

**UNIVERSITÉ KASDI MERBAH D'OUARGLA**  
Faculté des nouvelles technologies de l'information et de la communication  
Département d'électronique et de télécommunications



**Thèse**

**Master académique**

**Domaine:** Sciences et technologies

**Domaine:** électronique et communication

**Option:** signal et communication

Préparé et présenté par :

**GUETTAI Sara**

**BEN SLIMAN Sabrina**

**Titre:**

**Prédiction du spectre à base des réseaux de neurones artificiels pour la bande GSM dans les réseaux radio cognitifs**

Soumis le: 13/10/2020

Au jury composé de:

M. Benchabane Abderezzak	MCA	Président	UKM Ouargla
M. Ben Arabi Bilal	MCB	Examineur	UKM Ouargla
M. Moad Mohammed Sayeh	MAA	Encadreur	UKM Ouargla
Melle. Tidjani Sayhia		Co-encadreur	UFM Constantine I

**Année Universitaire : 2019/2020**

# Dédicaces

*Dieu merci, il m'a aidé à accomplir ce travail modeste. Je la dédie à mes chers parents qui me soutiennent et me guident dans chaque chemin de mes études, "Que Dieu les bénisse".*

*Surtout à mon cher mari, mes frères et sœurs qui m'ont soutenu et m'ont donné la force d'aller de l'avant.*

*Merci à tous*

*Guettai Sara*

*Je dédie ce Projet à «ALLAH» Tout-Puissant mon créateur, Mon fort pilier, ma source inspiration, de sagesse, de connaissance et de compréhension. A mes chers parents, qui me soutiennent et me guident dans tout mon chemin d'étude "que Dieu les bénisse" J'espère que leur rêve est réalisé.*

*Surtout à mon cher mari, et mes enfants, à mes frères et sœurs qui m'ont soutenu et m'ont donné la force d'aller de l'avant.*

*Merci à tous.*

*Ben slimane sabrina*



# Remerciements

*Avant tout, nous tenons à remercier Allah «Tout-Puissant» qui nous a donné, santé, courage et foi pour achever notre travail. Nous tenons également à exprimer notre sincère gratitude, notre appréciation et notre respect à le Pr.*

*Sayh M'hemed, pour sa grande confiance et pour nous avoir choisis parmi tous pour prendre en charge ce projet. En ajoutant nous tenons à remercier à Mlle. F.F.D.J.A.N.F Sayhia pour avoir accepté de nous encadrer dans cette étude.*

*Je la remercie pour son implication, son soutien et sa disponibilité, ses remarques fructueuses et ses précieux conseils lors de notre étude et réalisation de ce projet.*

*Nos remerciements sont adressés également aux enseignants de notre département d'électronique et des télécommunications pour leurs contributions à notre formation.*

*Enfin, nous remercions nos familles, nos amis et tous ceux qui, de près ou de loin, ont contribué à la réalisation de ce travail.*

*Ben slimane Sabrina, Guettai Sara*

# **Prédiction de spectre à base des réseaux de neurones artificiels pour la bande GSM dans les réseaux radio cognitifs**

## **Résumé**

L'allocation statique réelle des ressources spectrales avec la prolifération du nombre de systèmes de communication sans fil et d'utilisateurs pose un problème de rareté du spectre. Ainsi, les systèmes intelligents Cognitive Radio sont livrés avec ses mécanismes pour optimiser l'utilisation du spectre de manière efficace. La prédiction du spectre est la fonction la plus importante d'un réseau CR pour surmonter les retards de détection, de traitement et de prise de décision du spectre. De cette manière, la prédiction du spectre peut garantir un accès sûr et efficace pour les SU. Le but de cette étude est de la prédiction du spectre état futurs des canaux sur la base d'informations historiques antérieures, Où nous utiliser Le réseau de neurones artificiel (ANN).

Nous avons appliqué le réseau neuronal à la bande des GSM 900, Il a été conçu et formé à l'aide d'un code MATLAB, en utilisant base de données d'entrées réelles.

En outre, on a basé sur deux critères d'évaluation pour mesurer la performance de nôtres modèles proposés qui sont le Mean Square Error (MSE) et la régression.

## **Mots-clés:**

Radio cognitive (CR), prédiction de spectre, réseau neuronal (ANN), bande GSM.

## **Neural Network based spectrum prediction for GSM band in Cognitive Radio Networks**

## **Abstract**

The actual static allocation of spectral resources with the proliferation of the number of wireless communication systems and users poses a problem of spectrum scarcity. Thus, the intelligent Cognitive Radio systems come with its mechanisms to optimize the use of the spectrum efficiently. Spectrum prediction is the most important function of a CR network to overcome spectrum detection, processing and decision making delays. In this way, spectrum prediction can ensure safe and efficient access for SUs. The aim of this study is to predict the future state spectrum of channels based on past historical information, where we use the artificial neural network (ANN).

We applied the neural network to the GSM 900 band. It was designed and trained using MATLAB code, using actual input database.

In addition, we have based on two evaluation criteria to measure the performance of our proposed models which are the Mean Square Error (MSE) and the regression.

**Keywords:**

Cognitive radio (CR), spectrum prediction, neural network (ANN), GSM band.

التنبؤ بالطيف المعتمد على الشبكة العصبية لنطاق GSM في شبكات الراديو الإدراكي

**ملخص:**

إن التخصيص الثابت الفعلي للموارد الطيفية مع انتشار عدد أنظمة الاتصالات اللاسلكية والمستخدمين يطرح مشكلة ندرة الطيف. وهكذا، فإن أنظمة راديو الإدراك الذكي تأتي مع آلياتها لتحسين استخدام الطيف بكفاءة. والتنبؤ بالطيف هو أهم وظيفة لشبكة (CR) للتغلب على حالات التأخير في الكشف عن الطيف ومعالجته واتخاذ القرارات. وبهذه الطريقة، يمكن أن يضمن التنبؤ بالطيف الوصول الآمن والفعال للمستخدمين الثانويين (SU). الهدف من هذه الدراسة هو التنبؤ بحالة الطيف المستقبلية للقنوات بناءً على معلومات تاريخية سابقة، حيث نستخدم الشبكة العصبية الاصطناعية (ANN).

حيث طبقنا الشبكة العصبية على نطاق GSM 900. وقد تم تصميمه وتدريبه باستخدام رمز MATLAB، وذلك باستخدام قاعدة بيانات إدخال حقيقية.

بالإضافة إلى ذلك، اعتمدنا على معيارين لتقييم لقياس أداء نماذجنا المقترحة هي متوسط خطأ مربع (MSE) والانحدار.

**الكلمات المفتاحية:**

الراديو المعرفي (CR)، التنبؤ بالطيف، الشبكة العصبية (ANN)، نطاق GSM.

# Liste des matières

<b>Dédicaces</b>	<b>I</b>
<b>Remerciements</b>	<b>II</b>
<b>Résumé</b>	<b>III</b>
<b>Liste des matières</b>	<b>V</b>
<b>Liste des figures</b>	<b>VIII</b>
<b>Liste des tableaux</b>	<b>IX</b>
<b>Liste des abréviations</b>	<b>X</b>
<b>Introduction</b> .....	<b>1</b>
Références.....	<b>3</b>
<b>CHAPITRE I :La Radio Cognitive</b> .....	<b>4</b>
1. Introduction.....	<b>5</b>
2. Concepts relatifs à la radio cognitive .....	<b>5</b>
3. Techniques cognitives : évitement, contrôle et atténuation des interférences .....	<b>6</b>
3.1. Évitement des interférences (spectre entrelacés).....	<b>6</b>
3.2. Contrôle des interférences (spectre en couche).....	<b>6</b>
3.3. Atténuation des interférences (superposition du spectre).....	<b>7</b>
4. Radio logicielle (software radio).....	<b>8</b>
5. Architecture .....	<b>10</b>
6. Cycle de cognition.....	<b>11</b>
7. Fonctions de la radio cognitive.....	<b>11</b>
7.1. Détection du spectre (Spectrum sensing).....	<b>11</b>
7.2. Gestion du spectre (Spectrum management).....	<b>12</b>
8. Domaines d'application de la radio cognitive.....	<b>13</b>
9. Conclusion .....	<b>14</b>
Références .....	<b>16</b>
<b>CHAPITRE II : Détection et Prédiction spectral</b> .....	<b>17</b>
1. Introduction.....	<b>18</b>

2. Allocation spectrale statique des ressources radio.....	18
3. L'écoute spectrale (Spectrum sensing).....	19
3.1. Définition de la détection du spectre.....	20
3.2. Classes de l'écoute spectrale.....	21
3.2.1. Écoute spectrale pour la détection des opportunités de spectre.....	21
3.2.2. Écoute spectrale pour la détection des interférences.....	22
4. Méthodes de l'écoute spectrale (spectrum sensing methods) .....	22
4.1. Détection d'énergie.....	22
4.2. Filtre adapté (Matched filter) .....	23
4.3. Détection de la cyclostationnarité.....	24
4.4. Comparaison des techniques de détection.....	26
5. Prédiction du spectre.....	26
5.1. Motivations pour la prédiction.....	26
5.2. Définition de la prédiction du spectre.....	27
5.3. Nécessité de la prédiction dans les réseaux radio cognitifs.....	27
6. Méthodes de prédiction du spectre dans les réseaux de la Radio Cognitive.....	28
6.1. Prédiction linéaire (LP) .....	28
6.2. Modèle de Markov (MM) .....	28
6.3. Inférence bayésienne (BIF) .....	29
6.4. Prédiction basée sur les réseaux de neurones artificiels (ANNs) .....	29
7. Conclusion.....	31
Références.....	32
<b>CHAPITRE III : Simulation et résultats.....</b>	<b>35</b>
1. Introduction.....	36
2. Répartition de la bande GSM.....	36
3. Base de données.....	38
4. Réseau de neurones.....	39
4.1. Architecture d'un réseau de neurones.....	39

4.1.1. Réseaux statiques (feed-forward) .....	39
4.1.2 Réseau récurrents (Feed-back) .....	40
4.2. Perceptron multicouche (Multi-layer Perceptron) .....	40
4.3. Fonctions d'activation (fonctions de transfert) .....	42
4.4. L'apprentissage d'un réseau de neurones.....	43
4.4.1. Apprentissage non supervisé.....	43
4.4.2. Apprentissage supervisé.....	44
5. Notre modèle proposé.....	45
5.1. Modèle de régression.....	45
5.2. Nonlinear autoregressive exogenous neural network (NARX) .....	46
5.2.1. Spécification du modèle.....	46
5.3. Time Delay Neural Network (TDNN).....;	47
5.4. Algorithme de Levenberg Marquardt (LM) .....	49
6. Résultats et discussions.....	56
6.1. Résultats de simulation pour NARX.....	50
6.2. Résultats de simulation pour TDNN.....	52
6.3. Remarques et Commentaires.....;	56
6.4. Comparaison des performances et résultats.....	56
7. Comparaison avec les travaux similaires.....	57
8. Conclusion.....	58
Références.....	59
<b>Conclusion.....</b>	<b>63</b>



# Liste des figures

	<b>Titre des figures</b>	<b>page</b>
<b>Figure I.1:</b>	Les utilisateurs principaux (blancs) et secondaires (gris) souhaitent transmettre sur le même canal.....	7
<b>Figure I.2:</b>	Les régions des taux réalisables sous quatre techniques cognitives .....	8
<b>Figure I.3:</b>	Evolution d'une radio matérielle vers radio logicielle plume sur matériel reconfigurable, permettant la réalisation de la radio cognitive.....	9
<b>Figure I.4:</b>	Architecture de la radio cognitive.....	10
<b>Figure I.5:</b>	Cycle de cognition.....	11
<b>Figure I.6:</b>	Cycle de cognition simplifié.....	11
<b>Figure II.1:</b>	État actuel du spectre.....	19
<b>Figure II.2:</b>	L'écoute spectrale dans la période du réseau radio cognitif.....	19
<b>Figure II.3:</b>	Exemple d'un scénario d'occupation spectrale.....	21
<b>Figure II.4:</b>	Classification des techniques de détection du spectre.....	22
<b>Figure II.5:</b>	Schéma fonctionnel du détecteur d'énergie.....	22
<b>Figure II.6:</b>	Schéma fonctionnel du filtre adapté.....	24
<b>Figure II.7:</b>	Précision et complexité de détection de diverses méthodes de détection.....	25
<b>Figure III.1:</b>	Les bandes fréquentielles du GSM.....	37
<b>Figure III.2:</b>	Réseau de perceptrons multicouches (MLP).....	41
<b>Figure III.3:</b>	Diagramme du MLP utilisé dans MATLAB.....	41
<b>Figure III.4:</b>	Architecture du fonctionnement d'un neurone artificiel.....	42
<b>Figure III.5:</b>	Système d'apprentissage pour la modélisation d'un processus.....	44
<b>Figure III.6:</b>	Architecture du réseau de neurone NARX.....	46
<b>Figure III.7:</b>	a) Diagramme de l'architecture parallèle série NARX b) Schéma de l'architecture en boucle fermée NARX.....	47
<b>Figure III.8:</b>	Structure le réseau neuronal temporel (TDNN).....	48
<b>Figure III.9:</b>	Résultats des performances du modèle NARX.....	52
<b>Figure III.10:</b>	Résultats des performances du modèle TDNN.....	55

# Liste Des Tableaux

	<b>Titre Des Tableaux</b>	<b>page</b>
<b>Tableau I.1:</b>	Classification de la radio logicielle définie selon le SDR Fourme....	<b>9</b>
<b>Tableau II.1:</b>	Les avantages et Les inconvénients des méthodes de l'écoute spectrale.....	<b>26</b>
<b>Tableau II.2:</b>	Les avantages et Les inconvénients de différentes méthodes de prédiction.....	<b>30</b>
<b>Tableau III.1:</b>	Certaines fonctions couramment utilisées et leurs courbes sont données.....	<b>42</b>
<b>Tableau III.2:</b>	Critères de performances (MSE et régression) du modèle NARX en termes de la variation des paramètres du réseau.....	<b>50</b>
<b>Tableau III.3:</b>	Critères de performances (MSE et régression) du modèle TDNN en termes de la variation des paramètres du réseau.....	<b>53</b>
<b>Tableau III.4:</b>	Résultats des simulations NARX et TDNN.....	<b>57</b>
<b>Tableau III.5:</b>	Comparaison des performances avec d'autres RC basés sur NN algorithmes.....	<b>57</b>

# Liste des abréviations

<b>Acronyme</b>	<b>Signification</b>
<b>ANN</b>	Artificial Neural Networks
<b>ARFCN</b>	Absolute Radio Frequency Channel Number
<b>ARMA</b>	Auto- regressive Moving Average
<b>ARIMA</b>	Auto- regressive Integrated Moving Average
<b>BIF</b>	Bayesian Inference
<b>BTS</b>	Base Transceiver Station
<b>CAF</b>	Cyclic Autocorrelation Function
<b>CD</b>	Cyclostationary Detector
<b>CDMA</b>	Code Division Multiple Access
<b>CR</b>	Cognitive Radio
<b>CRN</b>	Cognitive Radio Network
<b>CSD</b>	Cyclic Spectral Density
<b>CSMA</b>	Carrier Sense Multiple Access
<b>DSA</b>	Dynamic Spectrum Access
<b>ED</b>	Energy Detector
<b>FCC</b>	Federal Communications Commission
<b>FDMA</b>	Frequency Division Multiple Access
<b>IEEE</b>	Institute of Electricale and Electronics Engineers
<b>ISR</b>	Ideal Software Radio
<b>GSM</b>	Global System for Mobile communications
<b>JM</b>	Jacobian Matrix
<b>LM</b>	Levenberg-Marquardt
<b>LP</b>	Linear Prediction
<b>MA</b>	Mobile Average
<b>MAC</b>	Medium Access Control
<b>MF</b>	Matched Filter
<b>MLP</b>	Multi-Layer Perceptron
<b>MM</b>	Markov Models

# Liste des abréviations

<b>MSE</b>	Mean Squared Error
<b>NARX</b>	Nonlinear Auto-regressive Network with exogenous
<b>PSD</b>	Power Spectral Density
<b>PU</b>	Primary User
<b>QoS</b>	Quality of Service
<b>RF</b>	Radio Frequency
<b>RMSE</b>	Roots Mean Squared Error
<b>SDR</b>	Software Defined Radio
<b>SNR</b>	Signal-to-Noise Ratio
<b>SP</b>	Sensory Perception
<b>SU</b>	Secondary User
<b>TDMA</b>	Time Division Multiple Access
<b>TDNN</b>	Time Delay Neural Networks
<b>WRAN</b>	Wireless Regional Access Networks
<b>WSS</b>	Wide Sense of Stationarity

# INTRODUCTION

---

---

# Introduction

La gestion de l'exploitation du spectre radio est devenue un enjeu primordial [5], où la demande de la bande passante a augmenté avec l'introduction de plusieurs normes sans fil. Cette avancée a amené sur une pénurie de spectre perçue, l'étude menée par la FCC (Federal communication Commission) montre que le spectre est disponible [6], et qu'un large éventail est disponible qui n'est pas utilisé. On peut donc dire que le problème est l'utilisation du spectre et non la rareté du spectre. Par conséquent, des techniques innovantes qui peuvent offrir de nouvelles façons d'exploiter le spectre disponible sont nécessaires [1].

