

Prédiction de couvertures radio indoor avec des réseaux de neurones antagonistes génératifs

Cheick T. CISSÉ^{1,2} Oumaya BAALA¹ Valéry GUILLET² François SPIES³ Alexandre CAMINADA⁴

¹UTBM, CNRS, Institut FEMTO-ST - F-90000 Belfort, France

²Orange Lab, Orange - F-90000 Belfort, France

³Université de Franche-Comté, CNRS, institut FEMTO-ST - F-25200 Montbéliard, France

⁴Univ. Côte d'Azur, CNRS, Inria, I3S, COATI - F-06000 Nice, France

Résumé – La prédiction de cartes de couvertures radio en indoor et en outdoor reste un défi de grand intérêt grâce au grand nombre d'applications qu'elle permet. De nombreuses méthodes existent pour cette tâche. Cependant, chacune d'elle a ses limites (temps de calcul, précision, niveau de détails requis en entrée, généralisation à différents environnements). De plus, le problème semble moins étudié en indoor qu'en outdoor.

Dans cet article, nous proposons un modèle multi-matériaux pour la prédiction de cartes radio indoor à l'aide de réseaux de neurones antagonistes génératifs (cGAN) et d'images de plan en entrée. La validité et l'efficacité de notre méthode sont vérifiées sur des données simulées. Les résultats numériques montrent que notre approche est plus performante que les méthodes de l'état de l'art.

Abstract – Radio map or radio coverage prediction in indoor and outdoor remains a challenge of great interest thanks to the large number of applications it enables. Many techniques exist for this task. However, each of them has their limitations (computation time, accuracy, level of input information required, generalization to different environments). Also indoors seems less studied than outdoors.

In this paper, we introduce a multi-material model for indoor radio map prediction based on conditional generative adversarial network (cGAN) and floor plan images as input. The validity and efficiency of our method are verified on simulated datasets. Numerical results show that our approach outperforms state of the art methods.

1 Introduction

Le développement des secteurs de la 5G et de l'Internet des objets (IoT) a entraîné une augmentation du nombre d'utilisateurs des réseaux et services de télécommunications. La planification ainsi que l'optimisation des réseaux devient donc très importante pour une bonne qualité de service (QoS). De nombreux critères sont connus pour avoir de l'impact sur la QoS tels que le choix de la technologie (ex : Wi-Fi, 5G), l'environnement, la couverture, le placement des points d'accès (APs), etc. La couverture étant un facteur clé, il est nécessaire de savoir comment la caractériser et l'améliorer. La fonction d'affaiblissement liée à la couverture fournit la carte radio représentant la distribution d'un signal dans un environnement. Cette carte dépend de plusieurs facteurs tels que le type des murs, des portes et de nombreux autres obstacles qui peuvent bloquer les ondes. Grâce aux méthodes d'apprentissage profond, il est possible aujourd'hui de prédire des cartes radio fiables en quelques millisecondes. Les méthodes conventionnelles pour la prédiction de carte radio (RMP) comme le Ray tracing (RT) largement utilisé nécessitent l'intervention d'experts. Plusieurs travaux ont été proposés dans le cadre de la RMP pour alléger notamment l'effort de l'utilisateur et l'expertise requise. Il existe cinq grandes catégories de modèles d'affaiblissement pour la RMP :

Les modèles empiriques [1] également appelés modèles statistiques, combinent des mesures avec des équations mathématiques pour prédire l'affaiblissement du signal. Ces modèles ont des temps de calculs réduits et ils ne nécessitent pas de

connaissances détaillées de l'environnement. Cependant, ils ne sont pas très précis.

Les modèles semi-déterministes [2][3] considèrent des mesures radio à différentes positions pour calibrer les paramètres du modèle et quelques informations sur l'environnement afin de prédire l'affaiblissement. Ces modèles représentent un bon compromis entre simplicité et précision.

Les modèles déterministes [4], notamment les modèles basés sur l'optique géométrique, s'avèrent très précis, mais nécessitent des ressources de calcul plus importantes et une description détaillée de l'environnement.

Les modèles de deep learning non génératifs [5][6] sont par exemple basés sur les Perceptrons multicouche (MLP) ou sur les réseaux de neurones convolutifs (CNNs). Les premiers sont limités et non généralisables à de nouveaux environnements. Les seconds se distinguent par leur capacité à généraliser à d'autres environnements et à prendre en compte les types de matériaux et les dimensions physiques de l'environnement. Il faut noter que la plupart de ces méthodes ont été développées pour l'outdoor et nécessitent toujours un expert radio.

Les modèles génératifs basés sur l'apprentissage profond reposent notamment sur cGANs. Plusieurs modèles de cGAN[7][8] ont été proposés pour la prédiction de cartes radio. Toutefois, à notre connaissance ces modèles sont tous conçus pour l'outdoor à l'exception de [9][10]. En plus, les 2 dernières méthodes souffrent de généralisation.

