probabilité de détection fixe $P_d = 0,9$ et un $RSB = 0$ dB.	126
4.23	Les courbes de ROC de la MS avec un nombre d'échantillons total égal à 300 et un $RSB = 0$ dB. On distingue les deux cas : avec et sans filtrage.	127

4.24	La probabilité de détection de la MS en fonction du RSB pour une fausse alarme égale à 10% et un nombre d'échantillons total égal à 160. On distingue les deux cas : avec et sans canal de propagation.	127
4.25	La probabilité de détection P_d pour une fausse alarme fixée à 10% et un $RSB = 0$ dB, en fonction du nombre d'échantillons (temps d'observation) et ceci pour la MS et la MCSS. Deux cas sont considérés : avec et sans canal de propagation.	128
4.26	La probabilité de détection P_d pour une fausse alarme fixée à 10% et un $RSB = 0$ dB, en fonction du nombre d'échantillons (temps d'observation) et ceci pour la MS et le détecteur de cyclostationarité. Deux cas sont considérés : avec et sans canal de propagation.	131
4.27	La probabilité de détection P_d pour une fausse alarme fixée à 10% sous un $RSB = 0$ dB, en fonction du nombre d'échantillons (temps d'observation) en utilisant un filtrage à l'émission et ceci pour les méthodes MS, MCSS, et le détecteur de cyclostationarité.	132
C.1	La réponse impulsionnelle du canal $c(\tau)$ utilisé.	148
C.2	Le module et la phase du canal $c(\tau)$ utilisé.	148
C.3	La carte des pôles et des zéros de $C(z)$	149

Liste des tableaux

2.1	Comparaison des principales propriétés des détecteurs d'énergie (radiomètre) et cyclostationnaire. Le (+) signifie un avantage et le (-) signifie un inconvénient	61
4.1	Comparaison du nombre d'échantillons et des complexités entre la MCSS proposé et le détecteur cyclostationnaire de Giannakis pour exactement la même performance $(P_{fa}, P_d) = (0, 1; 0, 85)$ sans canal de propagation. . .	119
4.2	Comparaison du nombre d'échantillons et de la complexité entre la MCSS proposée et le détecteur cyclostationnaire pour exactement les mêmes performances $(P_{fa}, P_d) = (0, 1; 0, 6)$ avec un canal de Rayleigh.	119
4.3	Comparaison du nombre d'échantillons et de la complexité entre la MS proposée et la MCSS pour exactement les mêmes performances $(P_{fa}, P_d) = (0, 1; 0, 91)$ sans canal de propagation.	129
4.4	Comparaison du nombre d'échantillons et de la complexité entre la MS proposée et la MCSS pour exactement les mêmes performances $(P_{fa}, P_d) = (0, 1; 0, 91)$ avec un canal de Rayleigh.	130
4.5	Comparaison du nombre d'échantillons et des complexités entre la MS proposée et le détecteur de cyclostationarité pour exactement les mêmes performances $(P_{fa}, P_d) = (0, 1; 0, 95)$ sans canal de propagation.	131
4.6	Comparaison du nombre d'échantillons et de la complexité entre la MS proposée et du détecteur de cyclostationarité pour exactement les mêmes performances $(P_{fa}, P_d) = (0, 1; 0, 95)$ avec un canal de Rayleigh.	132
C.1	Atténuation et retard des trajets du canal h	147

Publications de l'auteur au cours de la thèse

Revues

- Z. Khalaf, A.Nafkha, J. Palicot et M. Ghozzi « Low Complexity Enhanced Hybrid Spectrum Sensing Architecture for Cognitive Radio Equipment », International Journal on Advances in Telecommunications, issn 1942-2601 vol. 3, no. 3 & 4, pp. 215-227, 2010.
- Z. Khalaf et J. Palicot « On the Use of the Sparse Property of the Cyclic Autocorrelation Function to Blindly Estimate the Cyclostationarity », Frequenz, issn 2191-6349 vol. 66, issue 9-10, pp. 279-292, 2012.

Publication dans des conférences internationales

- Z. Khalaf, A.Nafkha, J. Palicot et M. Ghozzi « Hybrid Spectrum Sensing Architecture for Cognitive Radio Equipment », AICT, pp.46-51, 2010 Sixth Advanced International Conference on Telecommunications, Barcelona, Spain May 2010.
- Z. Khalaf, A.Nafkha et J. Palicot, « Enhanced Hybrid Spectrum Sensing Architectures for Cognitive Radio Equipment », URSI GASS 2011, Istanbul, Turquie Août 2011.
- Z. Khalaf, A.Nafkha et J. Palicot « Blind cyclostationary feature detector based on sparsity hypotheses for cognitive radio equipment », The 54th IEEE International Midwest Symposium on Circuits and Systems, Seoul, Korea, Août 2011 (Papier invité).
- Z. Khalaf, A.Nafkha et J. Palicot « Blind Spectrum Detector using Compressed Sensing », IEEE GLOBECOM 2011 Houston, Texas, USA.
- Z. Khalaf et J. Palicot « Exploiting Sparse Property of the Cyclic Autocorrelation Function for Cyclostationary Process », 7th Karlsruhe Workshop on Software Radios, Karlsruhe, Allemagne Mars 2012.
- Z. Khalaf, A.Nafkha et J. Palicot « Blind Spectrum Detector using Compressed Sensing and Symmetry Property of the Second Order Cyclic Autocorrelation », The 7th International Conference on Cognitive Radio Oriented Wireless Networks, IEEE CROWCOM Juin 2012 Stockholm, Suède.