Afin d'améliorer l'utilisation des ressources spectrales, le paradigme radio cognitive (RC) a été identifié comme candidat pour la prochaine génération de systèmes de communication sans fil [3], il faudrait partager efficacement les bandes fréquentielles entre les différents systèmes [5]. En outre, la RC a été définie différemment par différents auteurs dans la littérature. Toutefois, dans toutes les définitions, deux caractéristiques principales de RC sont récurrentes, c'est-à-dire (1) Capacité cognitive et (2) Reconfigurabilité [3]. Un réseau de (RC) se compose d'un utilisateur principal (UP) qui a les droits légaux d'utiliser le spectre attribué, tandis qu'un utilisateur secondaire (US) utilise le spectre de manière à ne provoquer aucune interférence à l'UP [2].

Un réseau radio cognitive (RRC) a une technique de gestion active du spectre connue sous le nom d'accès dynamique au spectre (DSA), et d'adapter la variabilité de la disponibilité du spectre des locaux et générer des espaces pour les utilisateurs secondaires (US), les utilisateurs qui partageront le spectre avec les UP. Un RRC trouve des espaces à occuper, dans le large spectre, lorsque cela est nécessaire, permettant l'utilisation du spectre temporairement disponible en transférant la transmission dans les trous du spectre, obtenant ainsi un accès opportuniste. Le dernier objectif des RRC est d'obtenir le meilleur spectre disponible grâce à la capacité cognitive et à la reconfigurabilité. Le défi majeur est de partager le spectre sous licence sans interférer avec la transmission des UP, car la partie majeure du spectre est déjà allouée. Pour déterminer l'occupation et les caractéristiques des UP, la détection spectrale a été largement utilisée.

---

---

Traditionnellement, les techniques de détection d'UP ont été basées sur les observations actuelles. Le canal change après avoir la détection d'UP provoquant des discontinuités inévitables.

Un autre chemin approprié est la prédiction de la disponibilité du canal cible, pour réduire l'interférence aux UP. À l'aide de la prédiction, une détection partielle du spectre peut être effectuée au lieu de la détection complète conventionnelle, ce qui réduit le délai de découverte lors du transfert du spectre [4].

Pendant la prédiction du spectre, les états du canal de la trame suivante sont prédits sur la base d'informations historiques. Emploi du réseau de neurones artificiel (RNA) pour la prédiction du spectre est très utile dans le cas d'une intensité de trafic constante, RNA peut prédire rapidement les états de canal de la trame suivante dès que sa formation est terminée. Selon les statistiques, la durée de prédiction est évaluée à 2% à 15% de la durée de trame, offrant la possibilité d'introduire la prédiction dans la structure de trame d'US. Pour surmonter le défi du faible débit de l'US dans les RRC à trafic élevé .

Cette thèse contient trois chapitres organisés comme suit:

**Chapitre I :** Nous présentons les concepts relatifs à la radio cognitive, principe de fonctionnement, limites théoriques des réseaux cognitifs, améliorations offertes par la radio cognitive, et domaines d'application de la radio cognitive.

**Chapitre II :** Nous présentons la détection spectrale, la définition de prédiction du spectre, et la nécessité de la prédiction dans les réseaux radio cognitifs.

**Chapitre III :** Dans ce chapitre, nous présentons le choix de la technique de prédiction du spectre, la prédiction du spectre par les réseaux de neurones artificielle sur la bande GSM900 (Up Link, Down link) et aussi, les différentes étapes jusqu'à l'obtention des résultats de prédiction, suivi par une discussion par rapport aux résultats obtenus.

---

---

# REFERENCES

- [1] B. G. Najashi, F. Wenjiang, M. D. Almustapha, “*Spectrum hole prediction based on historical data: A neural network approach*,” 2014, arXiv preprint arXiv:1401.0886.
- [2] R.V. Rao, J. Taler, “*Advanced engineering optimization through intelligent techniques*,” Cracow University of Technology Kraków Poland, 2018, Vol. 949, 2019, doi: <https://doi.org/10.1007/978-981-13-8196-6>.
- [3] S. Oyewobi, K. Djouani, A. Matthew Kurien, “*A review of industrial wireless communications, challenges, and solutions: A cognitive radio approach*,” University of Technology, Pretoria 0001, South Africa, p.6, 4 June 2020, doi:10.1002/ett.4055.
- [4] L. M. Tuberquia-David, L. Cruz, C. Hernández, “*Spectral prediction: approaches in cognitive radio networks*,” International Journal of Applied Engineering, Volume. 13, Nombre 10, pp. 8051-8052, Research India Publications, <http://www.ripublication.com>
- [5] N. Benghabrit, “*Allocation des ressources dans les réseaux radio cognitifs*,” Thèse Docteur, 19 Mars 2019, pp.1-2.
- [6] A. G. Benbrahim, C. G. Jieman, “*Analyse d'une chaîne de communication d'un réseau basé sur la radio cognitive*,” Mémoire de master, 24 juin 2013, pp.1-7.



# CHAPITRE 01

## 1. Introduction

Dans les systèmes de communication sans fil traditionnels, la sous- utilisation du spectre radioélectrique, ainsi que la demande croissante de spectre provenant des nouvelles applications sans fil, exige l'élaboration de nouvelles règles d'attribution du spectre pour les communications sans fil. Ces nouvelles règles d'attribution du spectre, qui permettront aux utilisateurs non licenciés (c.-à-d. les utilisateurs secondaires) d'accéder au spectre radioélectrique lorsqu'il n'est pas occupé par des utilisateurs licenciés (c.-à-d. les utilisateurs primaires) seront exploitées par la technologie de la radio cognitive (RC). La radio cognitive améliorera l'utilisation du spectre dans les systèmes de communication sans fil tout en tenant compte de la quantité croissante de services et d'applications dans les réseaux sans fil. Un émetteur-récepteur radio cognitif est capable de s'adapter à l'environnement radio dynamique et aux paramètres du réseau pour maximiser l'utilisation des ressources radio limitées tout en offrant une flexibilité dans l'accès sans fil [1].

## 2. Concepts relatifs à la radio cognitive

Les principales caractéristiques d'un émetteur-récepteur RC comprennent la connaissance de l'environnement radio (en termes d'utilisation du spectre, de densité spectrale de puissance des signaux transmis/reçus, de protocole de signalisation sans fil) et d'intelligence. Cette intelligence consiste en la capacité d'adaptation aux paramètres du système tels que la puissance de transmission, la fréquence porteuse, la technique de modulation (de la couche physique), et les paramètres de protocole des couches supérieures [1].

La mise en œuvre d'une radio cognitive sera basée sur le concept d'accès dynamique au spectre ADS (Dynamic Spectrum Access DSA). Grâce à l'ADS le spectre des fréquences peut être partagé entre les utilisateurs primaires et les utilisateurs cognitifs (c.-à-d. les utilisateurs secondaires) dans un environnement radio en évolution dynamique. Il existe deux manières d'accès dynamique au spectre : l'octroi de licences dynamiques (pour une utilisation exclusive dynamique du spectre radioélectrique) et le partage dynamique (pour la coexistence). Le partage dynamique peut être de deux types : le partage horizontal du spectre et le partage vertical du spectre. Dans le premier cas, tous les utilisateurs/nœuds ont les mêmes droits d'accès tandis que dans le second cas tous les utilisateurs/nœuds n'ont pas les mêmes droits d'accès (c.-à-d. qu'il y a des utilisateurs primaires et des utilisateurs secondaires) et que les utilisateurs secondaires accèdent de façon opportuniste au spectre sans affecter négativement les performances des utilisateurs primaires [1].

La détection du spectre (Spectrum sensing) est l'une des principales fonctions d'une radio cognitive. L'objectif est de déterminer l'activité des utilisateurs licenciés en observant périodiquement les signaux sur les bandes de fréquence cible. D'autre part, l'analyse des interférences est nécessaire pour concevoir les paramètres radio cognitifs, afin que l'impact des interférences sur les utilisateurs primaires puisse être minimisé.

### **3. Techniques cognitives : évitement, contrôle et atténuation des interférences**

Les réseaux cognitifs devraient obtenir de meilleures performances que les réseaux homogènes standard puisqu'ils sont capables (1) d'exploiter les capacités cognitives des nœuds, c'est-à-dire de détecter et de s'adapter à leur environnement sans fil et (2) souvent (mais pas nécessairement) d'exploiter de nouveaux scénarios dans lesquels les utilisateurs cognitives agiles sont autorisées à partager le spectre avec les utilisateurs primaires. Naturellement, la mesure dans laquelle les performances du réseau peuvent être améliorées dépend de ce que les radios cognitives savent de leur environnement spectral, et par conséquent, comment ils s'adaptent à cela. Le comportement cognitif, ou la façon dont les utilisateurs cognitifs secondaires utilisent le spectre primaire, peut être regroupé en trois catégories. Chaque catégorie exploite des degrés de connaissance variables de l'environnement sans fil au niveau de l'utilisateur(s) secondaire(s) [1] :

#### **3.1. Évitement des interférences (spectre entrelacés)**

Les signaux primaires et secondaires peuvent être considérés comme orthogonaux les uns aux autres : ils peuvent accéder au spectre d'une manière (TDMA) (time-division-multiple-access), d'une manière (FDMA) (frequency division- multiple-access), ou de quelque façon que ce soit qui garantit que les signaux primaires et secondaires n'interfèrent pas les uns avec les autres. La cognition requise par les utilisateurs secondaires pour y parvenir est la connaissance des brèches spectrales (en temps, en fréquence) du système primaire. Les utilisateurs secondaires peuvent alors exploiter ces vides spectraux [1].

#### **3.2. Contrôle des interférences (spectre en couche)**

Les utilisateurs secondaires transmettent sur le même spectre que les utilisateurs principaux, mais le font de manière à ce que l'interférence observée par les utilisateurs primaires des utilisateurs cognitifs soit contrôlée à un niveau acceptable. La cognition requise est la connaissance des « niveaux acceptables » d'interférence aux utilisateurs primaires que l'utilisateur cognitif peut engendrer, ainsi que la connaissance de l'effet de la transmission


cognitive sur le récepteur principal. Cette dernière hypothèse se résume, dans les canaux sans fil classiques, à la connaissance du ou des canaux entre les émetteurs cognitifs et les récepteurs primaires [1].

### 3.3. Atténuation des interférences (superposition du spectre)

Les utilisateurs secondaires transmettent sur le même spectre que les utilisateurs principaux, mais en plus de la connaissance des canaux entre les utilisateurs primaires et secondaires (nature), les nœuds cognitifs ont des informations supplémentaires sur le système primaire et son fonctionnement. Par exemple, la connaissance des codes des utilisateurs principaux, permettant aux utilisateurs secondaires de décoder les transmissions des utilisateurs primaires, ou dans certains cas même la connaissance du message des utilisateurs principaux [1].

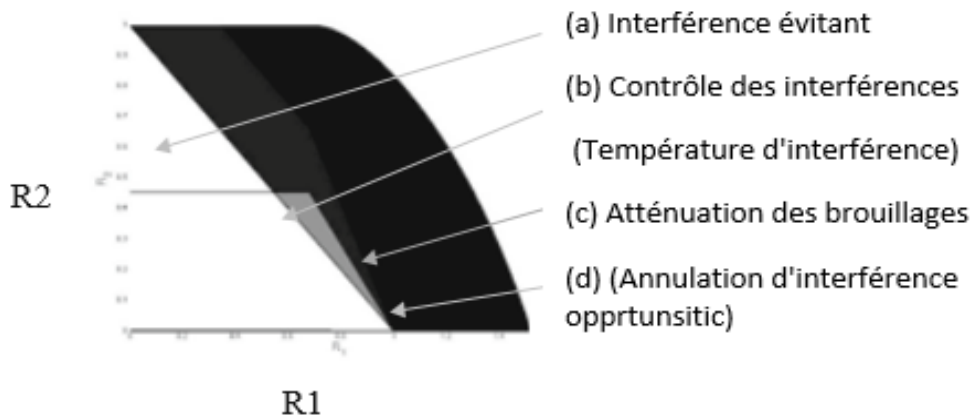
Nous considérons un canal simple dans lequel une paire d'émetteur-récepteur primaire (PTx, PRx) et une paire d'émetteurs-récepteurs cognitifs (STx, SRx) partagent le même spectre, Figure I.1. Pour ce canal simple, pour mesurer les limites fondamentales de la communication, en termes de taux de transfert, on utilise la notion de région de capacité du canal [1].

Dans un bruit gaussien, les taux  $R_1$  de la paire primaire Tx–Rx et  $R_2$  de la paire cognitive Tx–Rx sont illustrés dans la Figure I.2 pour les trois techniques cognitives (évitement, contrôle et atténuation des interférences) [1].



**Figure I.1.** Les utilisateurs principaux (blancs) et secondaires (gris) souhaitent transmettre sur le même canal [1].

Dans la Figure I.1 les lignes solides désignent la transmission souhaitée, les lignes pointillées dénotent l'interférence.



**Figure I.2.** Les régions des taux réalisables sous quatre techniques cognitives [1].

La région pour le technique évitement d'interférence est indiquée par le triangle blanc intérieur. La région en gris indique les taux pour la technique contrôle d'interférence. Enfin, la région en noire montre les taux R1 et R2 pour la technique atténuation des interférences, illustrées à la Figure I.2.

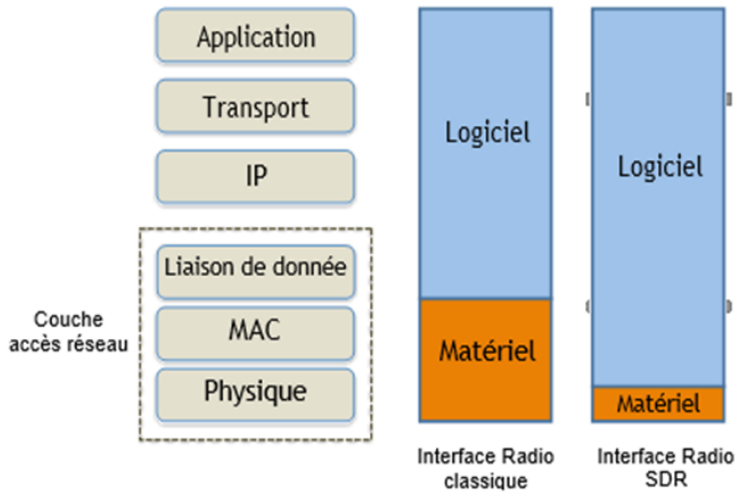
La conclusion fondamentale et naturelle est que, plus le niveau de cognition aux terminaux cognitifs est élevé, plus les taux réalisables sont élevés. Cependant, l'augmentation de la cognition se traduit souvent par une complexité accrue. À quel niveau de cognition, les systèmes secondaire fonctionneront dépendra des informations à priori disponibles et des contraintes de conception du réseau [1].

#### 4. Radio logicielle (software radio)

Inventée par Joseph Mitola en 1991, dans le but de définir une classe radio reprogrammable et reconfigurable, la radio logicielle présente le point de départ de la radio cognitive [2].

On peut trouver plusieurs définitions pour décrire la radio logicielle. L'IEEE (Institute of Electricale and Electronics Engineers) l'a défini comme :

La radio logicielle est une radio dans laquelle les fonctions typiques de l'interface radio généralement réalisées en matériel, telles que la fréquence porteuse, la largeur de bande du signal, la modulation et l'accès au réseau sont réalisés sous forme logicielle. La radio logicielle moderne intègre également l'implantation logicielle des procédés de cryptographie, codage correcteur d'erreur, codage source de la voix, de la vidéo ou des données [3], où un mode de réalisation décrivant la relation entre la RC et la radio logicielle est illustré à la Figure I.3 [2].



**Figure I.3.** Evolution d’une radio matérielle vers radio logicielle plumeés sur matériel reconfigurable, permettant la réalisation de la radio cognitive [4].

Il existe plusieurs modèles de la radio logicielle. Ils sont représentés dans le Tableau I.1

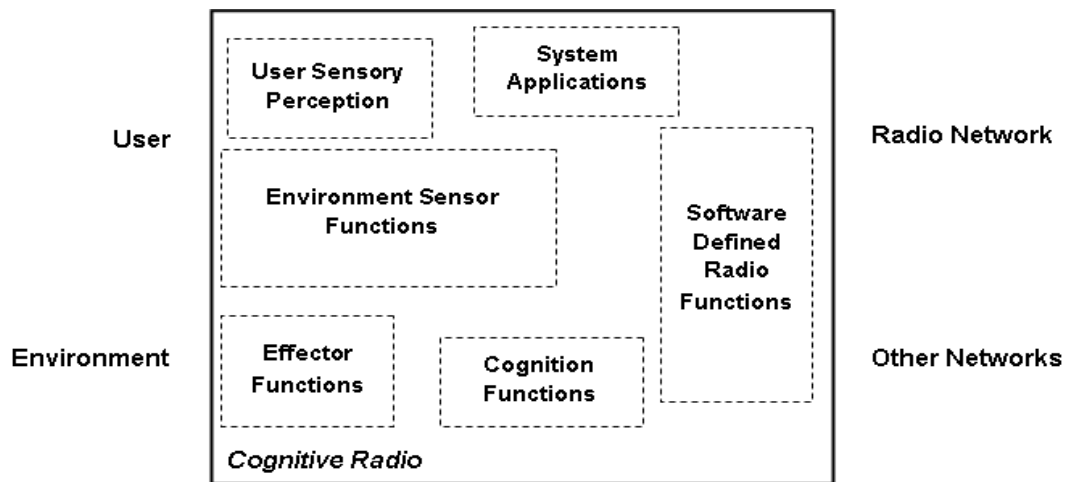
**Tableau I.1.** Classification de la radio logicielle définie selon le SDR fourme [4].

