



HAL
open science

Sélection de relais robuste aux canaux imparfaits pour la radio cognitive coopérative exploitant des réseaux profonds

Romain Negrel, Yacine Benatia, Anne Savard, Elena Veronica Belmega

► To cite this version:

Romain Negrel, Yacine Benatia, Anne Savard, Elena Veronica Belmega. Sélection de relais robuste aux canaux imparfaits pour la radio cognitive coopérative exploitant des réseaux profonds. 29ème Colloque Francophone du Traitement du Signal et des Images GRETSI 2023, Patrice Abry; Olivier Michel, Aug 2023, Grenoble, France. hal-04294889

HAL Id: hal-04294889

<https://hal.science/hal-04294889v1>

Submitted on 20 Nov 2023

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

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

Copyright

Sélection de relais robuste aux canaux imparfaits pour la radio cognitive coopérative exploitant des réseaux profonds

Romain NEGREL¹ Yacine BENATIA^{2,3} Anne SAVARD² E. Veronica BELMEGA^{1,3}

¹LIGM, UMR 8049, Université Gustave Eiffel, CNRS, ESIEE Paris, Marne-la-Vallée, France

²IMT Nord Europe, Institut Mines Télécom, Centre for Digital Systems, F-59653 Villeneuve d'Ascq, France

³ETIS UMR 8051, CY Cergy Paris Université, ENSEA, CNRS, F-95000, Cergy, France

Résumé – Notre étude porte sur la sélection de relais conjointe avec l'allocation de puissance permettant de maximiser le débit opportuniste d'un réseau de radio cognitive où le réseau secondaire est assistée par des relais full-duplex réalisant le schéma Compresser-et-Transférer ou *Compress-and-Forward* (CF). Le problème d'optimisation considéré n'est pas convexe mais peut-être résolu en exploitant des réseaux de neurones profonds (convolutifs ou entièrement connectés). Un deuxième avantage majeur des réseaux de neurones est leur robustesse à une connaissance imparfaite des canaux de communication.

Abstract – Our study aims at finding the joint optimal relay selection and power allocation policy to maximize the opportunistic achievable rate of a cognitive radio network where the secondary network is assisted by full-duplex relays performing Compress-and-Forward (CF). The considered optimization problem is not convex but can be solved by exploiting deep (convolutional or fully connected) neural networks. A second major advantage of neural networks lies in their robustness to imperfect channel state information.

1 Introduction

Le nombre croissant de dispositifs communicants ainsi que le besoin accru de débits toujours plus grands posent de nombreux défis pour les réseaux sans fil du futur en termes d'efficacité énergétique et spectrale, de délai, etc. Plusieurs technologies, comme la radio cognitive, le full-duplex, les communications coopératives ou l'intelligence artificielle ont donc été proposées pour y faire face, et il est fort probable que plusieurs de ces technologies doivent être combinées entre elles afin d'optimiser les réseaux de façon globale.

La radio cognitive et le full-duplex s'attaquent à la pénurie de spectre en permettant respectivement une utilisation opportuniste de bandes licenciées sous-utilisées à condition que la transmission primaire ne soit pas trop dégradée [7, 9]; ou la transmission et la réception simultanée [5]. Les communications coopératives sont quant à elles capables d'améliorer le débit d'un réseau en exploitant les signaux reçus de la part d'autres utilisateurs à portée. Enfin, il a été récemment démontré que les méthodes d'apprentissage profond permettent une gestion intelligente et efficace des ressources pour les réseaux sans fil du futur [3]. Ces dernières sont prometteuse car elles permettent de résoudre des problèmes d'optimisation complexes et non convexes, ce qui est souvent le cas dans les réseaux multi-utilisateurs et surtout les réseaux coopératifs où les relais réalisent des opérations non-triviales comme Décoder-et-Transférer (DF) ou Compresser-et-Transférer (CF) [1, 2, 7]. De plus, les approches par réseaux de neurones peuvent être rendues robustes à une connaissance imparfaite des canaux de communication [1].