Communications orales internationales

- Z. Khalaf, « Blind Spectrum Detector For Cognitive Radio using Compressed Sensing », 6th Technical Meeting of WUN Cognitive Communications Consortium December 2011, Houston, USA.

- Z. Khalaf et J. Palicot, « New Blind Free Bands Detectors using Cyclic Autocorrelation Function sparsity », The 3rd workshop of COST action IC0902 Cognitive Radio and Networking for Cooperative Coexistence of Heterogeneous Wireless Networks September 12-14, 2012 Ohrid, Macedonia.

Communications orales nationales

- Z. Khalaf, « Spectrum Detection Algorithms for Cognitive Radio using Compressed Sensing », séminaire SCEE Mai 2011, Rennes, France.
- Z. Khalaf, « Spectrum Sensing for Cognitive Radio using Compressed Sensing », Journée des doctorants de l'IETR, Juin 2011, Rennes, France
- Z. Khalaf, « Méthodes de détection des bandes libres », Journée des doctorants de l'IETR, Juin 2010, Rennes, France

Prix et distinctions

- Obtention du prix « *Best Paper Award* », lors de la 6e conférence, « Advanced International Conference on Telecommunications » (AICT 2010) Barcelone, Mai 2010.
- Obtention du prix « *Young Scientists Award* » URSI GASS 2011, Istanbul, Turquie, Août 2011.

Divers

- Membre du comité technique de la conférence internationale « Advanced International Conference on Telecommunications », AICT 2011, 2012, 2013.
- Relecteur pour les conférences internationales suivantes :
 1. AICT 2011, 2012, 2013
 2. CROWNCOM 2010, 2012
 3. ICT 2012, 2013
 4. WCNC 2012, 2013

Bibliographie

- [1] Y. Zeng, Y. Liang, A. Hoang, and R. Zhang, “A review on spectrum sensing for cognitive radio: challenges and solutions,” *EURASIP Journal on Advances in Signal Processing*, vol. 2010, p. 2, 2010.
- [2] A.V. Dantawaté and G.B. Giannakis, “Statistical tests for presence of cyclostationarity,” *IEEE Transactions on Information Theory*, vol. 42, pp. 2355–2369, September 1994.
- [3] E. Axell, G. Leus, E. Larsson, and H. Poor, “Spectrum sensing for cognitive radio: State-of-the-art and recent advances,” *Signal Processing Magazine, IEEE*, vol. 29, no. 3, pp. 101–116, 2012.
- [4] J. Mitola, *Cognitive radio: An integrated agent architecture for software defined radio*. Thèse de doctorat, Royal Institute of Technology, 2000.
- [5] Federal Communications Commission (FCC), “Spectrum policy task force,” *ET Docket No. 02-135*, November 2002.
- [6] J. Palicot (Survised by), *De la radio logicielle à la radio intelligente*. Collection Télécom, Lavoisier Librairie, 2010.
- [7] J. Palicot (Survised by), *Radio engineering: From software radio to cognitive radio*. Wiley, 2011.
- [8] S. M. Kay, *Fundamentals of Statistical Signal Processing: Detection Theory*. Prentice Hall, 1998.
- [9] H. V. Poor, *An Introduction to Signal Detection and Estimation*. Springer, 1988.
- [10] H.L. Van Trees, *Detection, estimation, and modulation theory*. John Wiley & Sons, New York, USA, 2001.
- [11] T. J. Lim, R. Zhang, Y. C. Liang, and Y. H. Zeng, “GLRT-based spectrum sensing for cognitive radio,” in *Proceedings of the IEEE Global Telecommunications Conference*, pp. 4391–4395, December, La, USA, 2008.
- [12] A.D. Whalen, *Detection of signal in noise*. Academic Press, Inc., 1971.
- [13] S. Atapattu, C. Tellambura, and H. Jiang, “Analysis of area under the roc curve of energy detection,” *Wireless Communications, IEEE Transactions on*, vol. 9, no. 3, pp. 1216–1225, 2010.
- [14] R. Tandra and A. Sahai, “Fundamental limits on detection in low snr under noise uncertainty,” in *Wireless Networks, Communications and Mobile Computing, 2005 International Conference on*, vol. 1, pp. 464–469, IEEE, 2005.