Niveau	Terme	Description
<b>Niveau 0</b>	Hardware Radio (HR)	Radio basée sur des composants matériels ne pouvant être modifiés que physiquement
<b>Niveau 1</b>	Software Controlled Radio (SCR)	Seules les fonctions de contrôle sont implémentées en logiciel, exp : niveau de puissance
<b>Niveau 2</b>	Software Dified Radio (SDR)	Les fonctions de contrôle ainsi que les techniques de modulations sont prises en charge en logiciel
<b>Niveau 3</b>	Ideal Software Radio (ISR)	L’évolution par rapport au SDR est que la programmabilité du système est étendue à l’ensemble du système avec une conversion analogique numérique à l’antenne

<b>Niveau 4</b>	Ultimate Software Radio (USR)	Cette définition est donnée dans le seul but de comparer les systèmes réels à une référence ultime. Ce système reprogrammable est capable de supporter n'importe quelle donnée de contrôle, n'importe quelle plage de fréquence, type de modulation... et reconfigurable en quelques millisecondes
-----------------	-------------------------------	--

## 5. Architecture

Mitola a défini l'architecture d'une radio cognitive par un ensemble cohérent de règles de conception par lequel un ensemble spécifique de composants réalise une série de fonctions de produits et de services [5].



**Figure I.4.** Architecture de la radio cognitive [3].

Les six composantes réalisent une série de fonctions et de service, elles sont définies comme elles sont définies selon la Figure I.4 comme suit [3]:

La perception sensorielle (Sensory Perception : SP) de l'utilisateur qui inclut l'interface haptique (du toucher), acoustique, la vidéo et les fonctions de détection et de la perception ;

- ✓ Les capteurs de l'environnement local (emplacement, température, accéléromètre, etc.);
- ✓ Les applications système (les services médias indépendants comme un jeu en réseau) ;
- ✓ Les fonctions SDR (qui incluent la détection RF et les applications radio de la SDR);
- ✓ Les fonctions de la cognition (pour les systèmes de contrôle, de planification, d'apprentissage) ;

✓ Les fonctions locales effectrices (synthèse de la parole, du texte, des graphiques et des affiches multimédias).

## 6. Cycle de cognition

Le cycle de cognition est élaboré pour contrôler la circulation de l'information dans l'environnement radio. La composante cognitive de l'architecture de la RC comprend une organisation temporelle, des flux d'inférences et des états de contrôle. Ce cycle synthétise cette composante de manière évidente. Les excitations entrent dans la RC comme des interruptions sensorielles envoyées sur le cycle de cognition pour engendrer une réponse adéquate [2].

Un cycle de cognition radio observe l'environnement, s'oriente, crée des plans, décide, et puis agit [2]. Un exemple de cycle de cognition pour la RC est illustré dans la Figure I.5 [3].

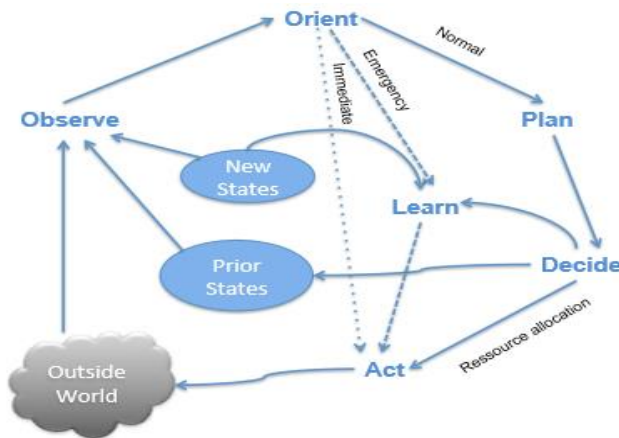


Figure I.5. Cycle de cognition [4].

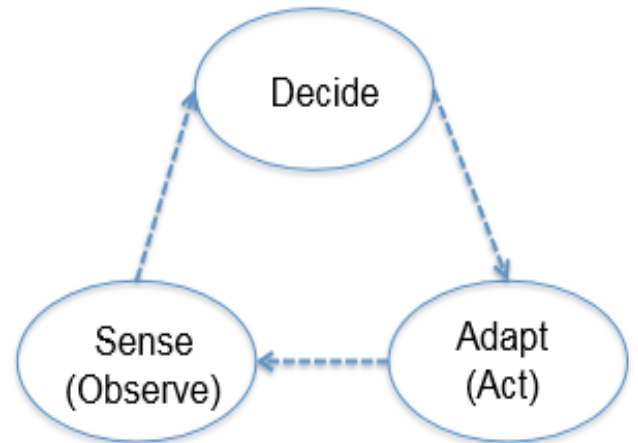


Figure I.6. Cycle de cognition simplifié [4].

## 7. Fonctions de la radio cognitive

Les principales fonctions de la radio cognitive sont les suivantes [6]:

### 7.1. Détection du spectre (Spectrum sensing)

- ✓ Détecter le spectre non utilisé et le partager sans interférence avec d'autres utilisateurs;
- ✓ La détection des utilisateurs primaires est la façon la plus efficace pour détecter les espaces blancs du spectre;
- ✓ L'un des objectifs de la détection du spectre, en particulier pour la détection des interférences;
- ✓ Obtenir le statut du spectre (libre / occupé), de sorte que le spectre peut être consulté par un utilisateur secondaire en vertu de la contrainte d'interférence.



- ✓ Le défi réside dans le fait de mesurer l'interférence au niveau du récepteur primaire causée par les transmissions des utilisateurs secondaires.

### 7.2. Gestion du spectre (Spectrum management)

✓ Capturer les meilleures fréquences disponibles pour répondre aux besoins de communication des utilisateurs.

✓ Les radios cognitives devraient décider de la meilleure bande de spectre pour répondre aux exigences de qualité de service sur toutes les bandes de fréquences disponibles.

Les fonctions de gestion peuvent être classées en plusieurs étapes qui sont présentées comme suit [6]:

#### a) Analyse du spectre

✓ Les résultats obtenus de la détection du spectre sont analysés pour estimer la qualité du spectre;

✓ Une des questions ici est de savoir comment mesurer la qualité du spectre qui peut être accédée par un utilisateur secondaire;

✓ Cette qualité est caractérisée par le rapport signal/bruit, la durée moyenne et la corrélation de la disponibilité des espaces blancs;

✓ Des algorithmes d'apprentissage de l'intelligence artificielle sont des techniques qui peuvent être employées par les utilisateurs de la RC pour l'analyse du spectre.

#### b) Décision sur le spectre

##### • Modèle de décision

✓ Un modèle de décision est nécessaire pour l'accès au spectre.

✓ La complexité de ce modèle dépend des paramètres considérés de l'analyse du spectre.

✓ Le modèle de décision devient plus complexe quand un utilisateur secondaire a des objectifs multiples.

##### • Compétition / Coopération dans un environnement multiutilisateur

Lorsque plusieurs utilisateurs (à la fois primaires et secondaires) sont dans le système, leur préférence va influencer sur l'accès au spectre. Ces utilisateurs peuvent être coopératifs ou non coopératifs dans l'accès au spectre.

- *Dans un environnement non-coopératif*, chaque utilisateur a son propre objectif, tandis que dans un environnement coopératif, tous les utilisateurs peuvent collaborer pour atteindre

un seul objectif. Tous veillent à ce que l'interférence causée à l'utilisateur primaire est maintenue en dessous de la limite de température de brouillage correspondante.

- *Dans un environnement coopératif*, les systèmes radio cognitives coopèrent les uns avec les autres pour prendre une décision pour accéder au spectre et maximiser une fonction objective commune en tenant compte des contraintes. Dans un tel scénario, un contrôleur central peut coordonner la gestion du spectre.

- **Mise en œuvre distribuée du contrôle d'accès au spectre**

Dans un environnement multiutilisateur distribué, pour un accès non-coopératif au spectre, chaque utilisateur peut parvenir à une décision optimale de façon indépendante en observant le comportement (historique / action) des autres utilisateurs du système. Par conséquent, un algorithme distribué est nécessaire pour un utilisateur secondaire pour prendre la décision sur l'accès au spectre de manière autonome.

- c) **Mobilité du spectre (Spectrum mobility)**

C'est le processus qui permet à l'utilisateur de la RC de changer sa fréquence de fonctionnement.

Les réseaux radio cognitive essayent d'utiliser le spectre de manière dynamique en permettant à des terminaux radio fonctionner dans la meilleure bande de fréquence disponible, de maintenir les exigences de communication transparentes au cours de la transition à une meilleure fréquence.

- **Auto-coexistence** : le canal cible ne doit pas être actuellement utilisé par un autre utilisateur secondaire.

- **Synchronisation** : le récepteur de la liaison secondaire correspondant doit être informé de la non-intervention du spectre.

## 8. Domaines d'application de la radio cognitive

Parmi les domaines d'application de la radio cognitive, on peut citer [5] :

- ✓ **Les réseaux sans fil de cinquième génération 5G :**

La radio opportuniste RC est apparue comme une technologie clé pour la 5<sup>ème</sup> génération des réseaux sans fil hétérogènes.

### ✓ **Coexistence de différentes technologies sans fil :**

IEEE 802.22, basée sur les utilisateurs WRAN (Wireless Regional Access Networks) peut utiliser efficacement la bande TV quand il n'y a pas d'utilisation du téléviseur à proximité ou quand une station de télévision ne diffuse pas.

### ✓ **Services de cyber santé (eHealth services) :**

Depuis que les équipements médicaux et les capteurs bio-signal sont sensibles aux interférences électromagnétiques, la puissance d'émission des appareils sans fil doit être soigneusement contrôlée.

En outre, différents dispositifs biomédicaux (équipement et appareils chirurgicaux, de diagnostic et de suivi) utilisent la transmission RF (Radio Frequency). L'utilisation du spectre de ces dispositifs doit être choisie avec soin pour éviter toute interférence avec l'autre. Dans ce cas, les concepts de la radio cognitive peuvent être appliqués.

### ✓ **Réseaux d'urgence :**

Les réseaux de sécurité publique et d'urgence peuvent profiter des concepts de la radio cognitive pour fournir la fiabilité et la flexibilité de communication sans fil.

### ✓ **Réseaux militaire :**

Avec la RC les paramètres de la communication sans fil peuvent être adaptés de manière dynamique en fonction du temps et de l'emplacement ainsi que de la mission des soldats.

## **9. Conclusion**

Nous avons présenté dans ce chapitre des notions importantes concernant la radio cognitive, ainsi que ses principes, en passant par une description de la radio logicielle [5].

En tenant compte des standards radios existants ou émergents, on peut constater que dans un même environnement, pourraient se trouver, dans une situation de coexistence, différentes interfaces radio, y compris le GSM, 3G, 4G, qui offrent une variété de services. D'un point de vue opérateur, une gestion optimisée du spectre s'impose pour pouvoir tirer le maximum de profit de la bande passante globale disponible.

La radio cognitive est un domaine technique aux frontières des télécommunications et de l'intelligence artificielle. Elle est, avant tout, un système radio qui met en place, en plus de sa fonction principale la communication, un "cycle cognitif" qui lui permet de comprendre son contexte et d'agir en conséquence. Cela offre aux utilisateurs un débit et une QoS accrus, globalement une augmentation du confort dans leurs communications. Pour assurer ces

fonctions, la radio cognitive doit pouvoir déterminer son emplacement géographique, repérer le brouillage, détecter l'occupation du spectre et recueillir de l'information sur la propagation, créant ainsi une sensibilisation à l'environnement radio [7].

# RÉFÉRENCES

- [1] V. Tarokh Editor, “*New Directions in Wireless Communications Research*,” University School of Engineering and Applied Sciences, Number: 2009928505 Springer Science Business Media, LLC 2009, pp.253-254, doi: 10.1007/978-1-4419-0673-1 Springer Dordrecht Heidelberg London New York.
- [2] A. G. Benbrahim, C. G. Jieman, “*Analyse d'une chaine de communication d'un réseau basé sur la radio cognitive*,” Mémoire de master, 24 juin 2013, pp.1-28.
- [3] I. Larbi, B. Benmammam, “*Négociation de spectre dans les réseaux de radio cognitive*,” Rapport de recherche (LTT), Université Abou Bekr Belkaid Tlemcen, Juin 2013, p.7.
- [4] N. Benghabrit, “Allocation des ressources dans les réseaux radio cognitifs,” Thèse Docteur, 19 Mars 2019, pp.1-23.
- [5] B. Benmammam, A. Amraoui, “*Réseaux de radio cognitive: Allocation des ressources radio et accès dynamique au spectre*,” LTT Laboratoire de Télécommunications Tlemcen, UABT, Algérie, pp.30-47.
- [6] B. Benmammam, “*Présentation de la radio cognitive*,” 3rd cycle. 2012. cel-00680189v1, pp.1-25, (HAL Id: cel-00680189.<https://cel.archives-ouvertes.fr/cel-00680189v1>).
- [7] Z. Amine, K. Chafâa, “*Gestion Intelligente de l'Allocation des Ressources Radio Cognitive*,” Mémoire de master, Université A/Mira de Béjaïa, 2018, p.15.

# CHAPITRE 02

### 1. Introduction

La radio cognitive (RC) est le mot de passe pour ouvrir la voie aux futurs réseaux sans fil, par ses nouvelles méthodes d'accès opportuniste et par sa gestion efficace des ressources radio. La RC peut résoudre le problème actuel de la rareté du spectre. Un système RC intelligent est conscient de son environnement. En apprenant le spectre radio à l'aide de la détection du spectre, de l'analyse des éléments de fréquence, de la détection de l'activité des utilisateurs principaux, il peut alors prendre des décisions sur les opportunités spectrales [1].

L'une des principales issues de la radio cognitive est la prédiction du spectre. L'ajout d'un bloc de prédiction à un système RC assure la connaissance préliminaire des états prochains du spectre, donc un accès sûr pour les utilisateurs secondaires (US), loin des interférences avec les utilisateurs principaux. Ces interférences sont dues aux retards causés par la détection du spectre, les retards de traitement et de prise de décision [2].

L'estimation de l'utilisation du spectre en plusieurs dimensions (le temps, la fréquence, l'espace, l'angle et le code), l'identification des opportunités dans ces dimensions et le développement d'algorithmes de prédiction peut être considéré comme des domaines de recherche encore ouverts [11].

### 2. Allocation spectrale statique des ressources radio

Le spectre radioélectrique disponible est une ressource naturelle limitée et devient de plus en plus encombré de jour en jour en raison de l'augmentation des appareils et des services sans fil. Il a également été constaté que le spectre alloué est sous-utilisé en raison de l'allocation statique du spectre. De plus, l'approche conventionnelle de la gestion du spectre est très rigide en ce sens que chaque opérateur sans fil se voit attribuer une licence exclusive pour fonctionner dans une certaine bande de fréquences. Et, avec la plupart du spectre radioélectrique utile déjà alloué, il est difficile de trouver des bandes vacantes pour déployer de nouveaux services ou pour améliorer ceux existants. Afin de surmonter cette situation, nous devons trouver un moyen d'améliorer l'utilisation du spectre, créant des opportunités d'accès dynamique au spectre [3].





L'utilisateur cognitif (UC) examine périodiquement l'état du canal (actif ou inactif) périodiquement et si l'émergence de l'utilisateur primaire (UP) sur ce canal est détectée dans l'intervalle de détection suivant, UC active sa communication dans un autre canal disponible comme indiqué sur la Figure II.2(a).

Comme dans cette approche, la transmission de données cesse pendant la détection du spectre, ce qui réduit le débit obtenu de l'UC. Mais la détection de l'apparition de UP est possible après un certain temps, ce qui entraîne une interférence au UP, et perte des données de la UC.

Par conséquent, afin d'exploiter toute la période de temps (T) pour la transmission de données, les chercheurs ont présenté une approche dans laquelle la détection et la transmission de données sont des phénomènes parallèles comme la montre dans la Figure II.2 (b). Pour cette fonctionnalité, UC comprend deux unités d'émetteur-récepteur, une pour la détection de spectre et l'autre pour la transmission de données. Ici, ce processus de détection concomitant à la transmission des données est appelé surveillance du spectre [7].

### 3.1. Définition de la détection du spectre

La détection du spectre est une fonction importante de la radio cognitive. L'utilisateur cognitif (UC ou US) doit analyser l'environnement radio afin de détecter le spectre inactif (ou trou spectral) et utiliser ce spectre inactif pour sa communication. L'opération de détection devrait également être capable de détecter instantanément et avec précision l'arrivée de l'utilisateur primaire (UP) sur la bande de fréquences, actuellement occupée par les utilisateurs secondaires (US) [8].