Nous considérons ici un réseau de radio cognitive coopératif où l'objectif est à la fois d'optimiser l'allocation de puissances dans le réseau secondaire tout en choisissant parmi plusieurs relais candidats celui maximisant le débit secondaire. Cette

étude étend nos travaux précédents [1] (dans lesquels un seul relais était disponible, donc sans sélection de relais) en considérant un problème d'optimisation dont certains paramètres d'optimisation sont continus (i.e., les puissances de transmission) et d'autre discrets (i.e., le relais à sélectionner). Comme dans [1], nous supposons une connaissance imparfaite des gains des canaux liés au réseau primaire.

Notre approche repose sur l'utilisation de réseaux de neurones profonds entièrement connectés ou convolutifs pour résoudre le problème d'optimisation non convexe. L'avantage des réseaux convolutifs est l'exploitation d'une part, de la corrélation spatiale entre les positions des relais, les gains de canaux relatifs, et la solution du problème étudié; et, d'autre part, des estimations de canaux disponibles à chaque relais. Nos résultats numériques montrent l'intérêt de notre approche basée sur les réseaux de neurones profonds. De plus, les réseaux de neurones convolutifs permettent de doubler le débit secondaire par rapport au réseau entièrement connecté tout en satisfaisant la contrainte de qualité de service primaire.

2 Système et formulation du problème




FIGURE 1 : Système de radio cognitive coopératif étudié

Soit le réseau de radio cognitive coopératif composé d'une paire émetteur/récepteur primaire et secondaire, ainsi que d'une grille de $K \geq 2$ relais aidant la communication secondaire représenté dans la Figure 1. Tous les relais de la grille implémentent le schéma de relayage Compresser-et-Transférer ou *Compress-and-Forward* (CF) en full-duplex et sont supposés annuler parfaitement toute auto-interférence. De plus, à chaque transmission secondaire, nous ne sélectionnerons qu'un seul des relais de la grille.

Les signaux reçus au niveau du k -ième relais de la grille, et des destinations primaire et secondaire sont donnés par

$$Y_{R_k} = h_{P R_k} X_P + h_{S R_k} X_S + Z_{R_k} \quad (1)$$

$$Y_i = h_{R_k i} X_{R_k} + h_{i i} X_i + h_{j i} X_j + Z_i, \quad (2)$$

où $i, j \in \{P, S\}, i \neq j$ et $k \in \{1, \dots, K\}$; X_P, X_S et X_{R_k} sont les messages de puissance moyenne P_P, P_S et P_{R_k} transmis par l'utilisateur primaire, l'utilisateur secondaire et le k -ième relais respectivement; Z_{R_k} et Z_i , de variance N_{R_k} et N_i , représentent le bruit blanc additif Gaussien complexe circulaire au niveau du k -ième relais et de la destination $i \in \{S, P\}$ respectivement.

Les deux messages transmis par le réseau secondaire sont traités comme du bruit supplémentaire au niveau de la destination primaire; et le message transmis par l'utilisateur primaire est traité également comme un bruit supplémentaire pour tous les récepteurs secondaires. Par conséquent, nous pouvons considérer des bruits Gaussiens équivalents \tilde{Z}_{R_k} et \tilde{Z}_S au niveau du k -ième relais et de la destination secondaire de variance $\tilde{N}_{R_k} = |h_{P R_k}|^2 P_P + N_{R_k}$ et $\tilde{N}_S = |h_{P S}|^2 P_P + N_S$, respectivement.

Dans la suite, nous noterons $C(x) = \log_2(1+x)$ la capacité du canal point-à-point Gaussien. Les débits atteignables primaire et secondaire lorsque le k -ième relais de la matrice est utilisé seront noté R_{P_k} et R_{S_k} , respectivement; et le débit primaire en l'absence de transmission du réseau secondaire est donné par $\overline{R}_P = C\left(\frac{|h_{P P}|^2 P_P}{N_P}\right)$.