- [15] T. Yücek and H. Arslan, “A survey of spectrum sensing algorithms for cognitive radio applications,” *Communications Surveys & Tutorials, IEEE*, vol. 11, no. 1, pp. 116–130, 2009.
- [16] A. Ghasemi and E. Sousa, “Spectrum sensing in cognitive radio networks: requirements, challenges and design trade-offs,” *Communications Magazine, IEEE*, vol. 46, no. 4, pp. 32–39, 2008.
- [17] J.Y. Baudais, S. Méric, and J. Le Maitre, “Estimation de position de bateaux depuis l’espace à l’aide des signaux ais,” in *XXIIe colloque GRETSI (traitement du signal et des images), Dijon (FRA), 8-11 septembre 2009*, GRETSI, Groupe d’études du traitement du signal et des images, 2009.
- [18] D. Cabric, A. Tkachenko, and R. Brodersen, “Spectrum sensing measurements of pilot, energy, and collaborative detection,” in *Military Communications Conference. MILCOM 2006. IEEE*, pp. 1–7.
- [19] L. Sampaio Cardoso, M. Debbah, S. Lasaulce, K. Mari, and J. Palicot, “Spectrum sensing in cognitive radio networks,” 2009.
- [20] L. Bixio, M. Ottonello, M. Raffetto, and C. Regazzoni, “Performance evaluation of a multiple antenna system for spectrum sensing,” in *Antennas and Propagation Society International Symposium. APSURSI’09.*, pp. 1–4, IEEE.
- [21] H. Urkowitz, “Energy detection of unknown deterministic signals,” *Proceeding of the IEEE*, vol. 55, pp. 523–531, April 1967.
- [22] D. Cabric, S.M. Mishra and R.W. Brodersen, “Implementation issues in spectrum sensing for cognitive radios,” *Conference Record of the Thirty-Eighth Asilomar Conference on Signals Systems and Computers*, vol. 1, pp. 772– 776, November 2004.
- [23] W.A. Gardner, “Signal interception: A unifying theoretical framework for feature detection,” *IEEE Transaction on Communications*, vol. 36, August 1988.
- [24] A. Sahai, N. Hoven, and R. Tandra, “Some fundamental limits on cognitive radio,” in *Allerton Conference on Communication, Control, and Computing*, pp. 1662–1671, 2004.
- [25] M. Olivieri, G. Barnett, A. Lackpour, A. Davis, and P. Ngo, “A scalable dynamic spectrum allocation system with interference mitigation for teams of spectrally agile software defined radios,” in *New Frontiers in Dynamic Spectrum Access Networks. DySPAN 2005. First IEEE International Symposium on*, pp. 170–179.
- [26] F. Weidling, D. Datla, V. Petty, P. Krishnan, and G. Minden, “A framework for RF spectrum measurements and analysis,” in *New Frontiers in Dynamic Spectrum Access Networks. DySPAN 2005. First IEEE International Symposium on*, pp. 573–576.
- [27] S. Geirhofer, L. Tong, and B. Sadler, “Cognitive radios for dynamic spectrum access—dynamic spectrum access in the time domain: Modeling and exploiting white space,” *Communications Magazine, IEEE*, vol. 45, no. 5, pp. 66–72, 2007.
- [28] J.C. Bic, D. Duponteil and J.C Imbeaux, *Element de communications numériques*. Dunod, 1986.
- [29] W.A. Gardner, *Statistical spectral analysis: A nonprobabilistic theory*. Prentice-Hall, 1987.

- [30] M. Ghozzi, *Détection cyclostationnaire des bandes de fréquences libres*. PhD thesis, PhD thesis, 2008.
- [31] W. Gardner, “Cyclic wiener filtering: theory and method,” *Communications, IEEE Transactions on*, vol. 41, no. 1, pp. 151–163, 1993.
- [32] J.-L. Lacoume, P.-O. Amblard et P. Comon, *Statistiques d’ordre supérieur pour le traitement du signal*. Masson, 1997.
- [33] H. Akaike, “Information theory and an extension of the maximum likelihood principle,” *Second International Symposium on Information Theory, Budapest*, 1973.
- [34] G. Schwartz, “Estimating the dimension of a model,” *Annal of stat.*, vol. 6, 1978.
- [35] J. Rissanen, “Modeling by shortest data description,” *Automatica*, vol. 14, no. 5, pp. 465–471, 1978.
- [36] A. Hayar, “Process for sensing vacant bands over the spectrum bandwidth and apparatus for performing the same based on sub space and distributions analysis,” *European patent*, no. 8368002.5.
- [37] M. Haddad, A. Hayar, M. Fetoui, and M. Debbah, “Cognitive radio sensing information-theoretic criteria based,” in *Cognitive Radio Oriented Wireless Networks and Communications, 2007. CrownCom 2007. 2nd International Conference on*, pp. 241–244, IEEE, 2007.
- [38] B. Zayen, A. Hayar, and K. Kansanen, “Blind spectrum sensing for cognitive radio based on signal space dimension estimation,” in *Communications, 2009. ICC’09. IEEE International Conference on*, pp. 1–5, IEEE, 2009.
- [39] M. Wax and T. Kailath, “Detection of signals by information theoretic criteria,” *Acoustics, Speech and Signal Processing, IEEE Transactions on*, vol. 33, no. 2, pp. 387–392, 1985.
- [40] R. Wang and M. Tao, “Blind spectrum sensing by information theoretic criteria,” in *Global Telecommunications Conference (GLOBECOM 2010), 2010 IEEE*, pp. 1–5, IEEE, 2010.
- [41] R. Mahesh, A. Vinod, C. Moy, and J. Palicot, “A low complexity reconfigurable filter bank architecture for spectrum sensing in cognitive radios,” in *Cognitive Radio Oriented Wireless Networks and Communications, 2008. CrownCom 2008. 3rd International Conference on*, pp. 1–6, IEEE, 2008.
- [42] A. Sahai and D. Cabric, “Spectrum sensing: fundamental limits and practical challenges,” in *Proc. IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks (DySPAN)*, 2005.
- [43] H. Zhang, *Filter Bank MultiCarrier (FBMC) for Cognitive Radio Systems*. Thèse de doctorat, Conservatoire National des Arts et Métiers et Wuhan Université, 2010.
- [44] Z. Tian and G. Giannakis, “A wavelet approach to wideband spectrum sensing for cognitive radios,” in *Cognitive Radio Oriented Wireless Networks and Communications, 2006. 1st International Conference on*, pp. 1–5, IEEE, 2006.
- [45] S. Haykin, “Cognitive radio: Brain-empowered wireless communications,” *IEEE Journal on Selected Area in Communications*, vol. 23, pp. 201–220, February 2005.
- [46] S. Mallat, *A wavelet tour of signal processing: the sparse way*. Academic Press, 2009.