L'objectif principal de la détection du spectre est de détecter l'état du spectre, c'est-à-dire s'il est inactif ou occupé, de sorte qu'il puisse être utilisé par un utilisateur sans licence. En termes d'occupation, les sous-bandes du spectre radioélectrique peuvent être classées comme suit [6] :

- 1) Les espaces blancs, qui sont exempts de brouilleurs RF, à l'exception du bruit dû à des sources naturelles et / ou artificielles ;
- 2) Les espaces gris, qui sont partiellement occupés par des brouilleurs ainsi que du bruit ;
- 3) Les espaces noirs, dont le contenu est complètement plein en raison de la présence combinée de communications et (éventuellement) de signaux parasites et de bruit.




Figure II.3. Exemple d'un scénario d'occupation spectrale [9].

### 3.2. Classes de La détection du spectre

Une des méthodes de classification de détection spectrale est la classification qui dépend de l'objectif de détection, comme indiqué ci-dessous [3], [10] :

#### 3.2.1. La détection du spectre pour la détection des opportunités de spectre

##### a. Détection de l'émetteur principal

Dans ce cas, la détection des utilisateurs primaires est effectuée en fonction du signal reçu aux niveaux des utilisateurs de la RC. Cette approche comprend :

- ✓ Détection basée sur un filtre adapté (Matched filter 'MF') ;
- ✓ Détection d'énergie ;
- ✓ Détection de la covariance ;
- ✓ Détection de la forme d'onde ;
- ✓ Détection de la cyclostationnarité.

##### b. Détection coopérative et collaborative

Dans cette approche, les signaux primaires et les opportunités du spectre sont détectées de manière fiable en coopérant avec d'autres utilisateurs, et le procédé peut être mis en œuvre comme un accès centralisé au spectre coordonné par un serveur de spectre

### 3.2.2. Écoute spectrale pour la détection des interférences

#### a. Détection de température d'interférence

Dans cette approche, les utilisateurs secondaires coexistent avec les utilisateurs primaires et sont autorisés à transmettre avec une faible puissance et sont limités par le niveau de température d'interférence afin de ne pas causer interférences nuisibles aux utilisateurs primaires.

#### b. Détection du récepteur primaire

Dans cette méthode, les interférences et / ou les opportunités du spectre sont détecté sur la base de la puissance de fuite de l'oscillateur local du récepteur primaire.

La Figure II.4 représente la classification des techniques principales de la détection du spectre :

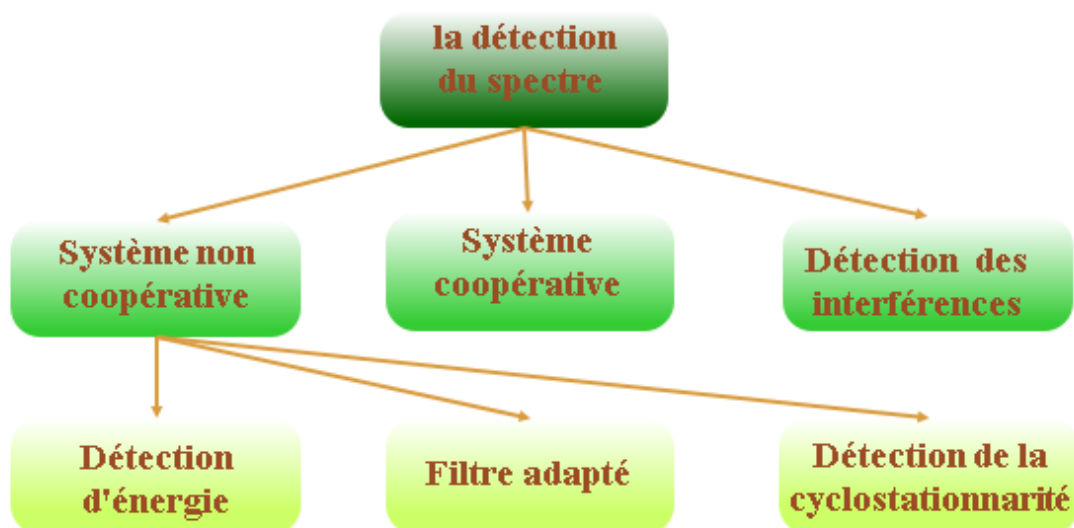


Figure II.4. Classification des techniques de détection du spectre [10].

## 4. Méthodes de la détection de spectre (spectrum sensing methods)

### 4.1. Détection d'énergie

Il s'agit d'une méthode de détection non cohérente qui détecte le signal primaire en fonction de l'énergie détectée. En raison de sa simplicité et de son absence de connaissance a priori du signal utilisateur primaire [3]. La détection de l'énergie (DE) (Energy detection) est la technique de détection la plus populaire en détection coopérative [12].




Figure II.5. Schéma fonctionnel du détecteur d'énergie [13].

Le schéma de principe de la technique de détection d'énergie est représenté dans la Figure II.5. Dans cette méthode, le signal est passé à travers le filtre passe-bande de la bande passante  $w$  et est intégré dans l'intervalle de temps. La sortie du bloc intégrateur est ensuite comparée à un seuil prédéfini. Cette comparaison est utilisée pour découvrir l'existence de l'absence de l'utilisateur principal. La valeur de seuil peut être fixée ou variable en fonction des conditions du canal.

Le DE est censé être le détecteur de signal aveugle car il ignore la structure du signal. Il estime la présence du signal en comparant l'énergie reçue avec un seuil connu dérivé des statistiques du bruit [13].

$$\begin{cases} y(k) = n(k) \dots \dots \dots H_0 \\ y(k) = h * s(k) + n(k) \dots \dots \dots H_1 \end{cases} \quad (II.1)$$

Les hypothèses  $H_0$ , absence  $H_0$  ou présence  $H_1$  d'une cible,  $s(k)$  est un signal aléatoire.

Où  $y(k)$  est l'échantillon à analyser à chaque instant  $k$  et  $n(k)$  est le bruit de variance  $\sigma^2$ , soit  $y(k)$  une séquence d'échantillons reçus  $k \{1, 2 \dots .N\}$  au niveau du détecteur de signal, puis une décision règle peut être énoncée comme suit [3]:

$$\begin{cases} H_0 \dots \dots \dots si \ \varepsilon < v \\ H_1 \dots \dots \dots si \ \varepsilon > v \end{cases} \quad (II.2)$$

$\mathcal{E} = E |y(k)|^2$  l'énergie estimée du signal reçu et  $v$  est choisi pour être la variance du bruit.

#### 4.2. Filtre adapté (Matched filter)

Un filtre adapté (MF) est un filtre linéaire conçu pour maximiser le rapport signal / bruit de la sortie pour un signal d'entrée donné. Lorsque l'utilisateur secondaire a une connaissance a priori du signal de l'utilisateur principal, la détection de filtre est appliquée. Le fonctionnement du filtre adapté équivaut à une corrélation dans laquelle le signal inconnu est convolé avec le

filtre dont la réponse impulsionnelle est le miroir et décalé dans le temps, version d'un signal de référence. Le fonctionnement de la détection de filtre adapté s'exprime comme suit [13] :

$$Y[n] = \sum_{k=-\infty}^{\infty} h[n-k] x[k] \quad (\text{II.3})$$

Où  $x$  est le signal inconnu (vecteur) et est convolé avec le  $h$ , la réponse impulsionnelle de filtre adapté qui est adapté au signal de référence pour maximiser le SNR. Détection utilisant le filtre en utilisant le filtre adapté n'est utile que dans les cas où les informations des utilisateurs principaux sont connues pour les utilisateurs cognitifs.



Figure II.6. Schéma fonctionnel du filtre adapté [13].

### 4.3. Détection de la cyclostationnarité

La détection de cyclostationnarité est une méthode de détection de la manière de transmissions des utilisateurs primaires en exploitant les caractéristiques de la cyclostationnarité des signaux reçus.

Les caractéristiques cyclostationnaires sont causées par la périodicité du signal ou dans ses statistiques comme la moyenne et l'autocorrélation ou ils peuvent être induits intentionnellement pour aider à la détection du spectre. Au lieu de la densité spectrale de puissance (PSD) (power spectral density), la fonction cyclique de corrélation est utilisée pour détecter les signaux présents dans un spectre donné [11].

Les algorithmes de détection basés sur la cyclostationnarité peuvent différencier le bruit des signaux des utilisateurs principaux. Ceci est le résultat du fait que le bruit est stationnaire au sens large (WSS) (wide sense of stationarity) sans corrélation alors que les signaux modulés sont cyclostationnaires avec corrélation spectrale due à la redondance des périodicités des signaux. De plus, la cyclostationnarité peut être utilisé pour distinguer les différents types de transmissions et les utilisateurs primaires [14].

La fonction de densité spectrale cyclique (CSD) (cyclic spectral density) d'un récepteur du signal peut être calculée comme suit [11] :

$$S(f, \alpha) = \sum_{\tau=-\infty}^{\infty} R_y^\alpha(\tau) e^{-j2\pi f\tau} \quad (II.4)$$

$$R_y^\alpha(\tau) = E[y(n + \tau)y^*(n - \tau)e^{j2\pi\alpha n}] \quad (II.5)$$

$R_y^\alpha(\tau)$  est un processus stationnaire de l'autocorrélation statistique,  $\tau$  son retard évolue au cours du temps,  $S(f, \alpha)$  La fonction d'autocorrélation cyclique (CAF) (cyclic autocorrelation function) et  $\alpha$  est la fonction cyclique de la fréquence. La fonction CSD (cyclic spectral density) génère des valeurs de crête lorsque la fréquence cyclique est égale aux fréquences fondamentales de signal transmis  $x(n)$ . Les fréquences cycliques et la fonction d'autocorrélation cyclique (CAF) (cyclic autocorrelation function) peuvent être extraits et utilisés comme caractéristiques pour identifier les signaux transmis [11].

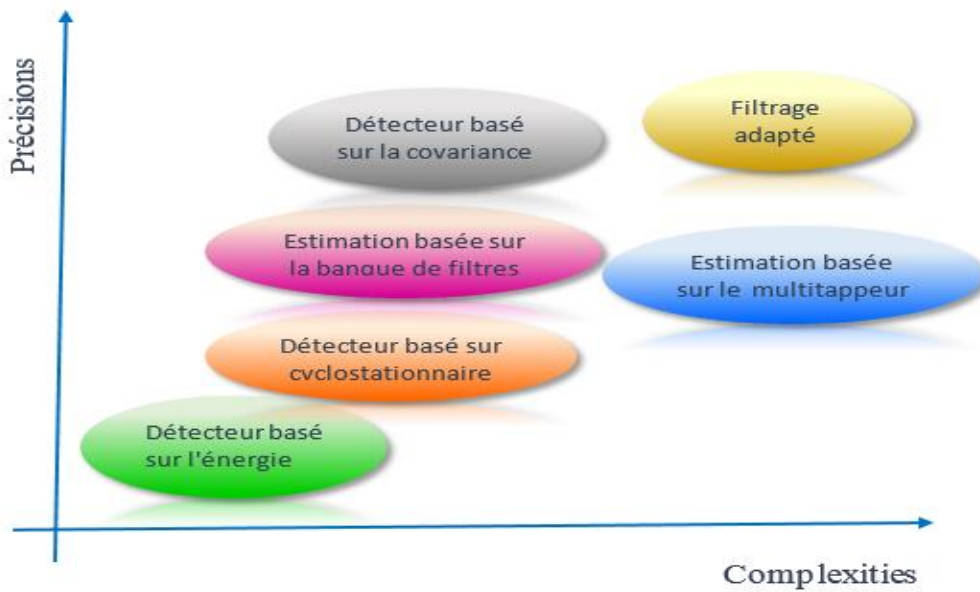


Figure II.7. Précision et complexité de détection de diverses méthodes de détection [3].

#### 4.4. Comparaison des techniques de détection

Tableau II.1. Les avantages et Les inconvénients des méthodes de l'écoute spectrale [15] :

Méthodes de détection	Avantages	Inconvénients
Détection d'énergie	-Facile à mettre en œuvre. -Faible complexité.	-Ne convient pas lorsque l'attaquant peut imiter les paramètres d'UP.

	- Aucune connaissance préalable de l'énergie d'UP n'est requise.	-Technique de détection du spectre. -Limité aux UP fixes. -Des nœuds plus efficaces sont requis.
<b>Filtre adapté</b>	-Robuste contre le bruit -Les caractéristiques de l'UP peuvent être émulées facilement.	-Exige une connaissance préalable du signal UP - Impossible de distinguer le signal UP légitime et ceux de l'utilisateur malveillant.
<b>cyclostationarité (rapport cyclostationnaire)</b>	-Robuste dans la détection du signal UP.	- Les caractéristiques d'UP peuvent être facilement émulées. .

### 5. Prédiction du spectre

La prédiction du spectre est connue comme une technique complémentaire utile à la détection du spectre pour capturer les informations pertinentes sur l'évolution spectrale et identifier les trous dans le spectre. La détection de spectre détermine l'état du spectre de manière passive en utilisant plusieurs méthodes de détection de signaux. La prédiction du spectre est par ailleurs une technique utilisée pour déduire l'état du spectre à partir des informations collectées dans le réseau et une exploitation efficace des corrélations inhérentes entre elles [17].

#### 5.1. Motivations pour la prédiction

Un utilisateur RC détecte séquentiellement les bandes de fréquence, et construit un groupe de spectre composé de tous les vides découverts pendant l'étape de détection. Il sélectionne un canal du groupe pour ses propres transmissions au stade de la décision en matière de spectre. Afin d'améliorer la capacité du canal, L'utilisateur du RC peut repérer de multiples lacunes, ce qui pourrait entraver le renforcement des capacités des réseaux RC comme indiqué ci-dessous, ce qui pourrait entraver le renforcement des capacités des réseaux RC comme indiqué ci-dessous [16]:

- ✓ La détection du spectre à large bande se traduit par un effet non négligeable de retards ;
- ✓ Décision de spectre basée sur les résultats de détection en temps réel compromet l'efficacité de l'utilisation du spectre en raison des retards introduits par la détection et la prise de décision ;

- ✓ Dans le partage du spectre, les utilisateurs RC peuvent accéder au spectre à des moments différents avec différentes exigences de bande passante et exigences de QoS ;
- ✓ L'attribution des bandes de spectre appropriées aux demandes de service RC hétérogènes, en rafales, peut entraîner des retards considérables, ce qui se traduit par une faible efficacité des politiques traditionnelles de partage de spectre ;
- ✓ Politique d'accès au spectre traditionnelle basée sur AMCS (Accès multiple Carrier Sensé) entraîne toujours des collisions de transmission puisque l'utilisateur R ne pas évacuer son canal occupé jusqu'à ce qu'un UP est détecté ;
- ✓ Néglige les caractéristiques inhérentes aux séries chronologiques ;
- ✓ Détection imparfaite de la tendance des données locales ;
- ✓ Faible précision des prévisions.

### 5.2. Définition de la prédiction du spectre

La prédiction du spectre est un processus dans lequel l'état avenir du canal est prévu sur la base des informations historiques de la chaîne. De plus, l'instant du temps de la disparition et de la réapparition d'UP sur le canal peut également être prévu. Divers chercheurs ont exploité le concept de prévision du spectre pour améliorer les performances de détection du spectre en exploitant uniquement les canaux prévus d'être libres à la détection, qui améliorent les performances de la détection et contribue à l'amélioration globale du système de communication [7]. La prédiction du spectre est une approche prometteuse pour améliorer les fonctions radio cognitives [17].

### 5.3. Nécessité de la prédiction dans les réseaux radio cognitifs

Les utilisateurs secondaires (cognitifs) effectueraient une détection du spectre pour garantir leur accès opportun au spectre sous licence. Cette opération est effectuée en temps réel et en balayant les bandes de spectre entières. Elle entraîne des retards non négligeables et une augmentation de la consommation d'énergie. Après avoir détecté les vides du spectre, un processus de prise de décision est suivi, ce qui entraîne un retard supplémentaire. De cette façon, un SU tardera à entrer la bande de fréquence. Il perd donc une partie de sa bande attribuée (sous-utilisation) et réduit ainsi l'efficacité spectrale. Ce retard peut provoquer des interférences avec les bandes d'occupation des UP. De plus, les interférences seront plus importantes si des utilisateurs (multi-RC utilisateurs) rejoignent le spectre en même temps ou à des moments différents avec des exigences de bande passante et des exigences de qualité de service (QoS) différentes. Ainsi, l'attribution de bandes de spectre appropriées aux demandes de service CR



hétérogènes en rafale compliquera la gestion du spectre à l'aide des politiques traditionnelles de partage du spectre [1].

Par conséquent, la meilleure façon de résoudre tous ces problèmes est d'ajouter un processus de prédiction pour rendre cette fonction plus intelligente et plus efficace. De cette façon, les US ne détectent que les bandes de spectre qui devraient être libres en temps et d'espace et sélectionnent un canal de haute qualité pour la détection et l'accès. Ainsi, pour augmenter l'efficacité de leurs accès dynamique au spectre au lieu de détecter l'ensemble des bandes sous licence, ils sélectionnent un canal de haute qualité pour détection et accès. Ceci va diminuer le temps de détection et par conséquent réduit la consommation d'énergie [1].