Dans cette étude, notre objectif est de choisir le meilleur relais parmi les candidats et de maximiser le débit secondaire R_{S_k} , lorsque le relais choisi et l'émetteur secondaire sont soumis à des contraintes de puissance maximale données par \overline{P}_R et \overline{P}_S , ainsi qu'à une contrainte de qualité de service (QoS) protégeant la transmission primaire. Cette dernière est donnée en terme de dégradation du débit primaire comparé au cas où le réseau secondaire est absent: $R_P \geq (1-\tau)\overline{R}_P$, $\tau \in [0, 1]$.

Ainsi, le problème d'optimisation considéré est donné par

$$\begin{aligned} (\text{OP}) \quad & \max_{k, P_{R_k}, P_S} R_{S_k}(P_S, P_{R_k}) \\ \text{s.t.} \quad & R_{P_k} \geq (1-\tau)\overline{R}_P, \\ & 0 \leq P_S \leq \overline{P}_S, \quad 0 \leq P_{R_k} \leq \overline{P}_R \\ & k \in \{1, \dots, K\}. \end{aligned}$$

Le théorème suivant donne la région de débits atteignables obtenue dans notre précédente étude [8] si le relais réalise CF.

Théorème 1. [8] *La région de débit atteignable en utilisant CF au k -ième relais de la matrice est donné par*

$$\begin{aligned} R_{P_k} & \leq C\left(\frac{|h_{P P}|^2 P_P}{|h_{R_k P}|^2 P_{R_k} + |h_{S P}|^2 P_S + N_P}\right) \\ R_{S_k} & \leq C\left(\frac{|h_{S S}|^2 P_S D + P_S \mathbb{E}[|h_{S S} \tilde{Z}_{R_k} - h_{S R_k} \tilde{Z}_S|^2]}{\tilde{N}_S(\tilde{N}_{R_k} + D) - |\mathbb{E}[\tilde{Z}_{R_k} \tilde{Z}_S^*]|^2}\right) \end{aligned}$$

$$\begin{aligned} \text{avec } D & = \frac{P_S \mathbb{E}[|h_{S S} \tilde{Z}_{R_k} - h_{S R_k} \tilde{Z}_S|^2] + \tilde{N}_{R_k} \tilde{N}_S - |\mathbb{E}[\tilde{Z}_{R_k} \tilde{Z}_S^*]|^2}{|h_{R_k S}|^2 P_{R_k}} \text{ et} \\ \mathbb{E}[|h_{S S} \tilde{Z}_{R_k} - h_{S R_k} \tilde{Z}_S|^2] & = |h_{S S}|^2 \tilde{N}_{R_k} + |h_{S R_k}|^2 \tilde{N}_S - 2P_P \mathcal{R}\{h_{S S} h_{S R_k}^* h_{P R_k} h_{P S}^*\}, \\ |\mathbb{E}[\tilde{Z}_{R_k} \tilde{Z}_S^*]|^2 & = |h_{P R_k}|^2 |h_{P S}|^2 P_P^2. \end{aligned}$$

Dans la suite, nous considérons que le réseau secondaire n'a qu'une connaissance imparfaite des canaux liés au système primaire: $h_{P P}$ (liaison primaire directe); $h_{S P}$, et $h_{R_k P}$ (liaisons interférentes du réseau secondaire au récepteur primaire); $h_{P R_k}$ et $h_{P S}$ (liaisons interférentes de l'émetteur primaire au réseau secondaire). Plus précisément, sous supposons que chaque relais estime tous les 8 gains de canaux individuellement et que les estimations des canaux du réseau primaire sont corrompues par un bruit Gaussien: $\hat{h}_{ij} = h_{ij} + \varepsilon_{ij}$, où $\varepsilon_{ij} \sim \mathcal{CN}(0, \sigma_{ij}^2)$ [6]. La variance de l'erreur d'estimation est telle que $\sigma_{ij}^2 = \text{Var}[h_{ij}]/\text{SNR}$, où $\text{Var}[h_{ij}]$ représente la variance empirique des vrais canaux h_{ij} et $\text{SNR} \in [-5, 20]$ dB représente le rapport signal/bruit (SNR) de l'estimateur. Nous dénoterons de plus \mathbf{h}_k le vecteur collectant les 8 gains de canaux présents dans le système étudié lorsque l'on considère le k -ième relais dans la matrice de candidats.