- [47] D. Thilakawardana et. al., "Spectrum occupancy detection for cognitive radios using wavelet transform analysis," in *Proceedings of the SDR'08 Technical Conference and product Exposit*, 2008.
- [48] S. Mallat and W. Hwang, "Singularity detection and processing with wavelets," *Information Theory, IEEE Transactions on*, vol. 38, no. 2, pp. 617–643, 1992.
- [49] Y. Hur, J. Park, W. Woo, K. Lim, C. Lee, H. Kim, and J. Laskar, "A wideband analog multi-resolution spectrum sensing (mrss) technique for cognitive radio (cr) systems," in *Circuits and Systems, 2006. ISCAS 2006. Proceedings. 2006 IEEE International Symposium on*, pp. 4–pp, IEEE, 2006.
- [50] Y. Youn, H. Jeon, J. Choi, and H. Lee, "Fast spectrum sensing algorithm for 802.22 wran systems," in *Communications and Information Technologies, 2006. ISCIT'06. International Symposium on*, pp. 960–964, IEEE, 2006.
- [51] Y. Hur, J. Park, K. Kim, J. Lee, K. Lim, C. Lee, H. Kim, and J. Laskar, "A cognitive radio (cr) testbed system employing a wideband multi-resolution spectrum sensing (mrss) technique," in *Vehicular Technology Conference, 2006. VTC-2006 Fall. 2006 IEEE 64th*, pp. 1–5, IEEE, 2006.
- [52] T. Yücek and H. Arslan, "Spectrum characterization for opportunistic cognitive radio systems," in *Military Communications Conference MILCOM*, 2006.
- [53] W. Guibene, M. Turki, B. Zayen, and A. Hayar, "Spectrum sensing for cognitive radio exploiting spectrum discontinuities detection," *EURASIP Journal on Wireless Communications and Networking*, 2012:4, 01 2012.
- [54] Z. Tiganj, *An algebraic delay estimation method for neuronal spike detection*. PhD thesis, Master thesis, Zagreb University, Croatia, 2008.
- [55] M. Mboup, C. Join, and M. Fliess, "An on-line change-point detection method," in *Control and Automation, 2008 16th Mediterranean Conference on*, pp. 1290–1295, IEEE, 2008.
- [56] W. Guibene, H. Moussavinik, and A. Hayar, "Combined compressive sampling and distribution discontinuities detection approach to wideband spectrum sensing for cognitive radios," in *ICUMT 2011, 3rd IEEE International Conference on Ultra Modern Telecommunications, 5-7 October, 2011, Budapest, Hungary*.
- [57] W. Guibene and A. Hayar, "Joint time-frequency spectrum sensing for cognitive radio," in *COGART, 3rd International Workshop on Cognitive Radio and Advanced Spectrum Management, November 2010, Rome, Italy*.
- [58] W. Guibene, A. Hayar, and M. Turki, "Distribution discontinuities detection using algebraic technique for spectrum sensing in cognitive radio networks," in *CROWN-COM 2010, 5th International Conference on Cognitive Radio Oriented Wireless Networks and Communications, 9-11 Juin 2010, Cannes, France*.
- [59] E. Candès, J. Romberg, and T. Tao, "Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information," *Information Theory, IEEE Transactions on*, vol. 52, no. 2, pp. 489–509, 2006.
- [60] E. Candès and M. Wakin, "An introduction to compressive sampling," *Signal Processing Magazine, IEEE*, vol. 25, no. 2, pp. 21–30, 2008.
- [61] D. Donoho, "Compressed sensing," *Information Theory, IEEE Transactions on*, vol. 52, no. 4, pp. 1289–1306, 2006.