### **6. Méthodes de prédiction du spectre dans les réseaux de la radio cognitive**

Nous présentons dans ce qui suit quelques techniques de prédiction et leurs applications dans les réseaux radio cognitifs.

#### **6.1. Prédiction linéaire (LP)**

Les prédicteurs linéaires sont largement utilisés dans le traitement numérique du signal, en raison de leur simplicité remarquable. Pour déduire la puissance du signal, les valeurs futures sont prédites en fonction linéaire des échantillons précédents. Selon une fonction linéaire. Les modèles de prédiction linéaire les plus courants sont le modèle autorégressif (AR), le modèle à moyenne mobile (MA), le modèle de la moyenne mobile autorégressive (ARMA) et le modèle de la moyenne mobile intégrée autorégressive (ARIMA) [17].

#### **6.2. Modèle de Markov (MM)**

Le modèle de Markov de premier ordre est la méthode de prédiction la plus simple a cause de sa structure, de ses paramètres d'estimation minimisés et de sa précision de prédiction. Pour prédire l'état futur, ils utilisent des informations pertinentes de l'état présent et non pas des informations du passé lointain. Ce qui en fait un modèle sans mémoire. C'est aussi le modèle le plus approprié pour prévoir des séries temporelles. Son inconvénient est qu'il implique un retard de décision qui diminue l'efficacité spectrale. Afin de surmonter cette lacune, on a proposé le modèle de Markov d'ordre N, qui prend en compte davantage d'informations précédentes. On constate alors qu'avec l'augmentation de l'ordre, la complexité augmente de façon exponentielle, ce qui conduit à l'augmentation du délai de prédiction du modèle [1].

#### **.6.3. Inférence Bayésienne (BIF)**

Le modèle BIF est l'une des méthodes de prédiction classiques dans réseau radio cognitif RRC. Habituellement, BIF est implémenté comme une partie critique des systèmes Markov. En effet, le schéma BIF peut être défini en bref comme une dérivation des distributions de probabilité du système. Ces distributions vont être décrites comme suit [18] :

La distribution de probabilité a priori  $P$  d'un paramètre  $\theta$  noté  $P(\theta)$  ;

- ✓ La distribution de probabilité postérieure, est la distribution d'un paramètre système  $\theta$  habitué aux données  $X = \{x_1, x_2, \dots, x_n\}$  observées à partir d'une expérience. Par conséquent, la distribution de probabilité postérieure de  $\theta$  peut être notée  $P(\theta/X)$ ;
- ✓ La fonction de vraisemblance du paramètre  $\theta$  est notée  $L(\theta/X)$  et définit la probabilité des données observées  $X = \{x_1, x_2, \dots, x_n\}$  sur la base du paramètre  $\theta$ . Autrement dit,  $L(\theta/X) = P(\theta/X)$  [2].

#### 6.4. Prédiction basée sur les Réseaux de Neurones Artificiels (RNA)

Les réseaux de neurones artificiels est une structure de calcul complexe composée de neurones non linéaires qui sont disposés en couches (couches d'entrée, couches cachées et couche de sortie) et hautement interconnectés à l'aide de connexions de poids adaptatifs pour rapporter les informations de la couche précédente à la suivante. Les neurones sont essentiellement les éléments de traitement qui reçoivent la somme pondérée de ses entrées et produisent une sortie via une fonction d'activation non linéaire [19].

De cette façon, les RNA sont classées comme modèles de régression non linéaire [18], discriminants et de réduction de données. De ce fait, il est considéré comme un mécanisme analysé et d'apprentissage de grandes quantités de données pour trouver des modèles et détecter des relations non linéaires entre entrée et sortie. En revanche, ils ont besoin d'une grande quantité de données de formation pour assurer une prédiction de haute précision [2].

## CHAPITRE II : Détection et Prédiction spectrale

**Tableau II.2.** Les avantages et Les inconvénients de différentes méthodes de prédiction [17].

Les méthodes	Les avantages	Les inconvénients
<b>LP</b>	<ul style="list-style-type: none"> <li>- Faible complexité pour les petites commandes</li> <li>- Convergence garantie</li> <li>- N'a pas besoin de seuil</li> </ul>	<ul style="list-style-type: none"> <li>- Nécessite des informations sur l'apprentissage</li> <li>-Dépend de processus stationnaires</li> <li>- Grande erreur cumulée pour les commandes élevées</li> </ul>
<b>MM</b>	<ul style="list-style-type: none"> <li>- Robustesse dans le traitement des séquences temporelles</li> <li>- Flexibilité dans les scénarios non stationnaires</li> <li>- Des bases statistiques solides</li> </ul>	<ul style="list-style-type: none"> <li>- Besoin d'une grande mémoire</li> <li>- Difficile de trouver le nombre optimal d'états</li> <li>- Les modèles gaussiens discrets ne sont pas compétents</li> </ul>
<b>BIF</b>	<ul style="list-style-type: none"> <li>- Les intervalles de confiance n'affectent pas les connaissances a priori</li> <li>- Mettre à jour les distributions de probabilité dans chaque observation</li> <li>- Il est modulaire, permettant l'ajout de variables et d'analyses après implémentation</li> </ul>	<ul style="list-style-type: none"> <li>- Temps de calcul intensif</li> <li>- Trouver des fonctions antérieures peut devenir complexe</li> </ul>
<b>NN</b>	<ul style="list-style-type: none"> <li>- Adaptation à des situations inconnues</li> <li>- Modélisation non linéaire des fonctions</li> <li>- Haute précision et tolérance au bruit</li> <li>- Convient aux environnements continus ou discrets</li> </ul>	<ul style="list-style-type: none"> <li>- Sur-ajustement possible de l'apprentissage</li> <li>- Coût informatique élevé</li> <li>- Structures de configuration multiples</li> <li>- Presque impossible à modifier ou à régler</li> </ul>

### 7. Conclusion

La prédiction du spectre est essentielle au développement et à la mise en œuvre éventuelle de la radio cognitive. En raison de la nature aléatoire du spectre qui varie d'un endroit à l'autre, il est nécessaire de mieux comprendre cette ressource rare afin que son comportement puisse être prédit avec peu ou pas d'erreur [20].

La compréhension de l'état du spectre pourrait être obtenue grâce à des mesures approfondies qui peuvent aider à développer un réseau radio cognitif. Elle nécessite l'implication et l'interaction de nombreuses techniques avancées.

Il existe de nombreux modèles de prédictions qui pourraient aider à réduire le temps de détection et la consommation d'énergie dans les systèmes radios cognitives. Parmi ces modèles, on peut citer la prédiction linéaire, la prédiction par Modèle de Markov, la prédiction par Inférence bayésienne et la prédiction par l'intelligence artificielle. Les meilleures méthodes innovantes de la prédiction utilisent des mécanismes hybrides qui améliorent les performances des méthodes traditionnelles et surmontent certains problèmes [1].

Contrairement à d'autres modèles, les modèles basés sur les réseaux neuronaux sont plus rapides une fois que le modèle a été conçu. Dans ce modèle, on utilise une base de données de géolocalisation qui contient des informations sur l'environnement actuel. Cette méthode basée sur l'apprentissage automatique pourrait s'avérer très efficace en raison de sa capacité à se mettre à jour chaque fois que de nouvelles informations sont disponibles [20]. La méthode de prédiction basée sur les réseaux de neurones artificielles sera présentée dans le chapitre III suivant.

# RÉFÉRENCES

- [1] S. Tidjani, Z. Hammoudi, “*A Survey on Spectrum Prediction Methods in Cognitive Radio Networks*,” in the Fourth International Conference on Trends in Computing and Information Technology (ICTCIT), International Journal of Computing Academic Research (IJCAR), ISSN 2305-9184, Vol.8, No 2, pp.24-31, April 2019.
- [2] J. Wu, Y. Li, “*A survey of spectrum prediction methods in cognitive radio networks*,” In: AIP Conference Proceedings. AIP Publishing LLC, p.020018, 2017, <https://doi.org/10.1063/1.4981557>.
- [3] M. Subhedar, G. Birajdar, “*Spectrum sensing techniques in cognitive radio networks: A survey*,” International Journal of Next-Generation Networks, Vol.3, No 2, pp. 37-51, 2011.
- [4] M. Ghozzi, “*Recherche de nouvelles ressources spectrales: Radio Cognitive et détection des bandes libres*,” Journée Radio Intelligente GDR/ISIS, France Telecom R&D, p.4, 24 Mai 2007.
- [5] S. Dahi, “*Acces et gestion des ressources radio dans les réseaux radio cognitives*,” Thèse de doctorat, Technologies de l’Information et de la Communication, L’Ecole Supérieure des Communications de Tunis (Sup’Com), p.12, 12 décembre 2015.
- [6] S. Haykin, D. J. Thomson, J. H. Reed, “*Spectrum sensing for cognitive radio*,” Proceedings of the IEEE, Vol.97, No 5, pp. 849-877, 2009, doi: 10.1109/JPROC.2009.2015711.
- [7] P. Thakur, et al, “*Spectrum mobility in cognitive radio network using spectrum prediction and monitoring techniques*,” Physical Communication, Vol.24, pp. 1-8, 2017, <https://doi.org/10.1016/j.phycom.2017.04.005>.
- [8] R. Zitouni, “*Software Defined Radio for Cognitive Wireless Sensor Networks: A reconfigurable Ieee 802.15. 4 Standard*,” Thèse de doctorat, Informatique, Université Paris-Est, p.36, 14 Octobre, 2015, <https://tel.archives-ouvertes.fr/tel-01361325>.
- [9] A. Ben Dhaou, “*Allocation dynamique des bandes spectrales dans les réseaux sans-fil à radio cognitive*,” Thèse de doctorat, comme exigence partielle de la maîtrise en informatique, Université Du Québec à Montréal, p.8, Septembres 2011, <http://www.archipel.uqam.ca/4368/1/M12175>.

- [10] E. Hossain, D. Niyato, Z. Han, “*Dynamic Spectrum Access and Management in Cognitive Radio Networks*,” Press, united kindom, Cambridge University, 2009, pp.39-95, ISBN 0521898471, 9780521898478.
- [11] T. Yucek, H. Arslan, “*A survey of spectrum sensing algorithms for cognitive radio applications*,” IEEE communications surveys & tutorials, Vol.11, No1, 2009, pp. 116-130, doi: 10.1109/SURV.2009.090109.
- [12] G. Ganesan, Y. Geoffrey-Li, “*Agility improvement through cooperative diversity in cognitive radio*,” School of Electrical and Computer Engineering Georgia Institute of Technology, Atlanta, GLOBECOM 05, IEEE Global Telecommunications Conference, IEEE, 2005, p. 2506, doi: 10.1109/GLOCOM.2005.1578213.
- [13] S. A. Malik, et al, “*Comparative analysis of primary transmitter detection based spectrum sensing techniques in cognitive radio systems*,” Australian journal of basic and applied sciences, Vol. 4, No 9, pp.4525-4527, ISSN 1991-8178, INSI net Publication 2010.
- [14] D. Cabric, R. w. Brodersen, “*Physical layer design issues unique to cognitive radio systems*,” In: 2005 IEEE 16th International Symposium on Personal, Indoor and Mobile Radio Communications. IEEE, Vol.2, pp. 759-763, September 2005, doi: 10.1109/PIMRC.2005.1651545.
- [15] F. Salahdine, N. Kaabouch, “*Security threats, detection, and countermeasures for physical layer in cognitive radio networks: A survey*,” Physical Communication, Vol. 39, p.12, 2020, journal homepage: [www.elsevier.com/locate/phycom](http://www.elsevier.com/locate/phycom).
- [16] X. Xing, T. Jing, W. Cheng, “*Spectrum prediction in cognitive radio networks*,” IEEE Wireless Communications, Vol.20, No 2, pp. 90-96, 2013.
- [17] L. M. Tuberquia-David, L. Cruz, C. Hernández, “*Spectral prediction: approaches in cognitive radio networks*,” International Journal of Applied Engineering, Vol.13, No10, pp. 8051-8063, Research India Publications. <http://www.ripublication.com>.
- [18] X. Xing, et al, “*Channel quality prediction based on Bayesian inference in cognitive radio networks*,” In: 2013 Proceedings IEEE INFOCOM., pp. 1465-1473, April 2013, E-mail: {10120170, tjing, yhuo}@bjtu.edu.cn, {hongjuan, cheng}@gwu.edu.
- [19] G. Phillips-Wren, “*Ai tools in decision making support systems: a review*,” International Journal on Artificial Intelligence Tools, Loyola University Maryland, Sellinger

School of Business, Vol. 21, No 02, Apr. 2012, p. 1240005,

<https://www.worldscientific.com/doi/pdfplus/10.1142/S0218213012400052>.

[20] B. Gafai-Najashi<sup>1</sup>, F. Wenjiang, M. Dikko-Almustapha, “*Spectrum hole prediction based on historical data: A neural network approach,*” College of Communication Engineering, Chongqing University, IJCSI International Journal of Computer Science Issues, Vol. 10, Issue 4, No 2, July 2013, ISSN (Print): 1694-0814 |ISSN (Online): 1694-0784694-0814, [www.IJCSI.org](http://www.IJCSI.org).

# CHAPITRE 03



### 1. Introduction

La détection de bandes libres constitue l'opération la plus coûteuse en termes de temps de traitement et de consommation énergétique pour un équipement radio mobile. Qui apparaîtrait inefficace et surtout inopportun. Un mécanisme de prédiction du spectre mesurant les probabilités des états prochaines des canaux (libre ou occupé) permettrait de réduire considérablement la fréquence des scans et assurerait un choix intelligent du canal à balayer. Toutefois, les solutions de prédictions actuelles présentent des faiblesses [1].

Grâce aux résultats obtenus au cours de la dernière décennie, les réseaux de neurones connaissent un succès croissant au niveau de la prédiction spectrale, et ont prouvé leur efficacité dans plusieurs domaines : comme le traitement de signal, l'identification des paramètres, la commande des procédés, l'estimation et la détection des défauts. Ils demeurent toutefois un sujet d'un grand intérêt pour les chercheurs qui désirent améliorer les performances de ces réseaux et étendre leur champ d'applications [7].

Dans ce chapitre, la procédure de préparation de la base de données (input / output) et de simulation du réseau de neurones proposé sont mis en œuvre. Une étude comparative de quelques modèles de prédictions a été effectuée sur la bande GSM 900.

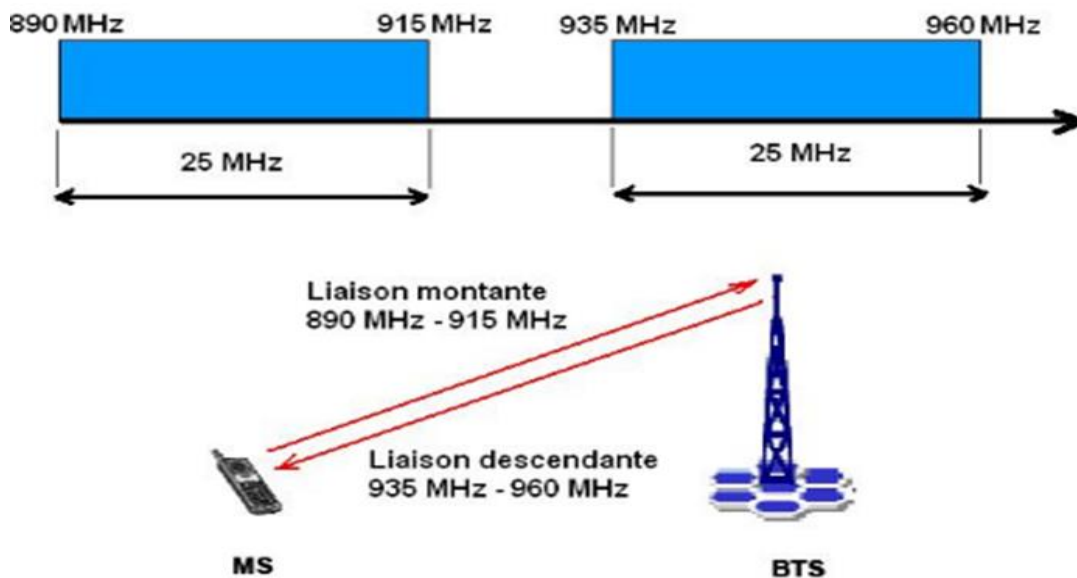
### 2. Répartition de la bande GSM

Un système radio-mobile a besoin d'une partie du spectre radio pour fonctionner. Pour une uniformisation au niveau mondiale, cette bande doit être allouée au niveau de l'UIT (Union International des Télécommunications), permettant une compatibilité réelle entre les différents organes du système à travers le monde entier [2].

La bande radio représente la ressource rare et le premier choix architectural fût le découpage du spectre alloué dans un plan temps/fréquence pour obtenir des canaux physiques pouvant supporter une communication téléphonique [2].

Le GSM opère dans la bande des 900 MHz, où 2 fois 25 MHz de bandes ont été allouées. Les deux parties correspondent au sens montant et au sens descendant de la liaison (Up Link et Down Link). La largeur des canaux étant de 200 kHz, on obtient 124 canaux duplex. Les bandes des deux liaisons ont en outre été séparées par 20 MHz, ce qui porte à 45 MHz l'écart duplex. Sur une bande, on émet des signaux modulés autour d'une fréquence porteuse qui siège au centre de la bande [2].