3 Solutions exploitant des réseaux de neurones profonds

Nous avons récemment proposé dans [1, 2] une méthode basée sur un réseau de neurones profond ainsi qu'un apprentissage robuste à la connaissance imparfaite des canaux permettant de maximiser le débit secondaire d'un réseau de radio cognitive coopératif avec un seul relais sous les mêmes contraintes de puissance et de QoS. Nous allons donc étendre cette étude au cas multi-relais avec des canaux complexes. Dans ce papier, en plus d'une architecture entièrement connectée [1, 2], nous allons également considérer un réseau convolutif qui permet d'exploiter les corrélations spatiales entre les positions des relais et les gains de canaux, dont dépendent la solution de notre problème.

Durant l'entraînement des réseaux, nous allons minimiser la fonction de coût suivante:

$$\mathcal{L} = \sum_{\ell=1}^N \sum_{k=1}^K -R_{S_k}(\mathbf{h}_{k, \ell}, P_S, P_{R_k}) + \lambda [(1-\tau)\overline{R}_P - R_{P_k}]^+,$$

où $[x]^+ = \max\{0, x\}$ et N représente le nombre total de réalisations des 8 gains de canaux $\mathbf{h}_{k, \ell}$, $\ell \in \{1, \dots, N\}$ dans la base d'entraînement. Cette fonction de coût permet d'incorporer la contrainte de QoS dans la fonction objectif, celle-ci n'étant pas une contrainte physique dure (comme la positivité des puissances par exemple) mais plutôt une exigence. Le paramètre λ permet le compromis entre maximiser le débit secondaire et satisfaire la contrainte de QoS du primaire. Pour nos simulations numériques, ce paramètre est empiriquement fixé à $\lambda = 10^3$. En utilisant cette fonction de coût, les réseaux de neurones considérés vont apprendre l'allocation de puissance optimale maximisant la moyenne des débits secondaires de tous les relais tout en satisfaisant, en moyenne sur tous les relais, la contrainte de QoS. Ensuite, le relais atteignant le meilleur débit secondaire avec cette allocation de puissance sera sélectionné. Il est à noter que même si la maximisation sur k dans le problème d'optimisation (OP) est remplacée par

une somme dans la fonction coût minimisée par le réseau de neurones, la solution prédite par le réseau de neurone permet également de résoudre le problème initial car d'une part nous ne sélectionnons qu'un relais à la fois et que maximiser la somme des débits $\sum_k R_{S_k}$ est équivalent à maximiser chacun des débits R_{S_k} de par leur indépendances les uns des autres.

Vis-à-vis de l'entraînement, nous supposons comme dans [2] que nous disposons de couples d'estimation parfaite et imparfaite des canaux : Les canaux parfaits sont utilisés lors du calcul de la fonction de coût, et les estimation imparfaites des canaux sont données en entrées des réseaux de neurones considérés. Dans la phase de test, les réseaux ne disposent bien évidemment en entrée que des estimations imparfaites des canaux. De plus, comme les canaux sont complexes, nous donnerons en entrée des réseaux de neurones à la fois la partie réelle et la partie imaginaire de ceux-ci.

Enfin, pour la phase de sélection du relais sur la grille, nous utilisons simplement les puissances prédites par les réseaux pour choisir le relais qui maximise le débit secondaire.