- [62] Z. Tian and G. Giannakis, "Compressed sensing for wideband cognitive radios," in *Acoustics, Speech and Signal Processing, 2007. ICASSP 2007. IEEE International Conference on*, vol. 4, pp. IV–1357, IEEE, 2007.
- [63] P. Feng and Y. Bresler, "Spectrum-blind minimum-rate sampling and reconstruction of multiband signals," in *Acoustics, Speech, and Signal Processing, 1996. ICASSP-96. Conference Proceedings., 1996 IEEE International Conference on*, vol. 3, pp. 1688–1691, IEEE, 1996.
- [64] S. Chen, D. Donoho, and M. Saunders, "Atomic decomposition by basis pursuit," *SIAM journal on scientific computing*, vol. 20, no. 1, pp. 33–61, 1998.
- [65] Y. Miara, C. D'Amours, and T. Aboulnasr, "A novel reduced power compressive sensing technique for wideband cognitive radio," *EURASIP Journal on Wireless Communications and Networking*, vol. 2012, p. 281, 2012.
- [66] T. Moon and W. Stirling, *Mathematical methods and algorithms for signal processing*, vol. 1. Prentice hall New York, 2000.
- [67] G. McLachlan and T. Krishnan, *The EM algorithm and extensions*. New York, 1997.
- [68] Z. Tian, "Compressed wideband sensing in cooperative cognitive radio networks," in *Global Telecommunications Conference, 2008. IEEE GLOBECOM 2008. IEEE*, pp. 1–5, IEEE, 2008.
- [69] Y. Wang, A. Pandharipande, Y. Polo, and G. Leus, "Distributed compressive wideband spectrum sensing," in *Information Theory and Applications Workshop, 2009*, pp. 178–183, IEEE, 2009.
- [70]
- [71] F. Zeng, C. Li, and Z. Tian, "Distributed compressive spectrum sensing in cooperative multihop cognitive networks," *Selected Topics in Signal Processing, IEEE Journal of*, vol. 5, no. 1, pp. 37–48, 2011.
- [72] J. Palicot and C. Roland, "La radio logicielle: enjeux, contraintes et perspectives: Nouvelles radiocommunications mobiles: du gprs à l'umts," *REE. Revue de l'électricité et de l'électronique*, no. 11, pp. 60–67, 2001.
- [73] C. Roland, *Etude d'un récepteur universel auto-adaptatif pour des transmissions sans fil*. PhD thesis, 2001.
- [74] F.-X. Socheleau, S. Houcke, P. Ciblat, and A. A. E. Bey, "Cognitive OFDM system detection using pilot tones second and third-order cyclostationarity," *Signal processing*, vol. 91, pp. 252–268, february 2011.
- [75] S. Ohno and G. Giannakis, "Optimal training and redundant precoding for block transmissions with application to wireless OFDM," *Communications, IEEE Transactions on*, vol. 50, no. 12, pp. 2113–2123, 2002.
- [76] P. Sutton, K. Nolan, and L. Doyle, "Cyclostationary signatures in practical cognitive radio applications," *Selected Areas in Communications, IEEE Journal on*, vol. 26, no. 1, pp. 13–24, 2008.
- [77] H. Zhang, D. Le Ruyet, and M. Terre, "Signal detection for ofdm/oqam system using cyclostationary signatures," in *Personal, Indoor and Mobile Radio Communications, 2008. PIMRC 2008. IEEE 19th International Symposium on*, pp. 1–5, IEEE, 2008.

