

Application des réseaux de neurones artificielles dans l'optimisation des performances d'antennes reconfigurables

Application of artificial neural network to optimize the performance of reconfigurable antenna

Amellal Rajaa

Doctorante

Faculté des sciences

Université ibn tofail

Laboratoire Systèmes Electroniques, Traitement de l'information, Mécanique et Energétique

amellalrajae@gmail.com

Date de soumission : 10/07/2023

Date d'acceptation : 16/08/2023

Pour citer cet article :

RAJA.A (2023) « Application des réseaux de neurones artificielles dans l'optimisation des performances d'antennes reconfigurables », Revue Internationale du chercheur « Volume 4 : Numéro 3 » pp : 1 – 18

Résumé

Cet article donne un aperçu de quelques applications de l'intelligence artificielle (IA) dans les réseaux d'antennes adaptatives et reconfigurables. L'apprentissage automatique dépend fortement de l'architecture du réseau de neurones et nécessite le contrôle du signal offert par la formation de faisceau numérique pour faire une détection plus précise des sources de signaux à travers leurs puissances ou en se basant sur leur rapport signal sur bruit, Ainsi que l'estimation de leurs angle d'arrivée à des antennes réceptrices, ceci nous a conduits à faire une revue des techniques de fonctionnement des surfaces intelligents reconfigurables.

Mots clés : « algorithmes adaptatifs », « antennes auto reconfigurable », « formation de faisceau », « direction d'arrivée », « surfaces intelligents reconfigurables »

Abstract

This paper provide an overview of some application of artificial intelligence (AI) in adaptive and reconfigurable antenna arrays. Machine learning is highly dependent on neural network architecture and requires control of the signal produced by digital beamforming in order to improve detection of signals sources through their power or based on signal to noise (SNR). As result this method increase inverse mapping of variables concerning the received signal for realize executed estimation of direction of arrival (DoA).

Wish led us to review the techniques for operating reconfigurable smart surfaces.

Keywords : «adaptive algorithm», «self-learning antenna» , «beamforming», «direction of arrival», « reconfigurable smart surfaces »

Introduction

L'intelligence artificielle (IA) couvre principalement les domaines tels que le traitement d'images, le traitement du signal, le traitement du langage naturel, les bases de données (Sud.Jaya& Christos.Christos(2011)). L'apprentissage basée sur IA consiste à programmer les machines pour qu'il exécutent des tâches basées sur des algorithmes de manière intelligente (Hafssa chddadi(2008)). Alors que l'apprentissage automatique se concentre sur les capacités des machines à recevoir un ensemble de données et à apprendre par elles-mêmes, elles modifient les algorithmes à mesure qu'elles en apprennent davantage sur les informations qu'elles traitent (Andrew Ng(2018)).

Le potentiel de ML pour résoudre des défis complexes imprévisibles et non linéaires attire des chercheurs dans le domaine de l'électromagnétisme (EM), en particulier dans les systèmes d'antennaires (Sud.Jaya& Christos.Christo(2011)).

L'application d'algorithmes intelligents provenant de l'apprentissage automatique (ML) dans le contrôle d'antennes reconfigurables peut briser l'inefficacité de la conception d'antennes traditionnelle basée sur l'expérience en ingénierie et les logiciels de simulation électromagnétique, Le premier algorithme prédire à chaque instant quel sera le meilleur mode à l'instant suivant, à l'aide de données en bande de base. Le second algorithme est déterministe et permet d'estimer et de suivre la direction et l'angle d'arrivée du signal (M. M. SHI (2018)). Il sélectionne ensuite le mode qui possède le meilleur gain dans cette direction, dans le but d'améliorer le bilan de liaison et d'éliminer les interférences, pour réaliser la conception des antennes auto reconfigurables la base d'un futur Radio bot (Trong Duc Nguyen(2012)). Cela nous conduit à porter l'éclairage à ces nouveaux champs de recherche concernant l'établissement des algorithmes adaptatifs basée sur l'apprentissage automatique nécessaires pour le contrôle et l'optimisation des paramètres et des caractéristiques des antennes reconfigurables. Un réseau d'antennes à retard fixe ne pourra pas atteindre cet objectif. De plus, nous avons besoin de la capacité de détecter le spectre, de communiquer et ensuite de re-détecter le spectre cela nous ramène à poser les questions suivantes : est qu'il y a une possibilité de faire la conception et la programmation d'une antenne robot et autonome ? quel efficacité d'algorithmes d'apprentissage automatique pour l'estimation de la direction d'arrivée afin de rendre les surfaces des antennes imprimées intelligentes et reconfigurable plus performant au niveau de la directivité ?