3.1 Réseaux de neurones entièrement connectés

Nous proposons dans un premier temps d'exploiter la même architecture que dans nos précédentes études maximisant le débit secondaire dans un réseau de radio cognitive coopératif aidé par un seul relais. Celle-ci, optimisée empiriquement, est composée de quatre couches cachées entièrement connectées comportant $M - 2M - 2M - 2M$ neurones, avec $M = 128$. Chaque couche cachée est suivie d'une fonction d'activation ReLu, et la couche de sortie est suivie de deux sigmoïdes permettant de projeter les puissances prédites dans l'ensemble faisable $[0, \overline{P_S}] \times [0, \overline{P_R}]$.

3.2 Réseaux de neurones convolutifs

Afin d'exploiter le fait que tous les relais estiment tous les gains de canaux et la corrélation spatiale entre les positions des relais, nous proposons d'exploiter des réseaux de neurones convolutifs (CNN). Ainsi l'entrée du réseau consistera en une image de dimension $5 \times 5 \times 16$, où les deux premières dimensions ($5 \times 5 = K$) correspondent aux nombre de relais candidats sur la grille et la dernière correspond aux parties réelles et imaginaires des 8 canaux présents dans le réseau. Afin de permettre une comparaison équitable entre les deux types de réseaux de neurones, nous considérons ici encore quatre couches cachées de convolutions, chacune contenant M puis $2M - 2M - 2M$ filtres de dimension 3×3 . Comme pour le réseau entièrement connecté, chaque couche cachée est suivie d'une fonction d'activation ReLu, et la couche de sortie contient deux filtres de convolution 3×3 suivis d'une sigmoïde permettant de projeter les puissances prédites dans l'ensemble faisable.

4 Résultats numériques

Dans la suite, nous supposons que les utilisateurs primaires et secondaires ainsi que leur destination associée sont positionnés de façon aléatoire dans une pièce 3D de taille $10\text{m} \times 10\text{m} \times 2.5\text{m}$. Chacun de ces noeuds est à une hauteur comprise entre 1m et 2m. La grille de 5×5 relais candidats couvre également toute la pièce, le premier relais étant situé en $(0, 0)$ et le dernier en $(10, 10)$ et ils sont tous situés à une

hauteur 2.5m (au plafond). De plus, les canaux suivent la distribution suivante $h_{ij} \sim \frac{\mathcal{CN}(0,7)}{\sqrt{1+d_{ij}^\alpha}}$, où d_{ij} représente la distance entre deux noeuds du réseau [2, 4].

Nos ensembles d'entraînement, validation et test sont composés de respectivement 10^6 , 5×10^5 et 10^6 paires d'estimations parfaite et imparfaite de gains de canaux. Les trois ensembles sont disjoints. Les canaux parfaits sont uniquement utilisés pour le calcul de la fonction de coût lors de l'entraînement et pour évaluer les différentes performances, sachant que les réseaux de neurones n'ont accès qu'aux canaux imparfaits pour leur prédictions. Nos simulations numériques sont présentées en fonction du rapport signal à bruit SNR de l'estimateur. Pour l'entraînement, nous avons utilisé ADAM avec un taux de 10^{-5} et 500 époques.

Les paramètres du système sont les suivants : $\tau = 25\%$, $P_P = \overline{P_R} = \overline{P_S} = 10$ et tous les bruits sont supposés de variance unitaire. Ces paramètres sont représentatifs parmi les nombreuses simulations réalisées et nos conclusions sont génériques.