- [78] G. Ganesan and Y. Li, "Agility improvement through cooperative diversity in cognitive radio," in *Global Telecommunications Conference, 2005. GLOBECOM'05. IEEE*, vol. 5, pp. 5–pp.
- [79] G. Ganesan and Y. Li, "Cooperative spectrum sensing in cognitive radio networks," in *New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005. 2005 First IEEE International Symposium on*, pp. 137–143, IEEE, 2005.
- [80] A. Leu, M. McHenry, and B. Mark, "Modeling and analysis of interference in listen-before-talk spectrum access schemes," *International Journal of Network Management*, vol. 16, no. 2, pp. 131–147, 2006.
- [81] X. Liu, "Sensing-based opportunistic channel access," *Mobile Networks and Applications*, vol. 11, no. 4, pp. 577–591, 2006.
- [82] P. Pawelczak, G. Janssen, and R. Prasad, "Performance measures of dynamic spectrum access networks," in *Proc. IEEE Global Telecommunications Conference (IEEE GLOBECOM 2006)*, 2006.
- [83] A. Ghasemi and E. Sousa, "Asymptotic performance of collaborative spectrum sensing under correlated log-normal shadowing," *Communications Letters, IEEE*, vol. 11, no. 1, pp. 34–36, 2007.
- [84] E. Axell, G. Leus, and E. Larsson, "Overview of spectrum sensing for cognitive radio," in *Proceedings of the International Workshop on Cognitive Information Processing (CIP)*, pp. 322–327, 2010.
- [85] E. Peh and Y. Liang, "Optimization for cooperative sensing in cognitive radio networks," in *Wireless Communications and Networking Conference, 2007. WCNC 2007. IEEE*, pp. 27–32, IEEE, 2007.
- [86] I.F. Akyildiz, W.Y. Lee, M.C. Vuran and S. Mohanty, "Next generation/dynamic spectrum access/cognitive radio wireless networks: A survey," *Computer Networks Journal (Elsevier)*, vol. 50, pp. 2127–2159, September 2006.
- [87] M. Buddhikot, P. Kolodzy, S. Miller, K. Ryan, and J. Evans, "DIMSUMnet: new directions in wireless networking using coordinated dynamic spectrum," in *World of Wireless Mobile and Multimedia Networks. WoWMoM 2005. Sixth IEEE International Symposium on a*, pp. 78–85.
- [88] J. Pérez-Romero, O. Salient, R. Agustí, and L. Giupponi, "A novel on-demand cognitive pilot channel enabling dynamic spectrum allocation," in *New Frontiers in Dynamic Spectrum Access Networks, 2007. DySPAN 2007. 2nd IEEE International Symposium on*, pp. 46–54, IEEE, 2007.
- [89] Z. Ji and K. Liu, "Cognitive radios for dynamic spectrum access—dynamic spectrum sharing: A game theoretical overview," *Communications Magazine, IEEE*, vol. 45, no. 5, pp. 88–94, 2007.
- [90] W. Saad, Z. Han, M. Debbah, A. Hjørungnes, and T. Basar, "Coalitional games for distributed collaborative spectrum sensing in cognitive radio networks," in *INFOCOM 2009, IEEE*, pp. 2114–2122.
- [91] Z. Quan, S. Cui, A. Sayed, and H. Poor, "Optimal multiband joint detection for spectrum sensing in cognitive radio networks," *Signal Processing, IEEE Transactions on*, vol. 57, no. 3, pp. 1128–1140, 2009.

- [92] Y. Liang, Y. Zeng, E. Peh, and A. Hoang, "Sensing-throughput tradeoff for cognitive radio networks," *Wireless Communications, IEEE Transactions on*, vol. 7, no. 4, pp. 1326–1337, 2008.
- [93] Y. Zeng, Y. Liang, E. Peh, and A. Hoang, "Cooperative covariance and eigenvalue based detections for robust sensing," in *Global Telecommunications Conference, 2009. GLOBECOM 2009. IEEE*, pp. 1–6, IEEE, 2009.
- [94] L. Cardoso, M. Debbah, P. Bianchi, and J. Najim, "Cooperative spectrum sensing using random matrix theory," in *Wireless Pervasive Computing, 2008. ISWPC 2008. 3rd International Symposium on*, pp. 334–338, IEEE, 2008.
- [95] Y. Zeng and Y. Liang, "Eigenvalue-based spectrum sensing algorithms for cognitive radio," *Communications, IEEE Transactions on*, vol. 57, no. 6, pp. 1784–1793, 2009.
- [96] V. Marčenko and L. Pastur, "Distribution of eigenvalues for some sets of random matrices," *Mathematics of the USSR-Sbornik*, vol. 1, p. 457, 1967.
- [97] J. Baik, G. Ben Arous, and S. Péché, "Phase transition of the largest eigenvalue for nonnull complex sample covariance matrices," *The Annals of Probability*, vol. 33, no. 5, pp. 1643–1697, 2005.
- [98] J. Baik and J. Silverstein, "Eigenvalues of large sample covariance matrices of spiked population models," *Journal of Multivariate Analysis*, vol. 97, no. 6, pp. 1382–1408, 2006.
- [99] E. Visotsky, S. Kuffner, and R. Peterson, "On collaborative detection of TV transmissions in support of dynamic spectrum sharing," in *New Frontiers in Dynamic Spectrum Access Networks. DySPAN 2005. First IEEE International Symposium on*, pp. 338–345.
- [100] T. Weiss, "A diversity approach for the detection of idle spectral resources in spectrum pooling systems," in *Proc. of 48th International Scientific Colloquium, Sept. 2003*, 2003.
- [101] S. Mishra, A. Sahai and R. Brodersen, "Cooperative sensing among cognitive radios," *IEEE International Conference on Communications*, 2006.
- [102] Z. Quan, S. Cui, H. Poor, and A. Sayed, "Collaborative wideband sensing for cognitive radios," *Signal Processing Magazine, IEEE*, vol. 25, no. 6, pp. 60–73, 2008.
- [103] A. Ghasemi and E.S. Sousa, "Collaborative spectrum sensing for opportunistic access in fading environments," in *Proc. IEEE Symp. New Frontiers Dynamic Spectrum Access Networks*, pp. 131–136, November 2005.
- [104] A. Ghasemi and E. Sousa, "Spectrum sensing in cognitive radio networks: the cooperation-processing tradeoff," *Wireless Communications and Mobile Computing*, vol. 7, no. 9, pp. 1049–1060, 2007.
- [105] C. Sun, W. Zhang, and K. Letaief, "Cooperative spectrum sensing for cognitive radios under bandwidth constraints," in *Wireless Communications and Networking Conference, 2007. WCNC 2007. IEEE*, pp. 1–5, IEEE, 2007.
- [106] C. Sun, W. Zhang, and K. Ben, "Cluster-based cooperative spectrum sensing in cognitive radio systems," in *Communications, 2007. ICC'07. IEEE International Conference on*, pp. 2511–2515.