Dans cet article, nous proposons un modèle de prédiction de cartes radio appelé Enhanced Indoor Radio Gan (E-IRGAN). Le modèle proposé est conçu pour être généralisable à diffé-

rents environnements indoor et emplacements de points d'accès. Nous introduisons l'utilisation du mécanisme d'attention couplé à la convolution dilatée ou convolution à trous pour améliorer les performances de notre méthode par rapport à l'état de l'art. Les contributions de notre travail sont les suivantes :

- nous introduisons une nouvelle architecture de cGANs pour la prédiction de cartes radio en indoor capable de fonctionner dans de nouveaux environnements en se basant uniquement sur une image de plan, les dimensions physiques et l'emplacement du point d'accès comme entrées,
- nous montrons la capacité de notre modèle à traiter différents types de matériaux des murs et présentons une analyse de son comportement en fonction des matériaux.

Le reste de l'article est organisé en 5 sections. L'architecture du réseau neuronal et les fonctions de perte sont décrites dans la section 2. Les jeux de données et leur pré-traitement sont détaillés dans la section 3. Les résultats sont analysés dans la section 4. Enfin, la section 5 souligne nos principales contributions et fournit des lignes directrices pour les travaux futurs.

2 Architecture de la solution proposée

Au delà de la nouvelle architecture proposée figure 1, nous avons testé trois autres modèles de générateurs proposés dans la littérature. En se référant à la figure 1, le bloc initial est composé de : padding de réflexion + Conv2D + Batch Normalization (BN) + Leaky ReLU. Les blocs d'encodage sont constitués de Conv2D + BN + Leaky ReLU. Les blocs de décodage sont formés par deux Conv2D + BN + Leaky ReLU. Le bloc final est composé d'un Conv2D suivi de la fonction d'activation Tanh. Les blocs de type "Gate" sont composés de Conv2D + BN + Leaky ReLU. Les figures 2 et 3 montrent respectivement l'architecture des blocs d'attention et des blocs de convolution dilaté.

La méthode d'entraînement des GANs est différente des réseaux de neurones classiques. Nous sommes dans le cadre d'un jeu minimisation-maximisation où le générateur essaie de tromper le discriminateur en prédisant des données proches des vraies et le discriminateur apprend à juger de la qualité d'une donnée générée par rapport à une donnée réelle. Ainsi progressivement, avec les retours du discriminateur sur la qualité des données générées, le générateur apprend à générer des données de plus haute qualité proches des réelles.

En plus de la fonction de perte d'origine des GANs appelée adversarial loss, les approches précédentes ont souligné l'importance de combiner la perte des GANs avec d'autres fonctions de perte notamment basées sur L2 ou L1. L'apprentissage du discriminateur (D) reste inchangé. Le générateur (G) a pour tâche non seulement de tromper le discriminateur mais aussi de prédire des images proches de la vérité terrain en se conformant aux pertes supplémentaires. Ainsi, au final il s'agit de minimiser la somme pondérée de 3 fonctions de pertes : la perte d'origine des GANs, la perte L1, et la perte SSIM (Structural similarity). La fonction objectif utilisée est alors donnée par l'équation suivante :

$$L = L_{cGAN}(G, D) + \lambda_1 L_1 + \lambda_2 SSIM \quad (1)$$

Expérimentalement les valeurs $\lambda_1 = 10$, $\lambda_2 = 10$, s'avèrent être convenables.

Pour entraîner les modèles cGANs, nous avons utilisé Adam Optimizer avec $\beta_1 = 0.5$ et $\beta_2 = 0.99$. Le taux d'apprentissage est fixé à $1e - 4$ et diminue progressivement jusqu'à $1e - 8$. Le nombre d'itérations est fixé à 80. L'implémentation des modèles est basée sur TensorFlow. L'entraînement des modèles a été réalisé sur une station de travail HP Z8 avec 2 GPU NVIDIA Quadro P5000.

3 Les jeux de données

La réalisation de mesures radio dans divers environnements prend du temps et est très coûteuse. Dans cette étude, en raison de l'indisponibilité de jeux de données en accès public pour l'indoor contrairement à l'outdoor, nous avons opté pour la création d'une base de données composée de données simulées. Nous avons mis en place 2 jeux de données radio simulées avec différents matériaux de construction typiques des environnements indoor, dans le cas présent des maisons et de petits bureaux. Les jeux de données sont générés avec le modèle de propagation Ray Tracing (RT) et Dominant Path Model (DPM) du logiciel de simulation Winprop [3]. Selon la surface des plans, le temps moyen de prédiction de la carte radio avec le modèle RT est environ 300 fois supérieur à celui du modèle DPM. Les paramètres de simulation sont définis dans le tableau 1. La base de données générée contient 24 plans de bâtiments différents. Nous disposons de 312 paires (plan, carte radio) pour le test et 2184 pour l'entraînement. Pour augmenter le nombre d'échantillons, nous appliquons une augmentation aléatoire des données pendant l'apprentissage en retournant et en faisant pivoter paires entrée-sortie.

TABLEAU 1 : Dataset settings.