Par la suite, nous considérerons les métriques suivantes : La dégradation du débit primaire causée par la présence du réseau opportuniste est définie comme $\Delta_\ell = 1 - \hat{R}_{P,\ell}/\overline{R}_{P,\ell}$, où $\hat{R}_{P,\ell}$ est le débit primaire obtenu par les réseaux de neurones. En utilisant cette métrique, nous définissons :

i) l'*outage empirique*, comme la proportion des cas où la contrainte de QoS n'est pas respectée

$$\text{Outage} = \frac{1}{N} \sum_{\ell=1}^N \mathbb{I}[\Delta_\ell > \tau]$$

où $\mathbb{I}[x]$ est égal à 1 lorsque x est vrai et 0 sinon ;

ii) la *dégradation moyenne du débit primaire*

$$\Delta_{\text{mean}} = \frac{1}{N} \sum_{\ell=1}^N \Delta_\ell$$

iii) et la *dégradation moyenne du débit primaire quand la contrainte de QoS n'est pas satisfaite* Δ_{out} :

$$\Delta_{\text{out}} = \frac{\sum_{\ell=1}^N \mathbb{I}[\Delta_\ell > \tau] \times \Delta_\ell}{\sum_{\ell=1}^N \mathbb{I}[\Delta_\ell > \tau]}$$

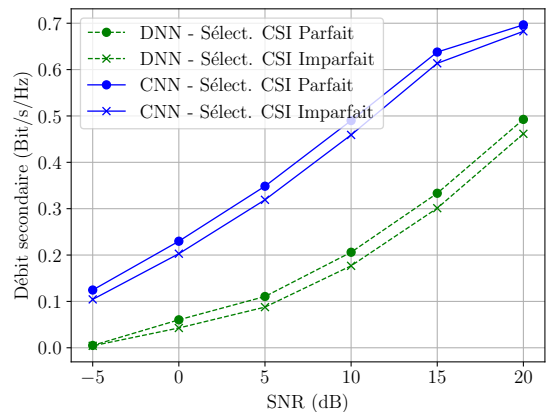


FIGURE 2 : Débit secondaire en fonction du SNR.

La Figure 2 montre le débit secondaire atteignable optimal obtenu soit avec les réseaux de neurones entièrement connectés ("DNN") ou avec les réseaux de neurones convolutifs ("CNN") pour différentes qualités d'estimation des canaux. Les courbes dénotées "Sélection CSI Parfait" correspondent au cas où, pour la phase de sélection de relais uniquement, un oracle donne les gains de canaux parfaits (ce qui correspond à la meilleure performance possible pour la sélection de relais étant donnée

l'allocation de puissance secondaire); les courbes "Sélect. CSI Imparfait" correspondent au cas où les gains de canaux imparfaits sont utilisés lors de la sélection de relais tout comme pour l'allocation de puissance du réseau secondaire.

Pour les deux types de réseaux de neurones, nous constatons que l'écart entre la méthode de sélection avec connaissance parfaite des canaux et celle avec connaissance imparfaite des canaux est très faible, montrant ainsi tout l'intérêt de notre apprentissage robuste. Dès lors, considérer des réseaux plus complexes permettant de prédire en même temps l'index du meilleur relais et l'allocation de puissance ne pourra pas dépasser la performance de la courbe "Sélect. CSI parfait".

Nous pouvons également constater que le débit obtenu par le réseau convolutif est toujours supérieur au débit obtenu par le réseau entièrement connecté, et ce quelque soit la qualité de l'estimation des gains de canaux. Ainsi, exploiter la corrélation spatiale entre les positions des relais conjointement avec les 25 estimations du canal primaire-primaire obtenues chacune par un relais, permet au réseau CNN de presque doubler le débit secondaire par rapport au DNN qui résout le problème d'allocation de puissance séparément pour chaque relais candidat avant de sélectionner le relais donnant le plus grand débit.

Les Figure 3 et Figure 4 quant à elle montrent la protection de la transmission primaire via la dégradation moyenne du débit primaire quand la contrainte de QoS n'est pas satisfaite Δ_{out} ainsi que la dégradation moyenne du débit primaire Δ_{mean} , et le taux d'outage respectivement, pour les deux types de réseaux de neurones. De même, pour toutes ces courbes, nous traçons la courbe de référence supposant la connaissance parfaite des gains de canaux ("Sélect. CSI Parfait").