Cet article présente les résultats d'estimation et de suivre l'angle d'arrivé du signal, par synthèse au moyen de deux types de réseaux de neurones que sont: Le perceptron multicouche MLP, le

réseau RBFNN (Radial- Basis- Function Neural Network) .Il s'articule comme suit : dans la section 2, nous commençons par une petite définition des antennes reconfigurables ensuite nous faisons un bref rappel sur l'architecture des réseaux de neurones artificielle et algorithmes d'apprentissage automatique (ML); dans la section 3, l'application d'algorithmes d'apprentissage automatique(ML) dans l'estimation d'angle d'arrivé du signal(Frank Hijlkema(2022)), aboutissant à la formulation de notre critère d'optimisation, dans la section 4, nous expliquons comment l'apprentissage automatique (ML) peut répondre aux diverses contraintes introduites par le déploiement en temps réel des antennes reconfigurables intelligents.

1. Antennes reconfigurable : définition et technologies

Une antenne reconfigurable a la capacité de changer sa configuration, dans le but d'intégrer avec l'environnement électromagnétique et rendre les conditions de propagation plus performant et d'éliminer les interférences et le bruit lors de la réception ce type d'antennes peuvent changer une à plusieurs de ses caractéristiques fondamentales par un moyen électrique, mécanique, numérique ou autre, et cela en fonction des besoins et du contexte environnemental. La reconfiguration de l'antenne est réalisée en modifiant la distribution du courant électrique, en conséquence les propriétés du champ électromagnétique et de l'impédance, donc les propriétés de phase et de polarisation en fonction de puissance reçue , et ceci de façon discrète ou continue, L'agilité des paramètres peut être envisagée par l'utilisation de composants électroniques commutables ou accordables (Trong Duc Nguyen(2012)).pour le classement des es antennes reconfigurables se fait selon la fonctionnalité, nous distinguons trois grandes familles : Antennes agiles en fréquence en diagramme de rayonnement et en polarisation.

Figure 1 : types d'antennes reconfigurables




Source : Auteurs

2. Apprentissage automatique (ML) : types et définition

L'apprentissage automatique est en outre classé en apprentissage supervisé, apprentissage non Supervisé et apprentissage par renforcement. L'apprentissage supervisé signifie la tâche d'apprendre une fonction qui mappe une entrée à une sortie sur la base d'exemples de paires entrée-sortie. Il déduit une Fonction à partir de données d'apprentissage étiquetées consistant en un ensemble d'exemples D'apprentissage, et la fonction peut être utilisée pour cartographier de nouveaux exemples (Hafssa cheddadi (2008)).

L'apprentissage supervisé utilise un ensemble d'algorithmes et de réseaux de neurones constitué de couches composé de variables d'entrées et de sorties souhaitées fait partie des accus rances. Le but de cet algorithme est d'apprendre le mappage entre l'entrée et la sortie, il faut des variables d'entrée x et une variable de sortie y et un algorithme est utilisé pour apprendre la fonction de mappage de l'entrée à la sortie $y = f(x)$ (Andrew Ng (2018)).

Figure 2 : apprentissage supervisé, non supervisé et par renforcement



Source: Andrew Ng (2018 deeplearning.ai)

❖ Réseaux de neurones artificiels :


Un réseau de neurones artificiels est formé d'un ensemble de neurones associés en couches (ou sous-groupes) et fonctionnant en parallèle en évaluant les vecteurs de pondération et les fonctions de transfert d'une couche à l'autre. Les réseaux de neurones artificiels offrant la possibilité de mémoriser la connaissance empirique et de la rendre disponible à l'usage cela fait suivant un processus de statistique des variables de sortie en minimisant l'erreur due à la covariance et la probabilité. Les habiletés de traitement du réseau vont être stockées dans les poids synaptiques, obtenus par des processus d'adaptation ou d'apprentissage (Andrew Ng (2018)).