- [107] R. Tenney and N. Sandell, "Detection with distributed sensors," *Aerospace and Electronic Systems, IEEE Transactions on*, no. 4, pp. 501–510, 1981.
- [108] C. Sun, W. Zhang and K Ben Letaief, "Cooperative spectrum sensing for cognitive radios under bandwidth constraints," *IEEE Wireless Communications and networking conference (WCNC)*, 2007.
- [109] N. Shankar, C. Cordeiro, and K. Challapali, "Spectrum agile radios: utilization and sensing architectures," in *New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005. 2005 First IEEE International Symposium on*, pp. 160–169, IEEE, 2005.
- [110] L. Lu, X. Zhou, U. Onunkwo, and G. Li, "Ten years of research in spectrum sensing and sharing in cognitive radio," *EURASIP Journal on Wireless Communications and Networking*, vol. 2012, no. 1, p. 28, 2012.
- [111] P.M. Fishman, "Radiometric detection of spread-spectrum signals in noise of uncertain power," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 28, pp. 654–660, July 1992.
- [112] W. Jouini, *Contribution to learning and decision making under uncertainty for Cognitive Radio*. PhD thesis, Supélec, 2012.
- [113] R. Tandra and A. Sahai, "SNR walls for signal detection," *Selected Topics in Signal Processing, IEEE Journal of*, vol. 2, no. 1, pp. 4–17, 2008.
- [114] W. Jouini, "Energy detection limits under log-normal approximated noise uncertainty," *Signal Processing Letters, IEEE*, vol. 18, no. 7, pp. 423–426, 2011.
- [115] W. Jouini, D. Le Guennec, C. Moy, and J. Palicot, "Log-normal approximation of chi-square distributions for signal processing," in *General Assembly and Scientific Symposium, 2011 XXXth URSI*, pp. 1–4, IEEE, 2011.
- [116] W.A. Gardner, "Exploitation of spectral redundancy in cyclostationary signals," *IEEE Signal Processing Magazine*, vol. 8, pp. 14–36, April 1991.
- [117] S. Enserink and D. Cochran, "A cyclostationary feature detector," in *Signals, Systems and Computers, 1994. 1994 Conference Record of the Twenty-Eighth Asilomar Conference on*, vol. 2, pp. 806–810, IEEE, 1994.
- [118] M. Öner and F. Jondral, "Air interface recognition for a software radio system exploiting cyclostationarity," in *Proc. IEEE PIMRC'04, Barcelona, Spain*, vol. 3, pp. 1947–1951, September 2004.
- [119] M. Öner and F. Jondral, "Extracting the channel allocation information in a spectrum pooling system exploiting cyclostationarity," in *Proc. IEEE PIMRC'04*, vol. 1, 2004.
- [120] P. Marchand, *Détection et reconnaissance de modulations numériques à l'aide des statistiques cycliques d'ordre supérieur*. Thèse de doctorat, INP Grenoble, 1998.
- [121] J. Proakis, *Digital communications*. Mc Graw Hill, 4th ed.
- [122] W.A. Gardner and G. Zivanovic, "Degrees of cyclostationary and their application to signal detection and estimation," *Signal processing*, vol. 22, March 1991.
- [123] H.L. Hurd and N.L. Gerr, "Graphical methods for determining the presence of periodic correlation," *Journal of Time Series Analysis*, vol. 12, no. 4, pp. 337–350, 1991.