Nous pouvons tout d'abord constater que quelque soit le type de réseau de neurone utilisé, la QoS est satisfaite dans plus de 96% des cas (Outage, Figure 4), montrant ainsi la puissance de notre approche basée réseaux de neurones pour résoudre le problème d'optimisation non convexe (OP). De plus, nous remarquons qu'en moyenne le taux de dégradation du débit primaire est largement inférieur au seuil de 25% pour toutes les qualités d'estimation des canaux (Δ_{mean} , Figure 3). Aussi, lorsque la QoS n'est pas satisfaite, la dégradation moyenne du débit primaire reste très proche du seuil des 25% (Δ_{out} , Figure 3).

En conclusion, le réseau de neurones convolutif permet de doubler le débit secondaire atteignable tout en satisfaisant en moyenne la contrainte de QoS et lorsque celle-ci n'est pas satisfaite, la dégradation moyenne du débit primaire est plus faible qu'avec les réseaux entièrement connectés.




FIGURE 3 : Dégradation du débit primaire en fonction du SNR.




FIGURE 4 : Taux de violation de la contrainte de QoS en fonction du SNR.

5 Conclusions

Dans cette étude, nous avons montré l'intérêt des réseaux profonds, et plus particulièrement des réseaux convolutifs ou entièrement connectés, afin de résoudre un problème d'allocation de ressources non convexe dans un réseau de radio cognitive coopératif, dans lequel il faut également sélectionner le meilleur relais parmi un ensemble de noeuds candidats. En réalisant un apprentissage robuste aux erreurs d'estimation des gains de canaux, nous avons montré que d'une part les deux types de réseaux de neurones respectent en moyenne la contrainte de qualité de service protégeant la transmission primaire; et d'autre part que le réseau convolutif, en exploitant la corrélation spatiale entre les positions des relais permet de presque doubler le débit secondaire par rapport au réseau entièrement connecté.

Références

- [1] Y. BENATIA, R. NEGREL, A. SAVARD et E. V. BELMEGA : Robustness to imperfect CSI of power allocation policies in cognitive relay networks. *In IEEE SPAWC*, 2022.
- [2] Y. BENATIA, A. SAVARD, R. NEGREL et E. V. BELMEGA : Unsupervised deep learning to solve power allocation problems in cognitive relay networks. *In IEEE ICC Workshop*, 2022.
- [3] B. BRIK et A. BOUTIBA, K. and Ksentini : Deep learning for 5G open radio access network : Evolution, survey, case studies, and challenges. *IEEE Open Journal of the Communications Society*, 2022.
- [4] Z. DING, Z. YANG, P. FAN et H. V. POOR : On the performance of non-orthogonal multiple access in 5G systems with randomly deployed users. *IEEE Signal Process. Lett.*, 21(12):1501–1505, 2014.
- [5] A. NASSER, H. AL HAJ HASSAN, J. ABOU CHAAYA, A. MANSOUR et K. YAO : Spectrum sensing for cognitive radio : Recent advances and future challenge. *Sensors*, 21(7):2408, 2021.
- [6] V. RIZZELLO et W. UTSCHICK : Learning the CSI denoising and feedback without supervision. *In IEEE SPAWC*, 2021.
- [7] A. SAVARD et E. V. BELMEGA : Full-duplex relaying for opportunistic spectrum access under an overall power constraint. *IEEE Access*, 8:168262–168272, 2020.
- [8] A. SAVARD et E. V. BELMEGA : Achievable rate regions for cooperative cognitive radio networks with complex channels and circular normal additive noises. *In GRETSI, Nancy, France*, 2022.
- [9] D. XU, X. YU, Y. SUN, D. NG et R. SCHÖBER : Resource allocation for IRS-assisted full-duplex cognitive radio systems. *IEEE Trans. Commun.*, 68(12):7376–7394, 2020.