❖ Neurone artificiel élémentaire:

La structure d'un neurone artificiel. Consiste sur le principe de statistique des variable d'entrées reçues à l'entrée en provenance des neurones amonts. A chacune de ces entrées est associée un vecteur de poids W_i abréviation représentatif de l'entrée X_0 , dont la valeur est fixée à 1. Chaque neurone élémentaire est doté d'une fonction de transfert (fonction d'activation) qui met l'accès à une multiplication par des poids, la somme de ces transformations donne une sortie unique Y , et se mapper ensuite pour alimenter un nombre variable de neurones avals et réaliser une prédiction par un algorithme supervisé (Hafssa cheddadi(2008)) Différents types de fonctions

de transfert pour le neurone artificiel a : Fonction à seuil, Linéaire par morceaux ; fonction empirique et gaussienne et plusieurs types. Nous constatons que les équations décrivant le comportement des neurones artificiels n'introduisent pas la notion de temps.

Figure 3: structure d'un neurone artificiel




Source: Andrew Ng (2018 deeplearning.ai)

❖ Procédure de développement de concept d'apprentissage et prétraitement des données d'entrée :

L'apprentissage de réseau se fera par un modèle d'apprentissage accordable. Afin de pouvoir générer l'apprentissage du réseau, il est nécessaire de créer une base d'apprentissage, De manière générale, les variables d'entrées doivent subir une phase de prétraitement et une phase de post-traitement après le flux des données par l'unité des réseaux de neurones (Andrew Ng (2018))

Figure 3: architecture de traitement de données



Source: (hafssa. Cheddadi, (2008))


Les possibilités offertes par les logiciels (Matlab et python) sur les méthodes d'apprentissage sont assez étendues, (le traitement des données par l'algorithme de rétro propagation de l'erreur ou l'erreur quadratique moyenne (MSE), et d'autres algorithmes en utilisant le terme momentum α et la technique d'adaptation du coefficient d'apprentissage et la fonction de réduit

de termes de basis et le calcul des vecteurs de poids, afin d'améliorer la vitesse de convergence (Hafssa cheddadi (2008)).

3. L'estimation d'angle d'arrivé des signaux arrivant à un réseau d'antennes basée sur l'apprentissage automatique et des réseaux de neurones profonds :

En tant que technologie clé dans les réseaux adaptatifs, l'estimation de la direction d'arrivée (DOA) est largement utilisée dans l'optimisation des performances des antennes reconfigurables intelligents. De plus, les approches de formation de faisceaux incluent la méthode de Bartlett, la distorsion de variance minimale moins réponse (MVDR) et la prédiction linéaire, tandis que les approches basées sur le sous-espace se réfèrent principalement à la classification des signaux multiples (MUSIC) et ses variantes et à l'estimation des paramètres du signal via l'information rotationnelle. Les techniques de variance (ESPRIT) pour atteindre une estimation exacte de l'angle d'arrivée (M. M. SHI (2018))., Des études antérieures ont montré que les réseaux de neurones peuvent être utilisés pour mettre en œuvre une formulation de régression ou de classification pour estimer le DoA d'une source unique. Pour plusieurs sources, des problèmes de mise en œuvre se posent pour la régression car seul un nombre prédéfini de DoA peut être estimé (Jeffrey H. Reed & R. Michael Bueh & Harpreet S. Dhill (2020)).