✓ La bande 890-915 MHz pour le sens mobile vers le réseau (Voie montante ou Up Link) ;



**Figure III.1.** Les bandes fréquentielles du GSM [2].

On appelle écart duplex la différence entre deux fréquences correspondantes Up Link et Down Link. Pour le GSM 900, Il est constant et vaut 45 MHz.

On appelle écart adjacent la différence entre deux fréquences consécutives Up Link ou Down Link. Pour le GSM 900, Il est constant et vaut 200 KHz.

Chaque porteuse (canal) GSM est identifié de manière unique par un numéro  $n$ , désigné par le sigle ARFCN (Absolute Radio Frequency Channel Number), codé sur 10 bits où la fréquence de la voie descendante est exprimée en MHz. Pour le GSM 900, si on indique par  $F_u$  les fréquences porteuses montantes et par  $F_d$  les fréquences porteuses descendantes, les valeurs des fréquences porteuses valent [2] :

- ✓  $F_u(n) = 890 + 0.2 \times n$  avec  $n = 1 : 124$
- ✓  $F_d(n) = 935 + 0.2 \times n$  avec  $n = 1 : 124$

Le multiplexage temporel consiste à diviser chaque canal de communication en 8 intervalles de temps de 0, 577 ms chacun appelé slot.

Un mobile n'utilisera qu'un time slot pour une communication bien précise, on pourra ainsi faire travailler jusqu'à 8 mobiles différents sur la même fréquence porteuse [2].

L'accès TDMA, (Time Division Multiple Access), permet aux différents utilisateurs de partager une bande de fréquence donnée. Sur une même porteuse, les slots sont regroupés par paquets de 8. La durée d'une trame TDMA est donc [2] :

$$\checkmark T_{\text{TDMA}} = 8 * T_{\text{Slot}} = 4.6152 \text{ ms}$$

### 3. Base de données

Les données utilisées dans cette étude ont été pris de la bande GSM900 up Link et down Link. Où Le GSM-900 utilise 890 - 915 MHz pour envoyer des informations de la station mobile à la station de base 'BTS' (liaison montante), et 935 - 960 MHz pour l'autre sens (liaison descendante), fournissant 124 canaux RF (numéros de canal 1 à 124) espacés de 200 kHz. Donc nous avons divisé la bande passante en 250 échantillons et 288 instants du temps pour les 24 heures, à partir desquels nous avons une matrice de 250 lignes et 288 colonnes.

- ✓ La bande montante (MS → BTS) de 890 à 915 MHz = 25 MHz  
⇒ 25MHZ / 200KHZ = 125 canaux ;
- ✓ La bande descendante (BTS → MS) de 935 à 960 MHz = 25 MHz  
⇒ 25MHZ / 200KHZ = 125 canaux ;
- ✓ (125 +125) = 250 sous-bandes ou canal ;
- ✓ Chaque canal est mesuré chaque 5minutes pour les 24heurs  
⇒ 1Jour = 24 heures, avec Temps d'échantillonnage = 5min ;  
⇒ (24 \* 60) ÷ 5 = 288 échos / jour / canal.

$$\text{On obtient : } \begin{bmatrix} X_{11} & X_{12} & X_{13} \cdots \cdots & X_{1 \ 250} \\ X_{21} & X_{22} & X_{23} \cdots \cdots & X_{2 \ 250} \\ X_{31} & X_{32} & X_{33} & X_{3 \ 250} \\ \vdots & \vdots & \vdots & \vdots \\ X_{288 \ 1} & X_{288 \ 2} & X_{288 \ 3} & X_{288 \ 250} \end{bmatrix}$$

Les réseaux de neurones artificiels sont appliqués sur ces données, où la base de données est divisée aléatoirement en trois parties bien distinctes :

- ✓ Celle destinée à l'apprentissage pour reconnaître la dynamique du système elle est la plus importante des parties (70%) ;
- ✓ Celle de la validation qui est utilisée après l'arrêt de l'apprentissage et l'enregistrement des poids des interconnexions du modèle le plus performant. La partie de données de validation (15%) permet une confirmation de la performance du modèle du réseau de neurones calculé ;

✓ Celle du test (15%) qui évite le sur-apprentissage en vérifiant et testant l'évolution des deux erreurs d'apprentissage.

### 4. Réseau de neurones

Le réseau de neurones artificiels (RNA) est une copie artificielle inspirée du fonctionnement du système neural du cerveau humain. Comme le prouve dans cette étude, les RNA présentent de nombreux avantages qui leur permettent d'avoir le succès de résoudre différents phénomènes complexes dans différents domaines [4].

Toutefois, un réseau de neurones artificiel (RNA) est un système de traitement de l'information non algorithmique, analytique et massivement parallèle. Il est composé de couches d'unités parallèles appelées neurones. Ces neurones, étant connectés par un grand nombre de liaisons pondérées, reçoivent des entrées sur leurs connexions entrantes, effectuent des opérations non linéaires en général et produisent les résultats finaux [5].

Le réseau de neurones artificiels a été appliqué dans divers aspects des nouvelles technologies. Il est également largement utilisé dans la prévision des problèmes en raison de sa simplicité en termes de formation. Alors que d'autres graphiques de prévision nécessitent une formation continue [6].

#### 4.1. Architecture d'un réseau de neurones

Selon la topologie de connexion des neurones, on peut les classer en deux grandes catégories : réseaux non bouclés (statique ou feed forward) et réseaux bouclés (dynamique, feed back ou récurrent) [7].

##### 4.1.1. Réseaux statiques (feed-forward)

Un réseau de neurones non bouclé (appelé aussi statique) est représenté comme un graphe dont les nœuds sont les neurones. L'information circule des entrées vers les sorties sans retour en arrière. Ce type de réseaux est utilisé pour effectuer des tâches d'approximation de fonction non linéaire, de la classification ou de la modélisation de processus statiques non linéaires [7].

L'architecture feed-forward est là où les connexions sont anticipées, cela signifie qu'un neurone n'acceptera pas une entrée d'un neurone il a précédemment alimenté [6].

### 4.1.2 Réseau récurrents (Feed-back)

Un réseau bouclé (récurrent), régi par une ou plusieurs équations différentielles, résulte de la composition des fonctions réalisées par chacun des neurones et des retards associés à chacune des connexions [7]. Les réseaux récurrents permettent également une rétroaction entre les neurones [6]. Le comportement dynamique d'un réseau de neurones bouclé peut être décrit par une représentation d'état paramétrée par les coefficients [7].

### 4.2. Perceptron multicouche (Multi-layer Perceptron)

Le Perceptron multicouche (MLP) est un classificateur linéaire de type réseau neuronal formel organisé en plusieurs couches au sein desquelles une information circule de la couche d'entrée vers la couche de sortie uniquement, et chaque couche est constituée d'un nombre variable de neurones. Un diagramme schématique de l'architecture de base est montré sur la Figure III.5 [5].

Le neurone est relié à plusieurs entrées d'où il reçoit de l'information de chacune, qui sont présentées par  $X_1, X_2, X_3, \dots, X_n$ . Les connexions des neurones n'ont pas la même importance, ils sont liés au poids synoptiques  $W_n$  affectés à chaque connexion.

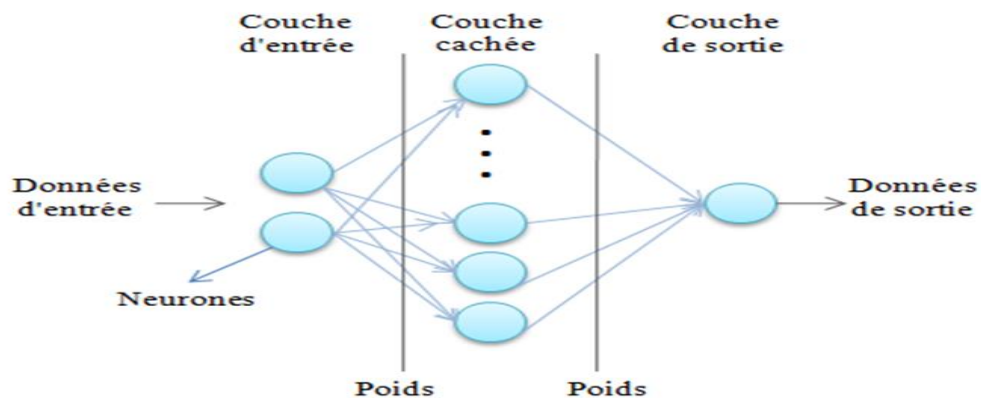
Chaque poids possède une valeur notée  $W_{ij}$ . Cette notation, la plus répandue dans la littérature scientifique, désigne le poids allant d'un neurone formel  $i$  au neurone formel  $j$ . Chaque poids transmet une information un stimulus provenant du neurone source  $i$  noté  $X_i$ . Ce stimulus (sa valeur) correspondant à l'information envoyé par le neurone source  $i$  est modulé par le poids liant les neurones  $i$  et  $j$ . Mathématiquement cela se traduit par [8] :

$$y_k = S\left(\sum_{i=0}^N w_{ij} * x_i\right) \quad (\text{III.1})$$


$S$  : est une fonction de transfert qui peut être une fonction de base sigmoïde, tangente hyperbolique ou radiale. La sortie finale de la dernière couche est calculée de la même manière. Un diagramme schématique simplifié de ce réseau est montré sur la Figure III.4 Les principales caractéristiques de ce modèle à mentionner [5], [9] :

✓ Couche d'entrée : les neurones de cette couche reçoivent les valeurs d'entrée du réseau et les transmettent aux neurones cachés. Chaque neurone reçoit une valeur, il ne fait pas donc de sommation ;

- ✓ Couche cachée (l'utilisateur peut changer le nombre de neurones cachés) : chaque neurone de cette couche reçoit l'information de plusieurs couches précédentes, effectue la sommation pondérée par les poids, puis la transforme selon sa fonction d'activation qui est en général une fonction sigmoïde. Par la suite, il envoie cette réponse aux neurones de la couche suivante ;
- ✓ Couche de sortie : elle joue le même rôle que les couches cachées, la seule différence entre ces deux types de couches est que la sortie des neurones de la couche de sortie n'est liée à aucun autre neurone ;
- ✓ L'algorithme d'apprentissage est une rétropropagation basée sur une méthode de minimisation de (Levenberg-Marquardt) LM qui est la plus utilisée ;
- ✓ La procédure d'apprentissage est contrôlée par une technique de validation croisée basée sur une division aléatoire de l'ensemble initial de données en 3 sous-ensembles (formation, contrôle du processus de validation et tests).



**Figure III.2.** Réseau de perceptrons multicouches (MLP) [10].



**Figure III.3.** Diagramme du MLP utilisé dans MATLAB [5].

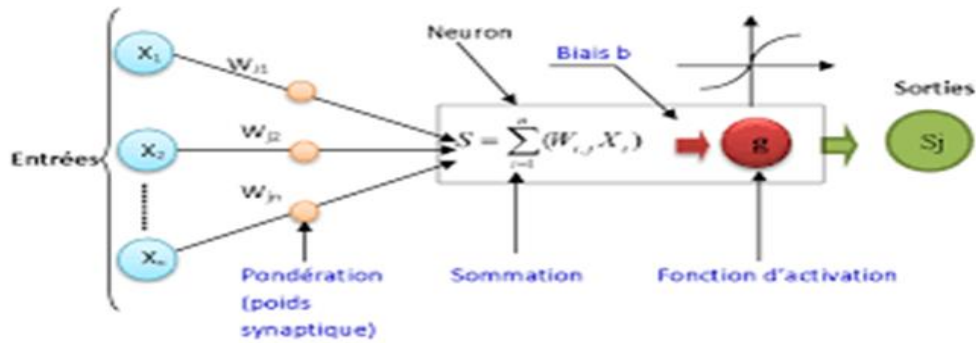


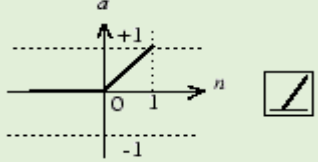
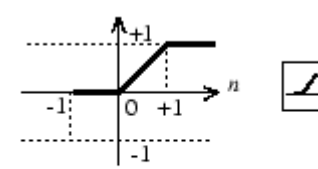
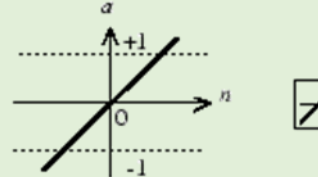
Figure III.4. Architecture du fonctionnement d'un neurone artificiel [7].

### 4.3. Fonctions d'activation (fonctions de transfert)

Les fonctions d'activation, également connues sous le nom de fonction de transfert, sont utilisées pour mapper les nœuds d'entrée vers les nœuds de sortie d'une certaine manière. Cette fonction, linéaire ou non, génère un signal de sortie qui est envoyé à la couche suivante. Le choix de cette fonction est un élément important dans les RNA. Cette dernière qui est une fonction de régression non linéaire, est généralement la plus utilisée par les RNA pour modéliser les paramètres non linéaires [5]

Tableaux III.1. Les fonctions de transfert couramment utilisées et leurs courbes [11].

Fonction de transfert	Équation	1D Graph
Hardlims	$a = \text{Hardlims}(n) = \begin{cases} 1 & \text{Si } n \geq 0, \\ -1 & \text{autrement.} \end{cases}$	<p><math>a = \text{hardlims}(n)</math> Symmetric Hard-Limit Transfer Function</p>
Tansig	$a = \text{Tansig}(n) = 2 / (1 + \exp(-2*n)) - 1$	<p><math>a = \text{tansig}(n)</math> Tan-Sigmoid Transfer Function</p>

<p>Poslin</p>	$a = \text{Poslin}(n)$ $= \begin{cases} n, & \text{Si } n \geq 0 \\ 0, & \text{Si } n < 0 \end{cases}$	 <p><math>a = \text{poslin}(n)</math> Positive Linear Transfer Function</p>
<p>Satlin</p>	$a = \text{Satlin}(n)$ $= \begin{cases} 0, & \text{if } n \leq 0 \\ n, & \text{if } 0 \leq n \leq 1 \\ 1, & \text{if } 1 \leq n \end{cases}$	 <p><math>a = \text{satlin}(n)</math> Satlin Transfer Function</p>
<p>Purelin</p>	$a = \text{Purelin}(n) = n$	 <p><math>a = \text{purclin}(n)</math> Linear Transfer Function</p>

#### 4.4. L'apprentissage d'un réseau de neurones

La phase d'apprentissage consiste à modifier selon l'algorithme d'apprentissage choisi tous les poids des connexions du réseau et toutes les valeurs de polarisation ou de seuil de chacun des neurones des couches cachées et des couches de sortie. Dans le cadre de ces définitions, on peut distinguer deux types d'apprentissage que l'on emploie avec différents types d'architectures : l'apprentissage supervisé et l'apprentissage non supervisé [4].

##### 4.4.1. Apprentissage non supervisé

Dans ce type d'apprentissage, on laisse le réseau évoluer librement jusqu'à ce qu'il se stabilise, sans lui fournir les données de sortie, le réseau ajuste les poids des connexions seulement avec les données d'entrées. Par l'apprentissage non supervisé, le réseau cherche à détecter les similarités et les différences entre les variables présentées dans la base de données et à refléter ces propriétés dans les valeurs de sortie, d'où son utilisation pour le traitement du signal et l'analyse factorielle [4].



4.4.2. Apprentissage supervisé

Un ensemble de données divisé en entrées et sorties est présenté au réseau de neurones sous forme d'une base de données. Un algorithme d'apprentissage prend en charge le calcul de l'écart entre les sorties réelles et les sorties prédites par le réseau neurones. Cet algorithme fait en sorte que la valeur de l'écart devient minimale, tout en ajustant les poids des connexions au fur et à mesure. Pendant un apprentissage supervisé, la rétropropagation utilise la méthode du gradient descendant pour minimiser les erreurs [4].

Dans ce travail, nous avons utilisé l'apprentissage supervisé comme tâche d'apprentissage d'un emploi qui attribue des intrants aux extrants en fonction des données utilisées dans l'étude.

Dans le réseau d'apprentissage, les poids et les biais sont utilisés pour générer la sortie cible en réduisant la fonction d'erreur, l'erreur quadratique moyenne (Mean Square Error) MSE. Les réseaux progressent grâce à un algorithme d'apprentissage et sont formés par époques qui sont le cycle complet de toutes les données d'entraînement existant dans le réseau.

L'apprentissage supervisé est basé sur la somme de la variance entre les sorties de réseau réelles et sorties préférées. Les poids et les biais sont modifiés en organisant l'ensemble de modèles d'apprentissage et les erreurs résultantes entre les sortie préférées et les sorties de réseau réelles. Ainsi, l'apprentissage supervisé se déroule comme une rétroaction en boucle fermée où l'erreur est le signal de retour. Le degré d'erreur est caractérisé par l'erreur quadratique moyenne MSE. Le MSE est déterminé après chaque époque et le processus d'apprentissage est terminé lorsque MSE est minimisé [16].