- [124] W.A. Gardner and C.M. Spooner, "Signal interception: Performance advantages of cyclic feature detectors," *IEEE Transaction on Communications*, vol. 40, January 1992.
- [125] L. Izzo, L. Paura and M. Tanda, "Signal interception in non-gaussian noise," *IEEE Transactions in Communication*, vol. 40, pp. 1030–1037, June 1992.
- [126] P. Rostaing, *Détection de signaux modulés en exploitant leurs propriétés cyclostationnaires : Application aux signaux sonar*. Thèse de doctorat, Université de Nice - Sophia Antipolis, 1997.
- [127] J. Renard et al., "Higher-order cyclostationarity detection for spectrum sensing," *EURASIP Journal on Wireless Communications and Networking*, vol. 2010, June 2010.
- [128] Athanasios Papoulis and S. Unnikrishna Pillai, *Probability, random variables, and stochastic processes*. McGraw-hill New York, 4th ed.
- [129] A. Martin, *Représentations parcimonieuses adaptées à la compression d'images*. Thèse de doctorat, Université de Rennes 1, 2010.
- [130] S. Mallat and Z. Zhang, "Matching pursuit in a time-frequency dictionary," *Transactions on Signal Processing*, pp. 3397–3415, 1993.
- [131] J-J. Fuchs, "Recovery of exact sparse representations in the presence of bounded noise," *IEEE Transactions on Information Theory*, vol. 51, pp. 3601–3608, October 2005.
- [132] D.L. Donoho, M. Elad, and V. Temlyakov, "Stable recovery of sparse overcomplete representations in the presence of noise," *IEEE Transactions on Information Theory*, vol. 52, pp. 6–18, January 2006.
- [133] J.A. Tropp, "Greed is good : algorithmic results for sparse approximation," *IEEE Transactions on Information Theory*, vol. 50, pp. 2231–2242, October 2004.
- [134] B.K. Natarajan, "Sparse approximate solutions to linear systems," *SIAM J. Comput*, vol. 24, pp. 227–234, April 1995.
- [135] G. Davis, S. Mallat, and Z. Zhang, "Adaptive time-frequency decompositions," *Optical Engineering*, vol. 33, no. 7, pp. 2183–2191, 1994.
- [136] Y. Pati, R. Rezaifar, and P. Krishnaprasad, "Orthogonal matching pursuit: Recursive function approximation with applications to wavelet decomposition," in *Signals, Systems and Computers, 1993. 1993 Conference Record of The Twenty-Seventh Asilomar Conference on*, pp. 40–44, IEEE, 1993.
- [137] Bradley Efron, Trevor Hastie, Iain M. Johnstone, and Robert Tibshirani, "Least angle regression," *The Annals of Statistics*, vol. 32, no. 2, pp. 407–499, 2004.
- [138] D.L. Donoho, M. Elad, and V. Temlyakov, "Regression shrinkage and selection via the lasso," *Journal of the royal statistical society*, vol. 58, no. 1, pp. 267–288, 1996.
- [139] J-J. Fuchs, "On the application of the global matched filter to the doa estimation with uniform circular arrays," *IEEE Transactions on Signal Processing*, vol. 49, pp. 702–709, April 2001.
- [140] R. Maleh and G. Fudge, "Rip analysis of modulated sampling schemes for recovering spectrally sparse signals," *arXiv preprint arXiv:1207.7347*, 2012.

- [141] E. Candes and T. Tao, "Decoding by linear programming," *Information Theory, IEEE Transactions on*, vol. 51, no. 12, pp. 4203–4215, 2005.
- [142] J. Haupt, L. Applebaum, and R. Nowak, "On the restricted isometry of deterministically subsampled fourier matrices," in *Information Sciences and Systems (CISS), 2010 44th Annual Conference on*, pp. 1–6, IEEE, 2010.
- [143] F. Yang, S. Wang, and C. Deng, "Compressive sensing of image reconstruction using multi-wavelet transforms," in *Intelligent Computing and Intelligent Systems (ICIS), 2010 IEEE International Conference on*, vol. 1, pp. 702–705, IEEE, 2010.
- [144] J. Fuchs, "Identification of real sinusoids in noise, the global matched filter approach.," in *15th Ifac-Ifors symposium on Identification and system Parameter Estimation*, pp. 1127–1132, 2009.
- [145] Desimir Vucic and Milorad Obradovic, "Matrix-based stochastic method for the spectral correlation characterization of digital modulation," *Facta Universitatis Series: Electronics and Energetics*, vol. 11, no. 3, pp. 271–284, 1998.
- [146] G.B. Giannakis, *Cyclostationary signal analysis*, in: V.K. Madisetti, D. Williams (Eds.), *Statistical Signal Processing Section of Digital Signal Processing Handbook*. CRC Press, Boca Raton, FL, Chap 17, 1999.
- [147] L. Lu and H. Wu, "A novel robust detection algorithm for spectrum sensing," *IEEE Journal on selected areas in communications*, vol. 29, February 2011.
- [148] A. Doostan and H. Owhadi, "A non-adapted sparse approximation of pdes with stochastic inputs," *Journal of Computational Physics*, vol. 230, pp. 3015–3034, April 2011.
- [149] "IEEE p802.22/d0.5, draft standard for wireless regional area networks part 22: Cognitive wireless ran medium access control (mac) and physical layer (phy) specifications: Policies and procedures for operation in the tv bands," IEEE, Mar. 2008.
- [150] "IEEE 802.22 working group," <http://grouper.ieee.org/groups/802/22/>.
- [151] C. Stevenson, C. Cordeiro, E. Sofer, and G. Chouinard, "Functional requirements for the 802.22 wran standard," *IEEE Std*, pp. 802–22, 2006.
- [152] C. Cordeiro, K. Challapali, D. Birru, and N. Sai Shankar, "IEEE 802.22: the first worldwide wireless standard based on cognitive radios," in *New Frontiers in Dynamic Spectrum Access Networks. DySPAN 2005. First IEEE International Symposium on*, pp. 328–337.