Figure 4: angle d'arrivée et phase géométrique d'un réseau d'antennes linéaires



Source: Auteurs

L'hypothèse de champ lointain ou d'onde plane est couramment utilisée dans notre problème, qui fait référence à une longueur d'onde beaucoup plus petite que la distance entre la source et l'antenne (M. M. SHI (2018)). Le modèle de signal de ULA suit l'équation:

$$(1) \quad X_m(t) = \sum_{n=1}^N s_n(t) e^{j2\pi\tau_n(m-1)} + n_m(t)$$

Où $X_m(t)$ Le nombre de sources et $n_m(t)$ termes de bruit. Sous forme matricielle, il est représenté par :

$$(2) \quad X = AS + N$$

$$(3) \quad A = [a(\theta_1), a(\theta_2) \dots, a(\theta_N)]$$

Et le vecteur directeur $a(\theta)$ est :

$$(4) \quad a(\theta_i) = [e^{j2\pi\tau(\theta)}, e^{j2\pi\tau(\theta)^2}, \dots, e^{j2\pi\tau(\theta)(M-1)}]^T$$

Matrice de covariance est définie par :

$$(5) \quad \hat{R} = \frac{1}{N} \sum_{i=1}^N x(i)x^H(i)$$

Comme indiqué précédemment, la formation de faisceaux est un moyen de façonner les signaux reçus, il peut être utilisé pour estimer DOA, Les approches basées sur les sous-espaces décomposent les signaux reçus en sous-espace de signal et en sous-espace de bruit, de manière à tirer parti des propriétés spéciales de ces sous-espaces pour estimer DOA (M. M. SHI (2018)), L'idée clé de MUSIC est de trouver q et une fonction vectorielle $f(\theta)$, tels que $q^H(\theta) = 0$ si et seulement si $\theta = \theta_i$. Le $P(\theta)$ est calculé par :

$$(6) \quad p(\theta) = \frac{1}{\|q^H f(\theta)\|^2}$$

D'après le vecteur signal reçu mentionné, on obtient la matrice d'autocorrélation suivante :

$$(7) \quad R_{xx} = E\{x(t)x^H(t)\} = AR_S + A^H \sigma^2 I$$

La matrice de covariance (R_x) des signaux reçus K à M valeurs propres décomposer en deux sous espaces:

$$\bar{E} = [\{\bar{e}_1, \dots, \bar{e}_K | \bar{e}_{K+1}, \dots, \bar{e}_M\}]$$

$$\begin{matrix} E_M & E_S \end{matrix}$$

On obtient donc :


$$(8) \quad P_{MUSIC}(\theta) = \frac{1}{a(\theta)^H E_M E_M^H a(\theta)}$$

$$(9) \quad \Theta_{MUSIC} = \text{argmin } a^H(\theta) E_S E_M^H a(\theta)$$

Cependant, MUSIC ne précise pas comment trouver le pic, ce qui implique en fait de gros calculs, en particulier pour plusieurs sources. Le réseau de neurones pourrait compenser l'inconvénient de MUSIC. Sur la vue de réseau de neurones, le problème vise à estimer la localisation à partir de données brutes (JONAS FUCHS& MARKUS GARDI, MAXI LÜBKE& ANAND DUB &FABIAN LURZ (2016)).

Étant donné que notre réseau de neurones fonctionne non seulement pour une estimation d'angle, mais également pour plusieurs estimations (Jeffrey H. Reed & R. Michael Bueh & Harpreet S. Dhill (2020)). Le réseau de détection est utilisé pour diviser la zone de recherche du réseau d'antennes dans différents secteurs de position pour détecter les signaux provenant de sources dans chaque secteur (JONAS FUCHS& MARKUS GARDI, MAXI LÜBKE& ANAND DUB &FABIAN LURZ (2016)). Dans notre cas, un réseau de détection basé sur la perception multiple (MLP) est considéré car il peut gérer toutes les entrées dimensionnelles sans faire aucune hypothèse sur la distribution des données d'entrée (Yi Gong & Xingpeng Mao (2020)).

Figure 5 : L'ensemble des différentes approches d'apprentissage en profondeur de DOA estimée.