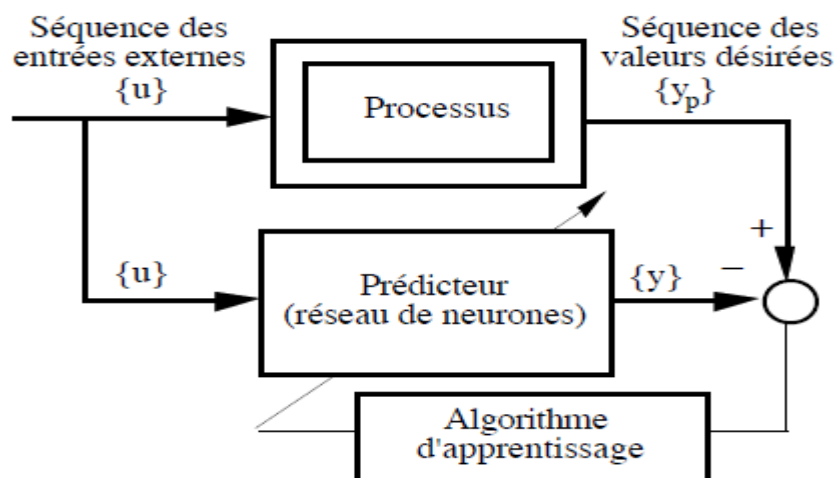


Figure III.5. Système d'apprentissage pour la modélisation d'un processus [12].

La Figure III.5 représente le système d'apprentissage pour la modélisation d'un processus : le but est d'estimer les coefficients du réseau prédicteur. Les séquences d'apprentissage sont constituées de la séquence des commandes  $u(k)$  appliquées au processus et au prédicteur, et de la séquence des sorties désirées pour le prédicteur, qui sont les sorties  $y_b(k)$  mesurées sur le processus. Les coefficients sont estimés de manière à minimiser une fonction de coût définie à partir de l'écart  $(y_b - y)$  à l'aide d'un algorithme d'apprentissage approprié [12].

### 5. Notre modèle proposé

Le réseau de neurones adopté dans notre étude est un réseau multicouche de rétropropagation à action directe. Il a été conçu et formé à l'aide d'un code MATLAB. Le modèle est basé sur la formation du réseau de neurones à l'aide d'une base de données d'entrée réelles (échantillons d'occupations spectrales pris pendant 24h), organisée sous forme de séries de temps qui sont chronologiques et dépendants aux entrées précédentes du système, des sorties précédentes ou les deux en même temps.

En outre, on a basé sur deux critères d'évaluation pour mesurer la performance de nos modèles proposés qui sont le MSE et la régression.

#### 5.1. Modèle de régression

L'analyse par régression est une technique qui se sert d'une fonction pour modéliser un phénomène physique particulier. Une variable indépendante de la fonction est souvent appelée « régresseur ». La fonction elle-même s'appelle « modèle de régression ». Un modèle de régression contient habituellement un certain nombre de paramètres réglables appelés des coefficients de régression. Ces coefficients sont choisis pour réduire au minimum l'erreur entre les données mesurées (réelles) et les valeurs correspondantes calculées avec le modèle de régression. Une fois que ces paramètres sont déterminés, le modèle de régression est utilisé pour la prédiction des besoins désirés [4].

Pour notre modèle de prédiction, on a utilisé la régression comme outil afin de mesurer combien les données de sortie du réseau (output data) correspondent aux données cibles (Target data).

5.2. Nonlinear Autoregressive Exogenous Neural Network (NARX)

5.2.1. Spécification du modèle

Nonlinear autoregressive exogenous neural network (NARX) est un réseau dynamique récurrent, avec des connexions de retour d'informations englobant plusieurs couches du réseau. Le modèle NARX est basé sur le modèle linéaire ARX, couramment utilisé dans la modélisation des séries temporelles. Le modèle NARX est défini selon l'équation suivante.

$$y = f(y_{t-1}, y_{t-2}, y_{t-3}, \dots, y_{t-k}, x_{t-1}, x_{t-2}, x_{t-3}, \dots, x_{t-k}) \quad (III.2)$$

La variable sortie  $y_t$  est régressée de ses valeurs précédentes et des variables exogènes  $x_t$  retardées de k périodes. Cette équation permet également de former un modèle vectoriel NARX, où l'entrée et la sortie peuvent être multidimensionnelles. Un diagramme du réseau résultant est montré à la Figure III.6 Présente ci-dessous [13].


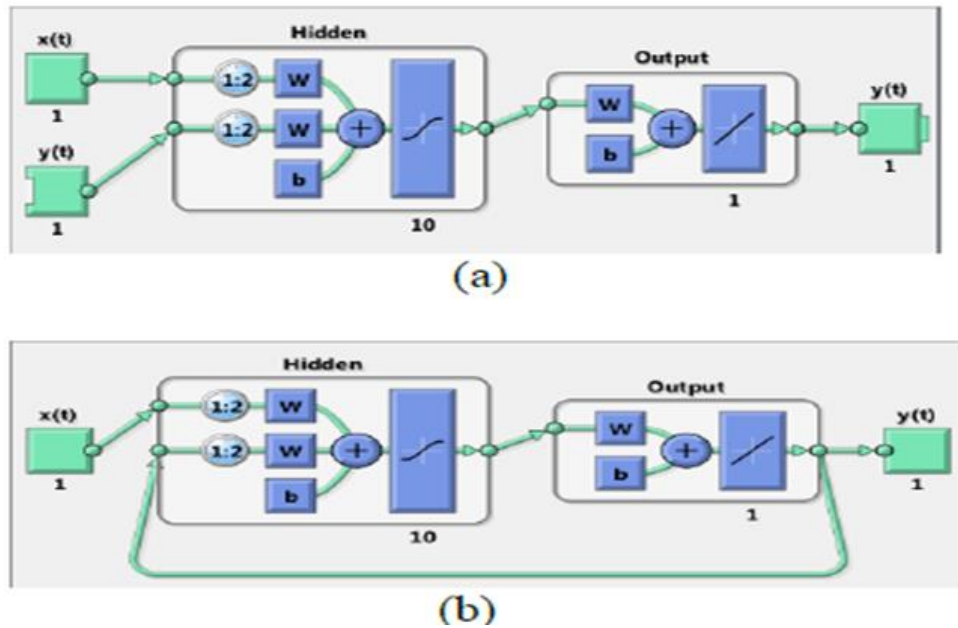


Figure III.6. Architecture du réseau de neurone NARX [13].

Le réseau NARX standard est un réseau à deux couches, avec une fonction de transfert sigmoïde dans la couche cachée et une fonction de transfert linéaire dans la couche de sortie. Il peut être exécuté en boucle fermée ou ouverte. La première signifie que la sortie du réseau NARX est renvoyée à l'entrée du réseau (par retards). Dans l'exécution en boucle ouverte, la sortie réelle est utilisée au lieu de renvoyer la sortie estimée. Cela a deux avantages. Le premier est que l'entrée dans le réseau feedforward est plus précise. La seconde est que le réseau résultant à une architecture purement feedforward, et la rétro propagation statique peut être utilisé [13].



**Figure III.7.** a) Diagramme de l'architecture parallèle série NARX, b) Schéma de l'architecture en boucle fermée NARX [5].

La Figure III.7. (a) illustre un diagramme du réseau obtenu. La sortie du réseau NARX peut être considérée comme une estimation de la sortie d'un système dynamique non linéaire à modéliser. Cette sortie est renvoyée à l'entrée du réseau dans le cadre de la conception NARX standard, Figure III.7. (b) La sortie réelle étant disponible pendant la formation, il sera avantageux de créer une architecture parallèle en série, dans laquelle la sortie réelle est renvoyée au lieu de la sortie estimée, Figure III.7. (b) Cela garantit que le réseau résultant a une conception purement directe et que la rétropropagation statique peut être adoptée pour la formation [5].

### 5.3. Time Delay Neural Network (TDNN)

TDNN est un perceptron multicouche étendu MLP (Rumelhart et McClelland, 1986) que permet de traiter les modèles temporels et les problèmes des signaux de variantes temporelles, c.-à-d. les signaux qui sont échelonnés et traduits au fil du temps. L'idée qu'a été suivi dans le TDNN est basée sur l'invention de délais, ce qui permet aux neurones individuels la capacité de stocker l'histoire de leurs signaux d'entrée. De cette façon, le réseau ensemble peut s'adapter non seulement à un ensemble de modèles, mais également à un ensemble de séquences de modèles. Par l'invention des retards de temps  $T \sim t$ , chaque neurone a accès à chaque valeur d'entrée à  $T + 1$  (courant plus 1 ...T retards) différents points dans le temps  $x(t - T, \dots, t)$ , voir Figure III.8 [14].

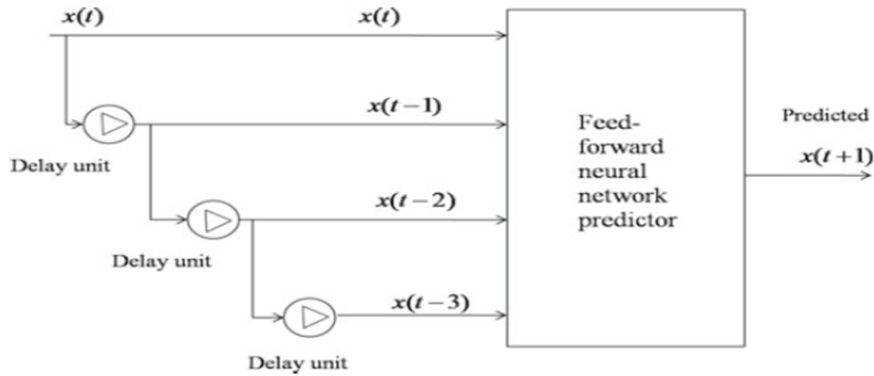


Figure III.8. Structure le réseau neuronal temporel (TDNN) [17].

Ainsi chaque neurone peut détecter des relations entre le courant et les anciennes valeurs d'entrée, qui pourraient être des modèles typiques dans le signal d'entrée. Aussi, le réseau est capable d'estimer des fonctions qui prennent en compte un historique (limité) du signal d'entrée, telles que des fonctions dépendant de la dérivée de l'entrée. Retarder les entrées des neurones situés dans une couche cachée ou la couche de sortie est similaire à multiplier les couches au-delà et aide avec l'échelle de modèle et la translation et est proche d'intégrer le signal d'entrée au fil du temps [14].

La loi d'apprentissage TDNN est essentiellement la loi de rétropropagation des erreurs, et les méthodes communes pour accélérer l'apprentissage de rétropropagation peuvent également être appliquées à la TDNN, il utilise l'algorithme LM. Cependant, afin de traiter les signaux d'entrée retardés ou échelonnés, la définition originale du TDNN exigeait que tous les liens (retardés) d'un neurone qui sont connectés à une entrée soient identiques [14].

L'objectif principal de toute formation est de réduire l'erreur globale  $E$  qui est définie comme suit [18] :

$$E = \frac{1}{N} \sum_{i=1}^N (o_i - t_i)^2 \quad (\text{III.3})$$

Où  $o_i$  est le nœud de sortie et  $N$  est le nombre total de nœuds, Figure III.9.

Le signal d'entrée est augmenté comme d'autres entrées avec des copies retardées. Ce réseau est invariant de décalage de temps car il n'a pas d'état interne. Un ensemble de retards sont ajoutés à la saisie afin d'atteindre l'invariance du décalage horaire. Des travaux ont été effectués pour créer TDNN adaptable pour éliminer le besoin de régler TDNN.

### 5.4. Algorithme de Levenberg Marquardt (LM)

Cet algorithme a été conçu pour approcher la vitesse d'entraînement du second ordre en calculant la matrice Hebbian. Si les fonctions de performance ont une forme de somme de carré. La matrice Hebbian peut être calculée comme [17].

$$\mathbf{H} = \mathbf{J}^T \mathbf{J} \quad (\text{III.4})$$

Et le gradient peut être calculé comme.

$$\mathbf{G} = \mathbf{J}^T \mathbf{E} \quad (\text{III.5})$$

Où  $\mathbf{J}$  est la matrice jacobienne (JM) qui contient les premiers dérivés des erreurs de réseau en ce qui concerne les biais et les poids, et  $\mathbf{E}$  est le vecteur d'erreurs réseau et  $\mathbf{T}$  indique une opération de transposition.

La rétro-propagation (BP) standard peut être utilisé pour calculer JM depuis BP est beaucoup moins complexe que d'apprentissage Hebbian. L'approximation à la matrice Hebbian est utilisée par l'algorithme LM en combinant le gradient et la méthode Gauss–Newton, un poids de mise à jour peut être calculé.

$$\mathbf{W}_{i+1} = \mathbf{w}_i [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{E} \quad (\text{III.6})$$

Où  $\mu$  est le taux d'apprentissage,  $\mathbf{W}_i$  est le poids, et  $\mathbf{I}$  est la matrice d'identité. Si  $\mu$  est grand, cette méthode devient la descente de gradient avec une petite taille de pas et si est 0, c'est la méthode de newton qui utilise la matrice hebbian approximative. Ainsi est diminué après chaque étape réussie et si étape provisoire augmenter la fonction de performance la valeur de est augmentée. À l'étape initiale, la somme de l'erreur au carré est déterminée à l'aide du poids initial et du taux d'apprentissage. Le poids mis à jour de l'algorithme LM est ensuite adapté à l'entraînement jusqu'à ce que la performance réponde aux critères du réseau [17].

## 6. Résultats et discussions

Les mesures sont prévues sur la base du modèle TDNN et de réseau de neurone NARX.


### 6.1. Résultats de simulation pour NARX

**Tableaux III.2.** Critères de performances (MSE et régression) du modèle NARX en termes de la variation des paramètres du réseau.


### CHAPITRE III : Simulation et résultats

Nombre de couche	Nombre de neurone dans chaque couche ( $C_n$ )	Delay (Retard d'entrée)	Fonctions de transfert	MSE	Régression [R; m; b]	Figures
2	$C_1=10$ $C_2= \text{Auto}$	$D_x =1$ $D_y =1$	Poslin Tansig	0.02877	[0.32; 0.32; 0.06]	(a) (a')
4	$C_1=20$ $C_2=15$ $C_3=20$ $C_4= \text{Auto}$	$D_x =1$ $D_y =1$	Poslin Poslin Poslin Tansig	0.02117	[0.37; 0.31; 0.02]	(b) (b')
4	$C_1 =10$ $C_2 =10$ $C_3 =10$ $C_4 =\text{Auto}$	$D_x =1$ $D_y =1$	Poslin Poslin Poslin Tansig	0.01804	[0.49; 0.31; 0.01]	(c) (c')
4	$C_1 =15$ $C_2 =10$ $C_3 =15$ $C_4 = \text{Auto}$	$D_x =1$ $D_y =1$	Poslin Tansig Tansig Tansig	0.01728	[0.39; 0.30; 0.02]	(d) (d')
4	$C_1=10$ $C_2=10$ $C_3 =10$ $C_4 = \text{Auto}$	$D_x =1$ $D_y =1$	Haradlims Poslin Tansig Tansig	0.01698	[0.49; 0.32; 0.02]	(e) (e')


$C_n$  est le nombre de neurones dans chaque couche.  $D_x$  et  $D_y$  sont les retard pour l'entrée  $X(t)$  et pour l'entrée récurrente  $Y(t)$ . « R » désigne le coefficient de corrélation entre les sorties et les cibles, il mesure comment la variation de la sortie est expliquée par les cibles. « m » et « b » représentent, respectivement, la pente et l'ordonnée à l'origine des meilleures régressions linéaires des cibles relatives aux sorties réseau. « Auto » le nombre de couche de sortie fournie automatiquement par le réseau




(a)




(a')



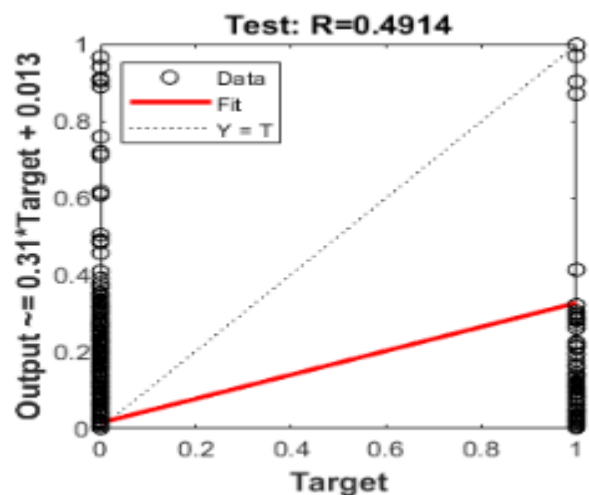
(b)



(b')




(c)




(c')







(d)



(d')



(e)



(e')

Figure III.9. Résultats des performances du modèle NARX.

Dans le Tableau.III.2, nous avons utilisé le code de formulaire NARX, les données d'entrée et les valeurs cibles ont été définies, les délais d'entrée et les délais de rétroaction ont été définis avec une valeur constante 1, et la fonction LM a été définie.

Après l'apprentissage, nous avons changé chaque fois le nombre de neurone dans chaque couche entre 10 et 20 et un changement entre les fonctions de transfert.

Les données sont divisées de manière aléatoire en (70%, 15%, 15%), apprentissage, validation et test, afin de vérifier la capacité de notre modèle à prévoir les données futures.

## 6.2. Résultats de simulation pour TDNN

Tableaux III.3. Critères de performances (MSE et régression) du modèle TDNN en termes de la variation des paramètres du réseau.