Sources: AHMED M. MONT & KORA R. MAH (2009)

4. Résultats ET discussions:

Les résultats de simulation confirment que la connaissance de plusieurs échantillons d'entrée/sortie, les paramètres internes du réseau de neurones ont été déterminés dans la phase de formation hors ligne, puis les valeurs de sortie DOA correspondantes ont pu être obtenues sur la base des données d'entrée actuelles pendant la phase de test. Voilà un spectre de DOA

normalisé estimé par le réseau MLP basé sur L'algorithme de propagation du fond est utilisé pour évaluer les gradients de la fonction d'erreur entre les vrais valeurs d'angle d'arrivée du signal et les estimations en temps réelle. La comparaison entre le réseau neuronal et MUSIC est illustrée à la Figure. 17, car nous pouvons remarquer que le réseau neuronal fonctionne nettement mieux que MUSIC dans notre cas, étant donné le même ensemble de données.

Figure 6 : exemple d'un spectre de DOA normalisé estimé par la méthode MUSIC et diagramme montrant de fonction d'erreur en fonction de nombre d'échantillons N



Sources : Auteurs

Nous présentons dans cette section le résultat de simulation de la valeur RMSE peut entraîner des interprétations trompeuses de la prédiction avec une petite différence entre le DoA estimé et le DoA réel, il est défini par :

$$(10) \text{ RMSE} = \sqrt{\frac{1}{MQ} \sum_{i=1}^Q \sum_{j=1}^M (\hat{\theta}'_{ij} - \hat{\theta}_{ij})^2}$$

Où Q est la capacité de l'ensemble de test, M est le nombre de sources de signaux et la variation de la valeur d'estimation DOA de la jème source dans le lme test, respectivement.


Pour étudier l'effet du bruit sur les performances du réseau de neurones, à titre de comparaison, l'erreur quadratique moyenne (RMSE) des estimations DOA a base des deux types RBFNN et MLP.

Tableau N°1 : les valeurs de sortie du réseau de neurones RBFNN et l'angle d'arrivé estimé :

Name	Type	Size	Value
rbf	RBFNetwork	1	RBFNetwork object of __main__ module
theta	float	1	33.52447324857696
theta_answer	list	99	[102.7552720614927, 143.70137495100832, 158.06308636065438, 127.288835 ...]
theta_rad	float	1	0.5851124381844274

Sources : Auteurs

Figure 7 : Exemple d'estimation d'angle d'arrivé à base de réseau RBFNN en fonction d'amplitude et RMSE de chaque algorithme avec différents nombres d'instantanés des signaux reçus



Sources : Auteurs

Tableau N°2 : Les valeurs normalisés du signal d'entrée ainsi que l'angle d'arrivée estimé par le réseau de neurones MLP avec le taux d'erreur MSE :

Name	Type	Size	Value
testError	float64	1	16.271504626105283
theta_avg	float64	1	17.84942324922115
theta_diff	list	5	[45.64296328586356, 2.794869256...]
theta_difference	float64	1	13.301713125498566
theta_sum	float64	1	88.3546450836447
trainError	float64	1	8.802981126947165
X	Array of float64	(99, 3)	[[0.00316284 0.0031249 0.00308...] [0.00738235 0.00777907 0.00821...]

Sources : Auteurs


D'après la figure ci-dessus, on peut voir que la RMSE de l'estimation DOA des cinq Méthodes tels que les algorithmes adaptatifs et d'apprentissage tend à diminuer avec le nombre d'instantanés ; lorsque les instantanés augmentent à un certain niveau (autour de 175 sur la figure 7), la tendance à la baisse de la RMSE n'est pas évidente.

D'après les résultats, le RMSE de tous les algorithmes d'estimation DOA diminue de manière significative à mesure que le SNR (Signal Noise Ratio) augmente.

❖ Application des algorithmes d'apprentissage pour les antennes reconfigurables intelligents et leurs déploiements en temps réel :

La réalisation d'une détection DOA intelligente est un sujet intéressant de longue date, mais elle est confrontée à de grands défis liés à la construction d'un détecteur électromagnétique (EM) accordable, d'un calculateur d'apprentissage automatique et d'interférences complexes dans l'environnement EM (Frank Hijlkema(2022)) ce qui nécessite de développer des solutions efficaces à l'aide de réseaux de neurones pour les systèmes radio cognitive mobil et sans fil utilisant la technologie des antennes reconfigurables intelligents(RIA) les antennes doivent pouvoir changer la direction du lobe principal en temps réel et à différentes fréquences (Trong Duc Nguyen(2012)). Cela implique le développement des techniques d'apprentissage automatique, telles que les réseaux de neurones et des algorithmes pour que ce type d'antennes arrivent à s'adapter et répondre à l'environnement RF observé, via une architecture de radio logicielle (SDR) contrôlée par des paramètres (Fusheng Zhu & Wei Cai & Zhigang Wang & Fang Li (2022)).

Figure 8 : le diagramme de rayonnement d'un système déphasé pour des puissances estimées




Sources : Auteurs

La simple détection et la classification des signaux ne sont pas les seules décisions qu'un RSI devra prendre. Il s'agira également de déterminer si plusieurs signaux sont présents, si oui, combien, types et leurs caractéristiques (classification temps-fréquence). Afin de les prendre en charge de reconfiguration La région de prise de décision PHY/MAC devrait être responsable de l'identification des décisions PHY/MAC qu'un système a antennes reconfigurables intelligents(RSI) doit prendre afin de caractériser son mode de fonctionnement, Les algorithmes d'apprentissage aident à extraire des connaissances sur les caractéristiques actuelles et à long terme de son environnement RF notamment l'apprentissage par renforcement.

Chaque règle de décision δ_i correspond à une action A_i de reconfiguration nécessaire pour adapter une fonction ou un opérateur a l'état évalué de l'environnement.

Figure 9 : Composants architecturaux de base d'un système a antennes auto reconfigurable



Sources : Auteurs

Nouvelle façon de caractériser l'environnement de propagation basée sur des réseaux de neurones notamment (MLP) réseau de neurones artificiels (ANN) est sélectionné pour établir l'élaboration de modèle de prédiction de canal en entraînant ce qui précède l'ensembles de

données. Puissance reçue du signal de référence (RSRP) obtenue par la modélisation de canal basée sur l'IA peut être utilisée pour calculer la couverture et le rapport signal/interférence plus bruit (SINR) (AHMED M. MONT & KORANY & R. MAHMOUD (2021)). La perte de chemin (PL) est un paramètre important dans le sans-fil exprimé par :

$$PL = P_{TX} + G_{BS} + G_{RX} - P_{RX}$$


Où PL est l'abréviation de perte de trajet; P_{TX} représente la puissance d'émission; G_{BS} et G_{RX} représentent le gain d'antenne de BS et Rx, respectivement; P_{RX} est la puissance reçue. La forme du SINR peut être explicitement écrit comme :

$$SINR(g_i) = \frac{P_i}{(I + \text{Noise})}$$

Le nombre de grilles dans de bonnes conditions de SINR divisé par le nombre total de grilles valides G_v . Modèle de perte de chemin basé sur MLP un réseau de neurones est composé d'un groupe de variables d'entrée et de sortie et de plusieurs couches cachées est un réseau neuronal direct multicouche (Emmanuel Tony (2016)).

Formés par l'algorithme de rétro propagation (BP).

Figure 10 : Exemple de spectre de mesure et d'estimation de perte de chemin de propagation des ondes Radio pour un système antenne en réception basé sur le réseau de neurones MLP_regressor.



Sources : Auteurs

Une méthode précise et efficace de prédiction et d'optimisation de la propagation, renforcée par l'intelligence artificielle (IA), à partir d'observations et de décisions passées à l'aide de

techniques d'apprentissage automatique (Fusheng Zhu & Wei Cai & Zhigang Wang & Fang Li (2022)).

Nous pouvons utiliser les données collectées afin de former des antennes reconfigurables qui peuvent s'adapter à tout changement dans l'environnement RF (Trong Duc Nguyen (2012)).