### CHAPITRE III : Simulation et résultats


Nombre de couche	Nombre de neurone dans chaque couche ( $C_n$ )	Delay (Retard d'entrée) ( $D_x$ )	Fonction de transfert	MSE	Régression [R; m; b]	Figures
5	$C_1 = 15$ $C_2 = 10$ $C_3 = 10$ $C_4 = 15$ $C_5 = \text{Auto}$	$D_x = 1$	Poslin Poslin Tansig Poslin Purlin	0.00527	[0.96; 0.92; 0.01]	(a) (a')
5	$C_1 = 20$ $C_2 = 15$ $C_3 = 15$ $C_4 = 20$ $C_5 = \text{Auto}$	$D_x = 1$	Poslin Poslin Tansig Poslin Purlin	0.00509	[0.96; 0.96; 0.003]	(b) (b')
4	$C_1 = 15$ $C_2 = 10$ $C_3 = 15$ $C_4 = \text{Auto}$	$D_x = 1$	Poslin Tansig Tansig Tansig	0.00479	[0.98; 0.95; 0.005]	(c) (c')
5	$C_1 = 10$ $C_2 = 10$ $C_3 = 10$ $C_4 = 10$ $C_5 = \text{Auto}$	$D_x = 1$	Poslin Poslin Tansig Poslin Purlin	0.00457	[0.96; 0.93; 0.007]	(d) (d')
4	$C_1 = 20$ $C_2 = 15$ $C_3 = 20$ $C_4 = \text{Auto}$	$D_x = 1$	Poslin Poslin Poslin Tansig	0.00457	[0.97; 0.94; 0.005]	(e) (e')

$C_n$  est le nombre de neurones dans chaque couche.  $D_x$  est le retard pour l'entrée  $X(t)$ . «R» désigne le coefficient de corrélation entre les sorties et les cibles, il mesure comment la variation de la sortie est expliquée par les cibles. «m» et «b» représentent, respectivement, la pente et l'ordonnée à l'origine des meilleures régressions linéaires des cibles relatives aux sorties réseau. «Auto» le nombre de couche de sortie fournie automatiquement par le réseau


Où  $\text{Output} = m \times \text{Target} + b$

Le Tableau III.3 illustre l'utilisation du code de modèle TDNN pour simuler les données d'entrée et définir les données de sortie attendues, et les retards d'entrée ont été fixés avec une valeur constante de 1, spécifiant l'algorithme LM.


Le même travail précédent, après d'apprentissage nous avons changé à chaque fois le nombre de neurones dans chaque couche entre 10 et 20 et le nombre de couches et aussi un changement entre les fonctions de transfert.




(a)




(a')




(b)




(b')




(c)




(c')



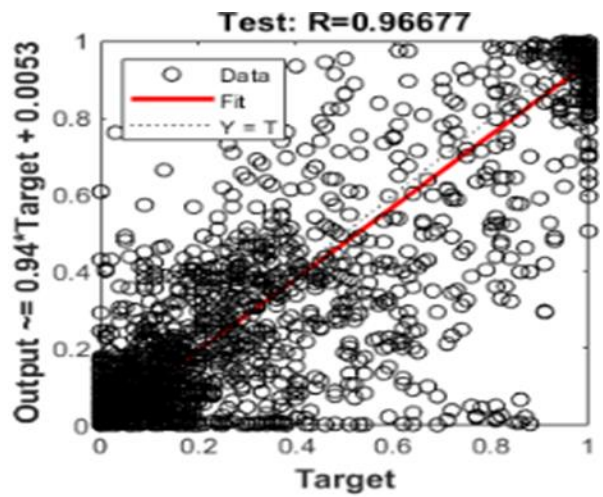
(d)



(d')



(e)



(e')

Figure III.10. Résultats des performances du modèle TDNN.

### 6.3. Remarques et Commentaires

Le travail proposé a été mis en œuvre à l'aide de matlab. Les réseaux de neurones ont été conçu à l'aide d'un mécanisme de retard au niveau de l'entrée du réseau utilisé pour prédire le spectre dans les 24 heures, pour chaque 5 minutes, nous définissons les valeurs d'entrée et les valeurs de sortie cibles en fonction des données réelles et nous avons également utilisé l'apprentissage supervisé en travaillant avec l'algorithme LM pour accélérer l'apprentissage et donner des résultats plus précis. Nous avons choisi NN parce qu'il fournit les meilleurs résultats par rapport aux autres technologies NN, en termes de réduction des erreurs.

En appliquant ces processus sur les deux réseaux, NARX et TDNN, les résultats sont donnés après l'apprentissage comme suivent :

Dans le Tableau III.2 en utilisant NARX, les meilleurs résultats ont été obtenus en termes de valeurs de régression et de valeurs d'erreur quadratique moyenne MSE, lorsque nous avons réduit le nombre de neurones cachés et modifié les fonctions d'activation, laissant les mêmes valeurs de délai fixes de 1, définir la valeur de validation maximum à 10, nous constatons que la valeur de R est égale à 0.48701 pour le test illustré à la Figure III.9. (e'). RMSE est de 0.016983 Figure III.9. (e).

Dans le Tableau III.3 en utilisant TDNN, les meilleurs résultats ont été obtenus lorsque nous avons augmenté le nombre de neurones cachés. Définir la valeur de validation maximum 50, nous trouvons que la valeur de R = 0.97615 sur la Figure III.10. (c') et les valeurs de MSE = 0.004572 sur la Figure III.10. (e).

Où R représente la régression et MSE représente erreur quadratique moyenne.

### 6.4. Comparaison des performances et résultats

Pour évaluer les performances de nos méthodes de prédiction, on a conçu à deux mesures de performances (d'erreur) afin de comparer nos résultats avec les travaux similaires, l'erreur quadratique moyenne (means square error) MSE, et la racine des moindres carrés (Root means square error) RMSE exprimée comme suit [5] :

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2 \quad (\text{III.7})$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2} \quad (III.8)$$

**Tableau III.4.** Résultats des simulations NARX et TDNN.

Les méthodes	MSE	RMSE	Régression
<b>TDNN</b>	0.00457	0.06761	0.97
<b>NARX</b>	0.01698	0.13031	0.49

Concernant la comparaison entre les deux types de modèle RNA, Les résultats des Tableau.III.2 et Tableau.III.3 ont montré que TDNN fonctionnait mieux que NARX à la prédiction spectrale par simulation sur des données réelles. Et aussi l'interprétation des résultats. Tableau.III.4 Plus généralement, les réseaux TDNN sont plus précis que les réseaux NARX, en termes de prédictions et de rapidité d'apprentissage et de mémorisation car les valeurs MSE et RMSE sont très faibles, donc pour se rapprocher davantage des valeurs ciblent.

## 7. Comparaison avec les travaux similaires

Une comparaison est faite dans le Tableau.III.5 qui montre les valeurs d'erreur pour meilleurs cas en utilisant différentes techniques (Neural Network) NN.

**Tableau III.5.** Comparaison des performances avec d'autres RC basés sur NN algorithmes.

Chercheur	Technique de réseau neuronal	Valeur d'erreur
<b>Tsagkaris [18]</b>	Focused Time Delay (FTD)	0,0637
<b>Ustundab [20]</b>	Multi-Layer Perceptron (MLP)	0.0625
<b>Notre approche</b>	Time Delay Neural Network (TDNN)	0.06761
<b>Baldo [19]</b>	Multi-Layer Feed Forward (MLFF)	0.8

### 8. Conclusion

La prédiction du spectre est la fonction la plus importante d'un réseau RC pour surmonter les retards de détection, de traitement et de prise de décision du spectre.

Dans ce chapitre, des procédures de simulation sont effectuées, ainsi nous avons conçu le prédicteur d'état du canal en utilisant deux schémas adaptatifs différents, à savoir un réseau neuronal modèle TDNN et le modèle NRAX sur la bande GSM900. L'avantage des schémas de prédiction de l'état des canaux proposés est que ces schémas nécessitent de connaissance a priori des statistiques d'utilisation des canaux. Nous avons comparé leurs résultats, et nous avons conclu que le modèle TDNN est meilleur et plus proche de prédire l'état des occupations radio, car il fournit non seulement une détection d'énergie significative mais aussi améliore l'utilisation du spectre.

En outre, nous avons utilisé l'algorithme LM pour accélérer le processus d'apprentissage et donner des résultats plus précis. À partir de là, les résultats le modèle TDNN ont montré un très faible taux d'erreur de 0,04, en comparant nos résultats avec le modèle NARX, nous avons conclu que les résultats obtenus sont très proches de ceux d'autres chercheurs dans les techniques RNA, ce qui est une indication de l'efficacité du processus de prédiction RNA. L'approche proposée s'est avérée plus précise que les méthodes précédentes.

# RÉFÉRENCES

- [1] D.Ouattara, et al. “*Un système de prédiction spectrale pour une connectivité permanente dans le cadre du suivi en temps réel de patients,*” HAL archive ouverte, vol. RNTI, pp. 99-120, 24 août2013, Disponible: <https://hal.archives-ouvertes.fr/hal-00853897>
- [2] M .K, Tcheumtchoua Kamdem, “ *Développement d’une plateforme de reporting automatique des mesures radio et des états GOS (GSM/GPRS), de prédiction de couverture et de c/i,*” 2009. [En ligne]. Disponible: [https://www.memoireonline.com/06/10/3545/m\\_Developpement-dune-plateforme-de-reporting-automatique-des-mesures-radio-et-des-etats-GOS-GSMGP8.html](https://www.memoireonline.com/06/10/3545/m_Developpement-dune-plateforme-de-reporting-automatique-des-mesures-radio-et-des-etats-GOS-GSMGP8.html).
- [3] A. SLIMANI, “ *Dimensionnement et Planification d’un Réseau GSM,*” Thèse de Master en Télécommunications, Université Abou-Bekr Belkaïd Tlemcen, déc. 2010, pp.10-108.
- [4] B.CHLYAH, “*La prédiction statique et dynamique des besoins énergétiques d'un bâtiment en utilisant les réseaux de neurones artificiels,*” Mémoire de maîtrise électronique, Mémoire de maîtrise électronique, École de technologie supérieure, Montreal, QC, 2008. [En ligne]. Disponible: <https://espace.etsmtl.ca/id/eprint/133/>
- [5] H. Loutfi, et al. “*Generation of horizontal hourly global solar radiation from exogenous variables using an artificial neural network in Fes (Morocco),*” IJRER, Vol.7, No 3, 2017. [En ligne]. Disponible: <https://ijrer.org/ijrer/index.php/ijrer/article/view/5852>
- [6] B.G. Najashi, et al. “*Spectrum whole prediction based on historical data: A neural network approach,*” arXiv preprint arXiv: 1401.0886.niversité Du Québec, January 2014, pp.10-39.
- [7] M. Nouressadat, “*Etude des performances des réseaux de neurones dynamiques à représenter des systèmes réel: une approche dans l'espace d'état,*” Thèse de Magister. Université De Sétif 1 Algérie, 04 Jul. 2009, pp.3-18.



- [8] I. Chraïbi Kaadoud, “*Fonctionnement mathématique du neurone formel*,” Science Blogs, 08 Oct. 2018 [En ligne]. Disponible: <http://www.scilogs.fr/intelligence-mecanique/reprenons-bases-neurone-artificiel-neurone-biologique/>
- [9] M.Y. Ammar, “*le titre de docteur de l’institut national polytechnique de toulouse*,” Thèse de doctorat. Tunisie : Ingénieur en Génie des Matériaux (Ecole Nationale d’Ingénieurs de Sfax), Tunisie, 17 juil. 2007, pp.13-22.
- [10] A. Ferchichi, “*Structure de modèle de réseau de neurones artificiels*,” [figure] Tiré de. [https://www.researchgate.net/figure/Structure-de-modele-de-reseau-de-neurones-artificiels\\_fig5\\_322263283](https://www.researchgate.net/figure/Structure-de-modele-de-reseau-de-neurones-artificiels_fig5_322263283).
- [11] Mathworks, Centre d'aide - MATLAB & Simulink, 1994, [En ligne]. Disponible : <https://www.mathworks.com/help/deeplearning/ug/neuron-model.html>.
- [12] I. Rivals, et al. “*Modélisation, classification et commande par réseaux de neurones: principes fondamentaux, méthodologie de conception et illustrations industrielles*,” Ecole Supérieure de Physique et de Chimie Industrielles de la Ville de Paris, pp.3-43.
- [13] M. B. Houad, Y.Oubouali, “*Prévisions de la liquidité des actions cotées à la bourse des valeurs de Casablanca*,” Comparaison entre la modélisation ARIMA et les réseaux de neurones NARX,” Science Direct, Vol.10, No 2, pp.83-99, 25 dec.2018, doi: 10.1016/j.rgo.2018.07.001,  
[Enligne]. Disponible:<https://www.sciencedirect.com/science/article/pii/S2214423418300930>.
- [14] M. Kaiser, “*Time-delay neural networks for control*,” IFAC Proceedings Volumes, Vol. 27, No 14, 1994, pp. 967-972, [En ligne]. Disponible: [https://doi.org/10.1016/S14746670\(17\)47423-4](https://doi.org/10.1016/S14746670(17)47423-4).
- [15] R. Aravena, “*Input delay neural network architecture with p memory order*,” [figure] Tire de: [https://www.researchgate.net/figure/Input-delay-neural-network-architecture-with-p-memory-order\\_fig3\\_253802879](https://www.researchgate.net/figure/Input-delay-neural-network-architecture-with-p-memory-order_fig3_253802879).
- [16] A.K.YADAV, S. S. CHANDEL, “*Solar radiation prediction using Artificial Neural Network techniques: A review*,” Renewable and sustainable energy reviews, Vol. 33, 2014, pp. 772-781.

- [17] S. Tiwari, et al. “*Smart Innovations in Communication and Computational Sciences*,” Proceedings of ICSICCS-2018, Springer, Vol. 851, 2018, pp.257-263.
- [18] K. Tsagkaris, A.Katidiotis, P.Demestichas, “*Neural Network based learning schemes for cognitive radio systems*,” Computer Communication Journal vol.31, issue 14, 2008,pp. 3394-3404
- [19] N.Baldo, B.R.Tamma, B.S.Manoj, R.Rao, M.Zorzi, “*A Neural Network based Cognitive controller for Dynamic Channel Selection*,”
- [20] B. Ustundag, O. Orcay, “*Pattern Based Encoding for Cognitive Communication*,” presented at the 3rd International ICST Conference on Cognitive Radio Oriented Wireless Networks and Communications, Jul. 2008, Accessed: May 26, 2020. [Online]. Available: <https://eudl.eu/doi/10.1109/crowncom.2008.4562494>.

# CONCLUSION

# CONCLUSION

La technologie sans fil a permis le développement d'applications et d'appareils de plus en plus diversifiés, entraînant une croissance exponentielle de l'utilisation des services de radiocommunication. Ces progrès ont fait du spectre radio une ressource rare et par conséquent, son utilisation efficace est de la plus haute importance. Pour faire face à la demande progressive, le spectre disponible limité et l'inefficacité dans l'utilisation du spectre nécessitent de nouvelles règles pour exploiter le spectre sans fil existant de façon opportuniste. L'accès dynamique au spectre (DSA) promet une solution pour faire face à la demande croissante d'accès au spectre.

La radio cognitive permet d'introduire de l'intelligence et de la flexibilité dans la gestion des ressources de spectre, et peut réduire le problème de rareté du spectre en permettant aux utilisateurs non autorisés de partager le spectre avec des utilisateurs autorisés sans interférence. Ainsi les utilisateurs non autorisés peuvent utiliser des bandes sous licence qui ne sont pas temporairement occupées par des utilisateurs sous licence.

Par conséquent, la stratégie pour déterminer si une bande de spectre est vacante est au cœur des technologies RC. Les performances du réseau RC dépendent de la détection du spectre, de la décision du spectre et du partage du spectre, afin de connaître l'activité principale de l'utilisateur pour fournir des bandes vacantes pour l'utilisateur secondaire.

La RC, après avoir exécuté ces fonctions, induit systématiquement des retards importants dus à la détection du spectre, au traitement et à la prise de décision, aboutissant ainsi à une consommation d'énergie massive et une augmentation de la latence. Une solution efficace à ce problème est la prédiction du spectre.

Parmi les différentes techniques de prédiction, nous avons travaillé sur un modèle de prédiction de spectre basé sur des réseaux de neurones artificiels qui a montré de meilleures performances de prédiction. Dans cette étude, nous avons effectué une prédiction d'occupation spectrale sur la bande GSM900 de la liaison montante et descendante, en utilisant des données réelles obtenues pendant 24 heures avec des échantillons pris toutes les 5 minutes. Nous avons obtenu des résultats très prometteurs qui démontrent clairement les performances supérieures du modèle TDNN par rapport au modèle NARX pour réduire

davantage les erreurs de prédiction. De plus, les TDNN ont présenté des prédictions plus précises que les travaux similaires en technologies RNA.

Pour enrichir cette étude, nous proposons de l'appliquer pour les réseaux de communication sans fil de la prochaine génération (5G et 6G). Elle sera menée pour prédire le spectre pour les différents types des canaux radio et non pas seulement pour la bande GSM, afin d'exploiter le spectre d'une manière plus efficace.