Conclusion :

Dans cet article, nous avons présenté une nouvelle approche basée sur l'IA et les algorithmes d'apprentissage automatique pour détecter les signaux et estimer les DOA des ondes radio reçus par des antennes reconfigurables. L'architecture du réseau a été conçue pour répondre aux détections exactes mais le problème réside dans une cartographie qui relie les signaux de réseau d'antennes observés avec ses DOA associés à des ondes incidentes. L'objectif de cette étude est le développement d'un algorithme d'apprentissage et de détection pour des antennes reconfigurables intelligents afin de trouver Nouvelle façon de caractériser l'Environnement de propagation basée sur des réseaux de neurones et éliminer les pertes de chemin et les interférences dans un système antennaire reconfigurable MIMO sélectionné pour établir l'élaboration de modèle de prédiction de canal en entraînant ce qui précède l'ensembles de données. Dans un futur travail on peut unifier les techniques d'apprentissage automatique de l'intelligence artificiel et la formation de faisceau dans une seule structure pour réaliser une configuration numérique des antennes a la réception.

BIBLIOGRAPHIE ET REFERENCES:

- AHMED M. MONTASER & KORANY R. MAHMOUD ,(2021) “Deep Learning Based Antenna Design and Beam-Steering Capabilities for Millimeter-Wave Applications” . IEEE transactions on neural networks and learning systems, Digital Object Identifier 10.1109/ACCESS.2021.3123219. VOLUME 9, numéro 9.
- Andrew Ng, (2018) “Programming Assignments of Deep Learning Specialization (5 courses)” Scribe: Wan Zhen , course Hero volume 1.
- Ciccia, Simone , (2018).”Reconfigurable Antenna Systems: Platform implementation and low-power matters” , Politecnico di Torino, volume 1.
- CHRISTOSLIASKOS &LEFTERIS MAMATAS , ARASH POURDAMGHANI , AGELIKI TSIOLIARIDOU, SOTIRIS IOANNIDIS, ANDREAS PITSILLIDES , Senior Member IEEE, STEFAN SCHMID , AND IAN F. AKYILDIZ ,(2022). “Software-Defined Reconfigurable Intelligent Surfaces: From Theory to End-to-End Implementation”, IEEE, Volume: 110,numéro 9 .
- Emmanuel Tonye, ·(August 2016) “Antennes intelligentes: Analyse des performances par l’exemple”. Article researchgate IDO :306426899.
- Frank Hijlkema (2022) “Direction-of-Arrival Estimation Using a Machine Learning Framework”. University of Twente M.Sc. Thesis Maart Volume 1.
- Fusheng Zhu , Weiwen Cai , Zhigang Wang , and Fang Li (2022) “AI-Empowered Propagation Prediction and Optimization for Reconfigurable Wireless Networks” Volume 1.
- Jeffrey H. Reed Dr. R. Michael Buehrer Dr. Harpreet S. Dhillon (2020).” Multiple Angles of Arrival Estimation using Neural Networks”, Bradley Department of Electrical and Computer Engineering, Virginia Tech, USA publié dans arXiv:2002.00541v1 Volume 1 Nnuméro 1.
- JONAS FUCHS, MARKUS GARDILL, MAXIMILIAN LÜBKE, ANAND DUBEY, AND FABIAN LURZ (2016).” A Machine Learning Perspective on Automotive Radar Direction of Arrival Estimation” IEEE Digital Object Identifier 10.1109/ACCESS.2022.3141587 Volume 4.
- Hafssa chddadi, (2008). “Réseaux de Neurones Tutorial en Matlab” Département Informatique ESIEE-Paris Url: <http://www.esiee.fr/alanit>

- Sudharman Jayaweera, Christos Christodoulou (2011). “Radiobots: Architecture, Algorithms and Real time Reconfigurable Antenna Designs for Autonomous, Self-learning Future Cognitive Radios”). digitalrepository.unm.edu Volume 1 pp36 .
- Trong Duc Nguyen,(2012). “ Conception d’antenne intelligente reconfigurable pour la radio cognitive “ HAL Thèses Volume 1 numéro 1.
- M. M. SHI. (2018), “Simulation Implementation of Direction of Arrival Estimation based on MUSIC Algorithm”.[J]. Communications Technology, Volume 7 numéro 3.
- Yi Gong and Xingpeng Mao, (2020).“Deep Neural Network for Estimation of Direction of Arrival with Antenna Array” IEEE transactions on neural networks and learning systems, VOLUME 8 numéro 4.