General settings			
Tx height	1 m	Rx height	1.2 m
Frequency	2.4 GHz	Resolution	0.5 cm
Inner walls	Brick - 10 cm Plaster - 2.6 cm	Outer walls	Concrete - 20 cm Brick - 20 cm
Propagation Model	DPM, RT	Signal	Path Loss
Min surface	103 m^2	Max surface	500 m^2

La performance des modèles d'apprentissage profond dépend beaucoup de la qualité des données mais aussi de la représentation des données en entrée. Notre modèle prend en entrée 2 canaux. Un premier canal contient l'image représentant le plan du bâtiment. Pour incorporer la position du point d'accès et les dimensions physiques du bâtiment, nous mettons en place un canal supplémentaire appelé canal espace libre. Nous fixons à 1 le pixel correspondant à la position du point d'accès et les valeurs des autres pixels sont calculées à partir de l'équation d'affaiblissement de propagation en espace libre : $20 * \log_{10}(d) + 20 * \log_{10}(f) + 32.44$ où d est la distance en mètres entre l'émetteur et le pixel concerné, et f la fréquence en GHz. En ce qui concerne le codage du plan, les pixels correspondant à chaque matériau prennent la valeur de la permittivité de ce matériau. Pour prendre en compte l'épaisseur des murs, la valeur de la permittivité est multipliée par

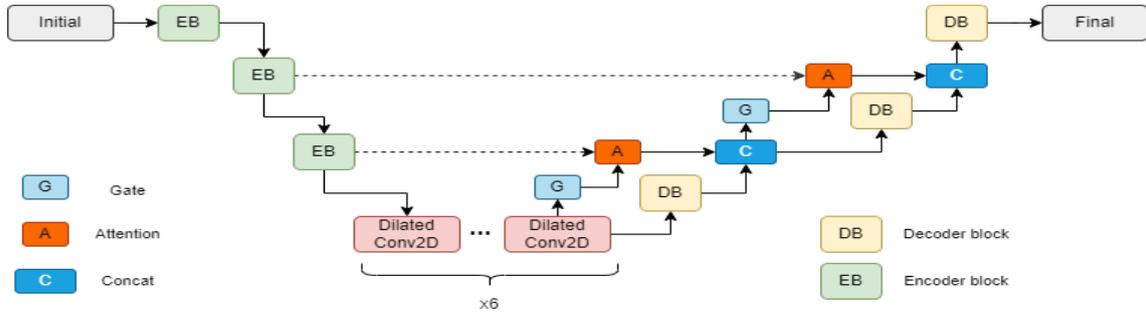


FIGURE 1 : Architecture de l'E-IRGAN.

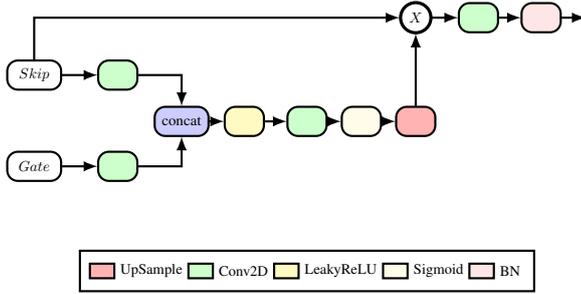


FIGURE 2 : Bloc d'attention.

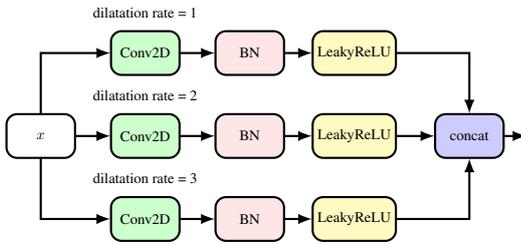


FIGURE 3 : Bloc de convolutions diluées.

2 lorsqu'il s'agit d'un mur extérieur. Les pixels identifiant le fond sont mis à 0. Cet encodage du plan est réalisé de façon automatique avec un modèle de segmentation. Comme les modèles d'apprentissage profond ont une taille d'entrée fixe, toutes les images sont redimensionnées à 256x256 pixels et la plage de valeurs des pixels normalisées à [-1,1]. Pour des raisons de visualisation, nous avons inversé l'échelle de valeur des cartes radio dans les différentes figures.

4 Analyse et résultats

Dans cette section, nous évaluons les performances des modèles testés à l'aide de trois métriques : le PSNR qui est le rapport entre la puissance maximale du signal et la puissance du bruit, le SSIM [11] qui mesure la similarité entre deux images données. SSIM est compris entre 0 et 1 et est optimale pour des valeurs proches de 1, l'erreur quadratique moyenne (RMSE) en dB est une métrique standard utilisée dans d'autres travaux connexes. Pour comparer nos modèles à l'état de l'art, nous avons inclus dans notre étude trois autres architectures proposées récemment, à savoir SegNet [12], DeepRay [5] et le UNet pour la prédiction de cartes radio. Le tableau 2 résume les performances des modèles testés. Les modèles avec * ont été entraînés à la façon des cGANs. Comme le montre le ta-

bleau 2, l'E-IRGAN atteint la meilleure performance sur les deux jeux de données. Nous pouvons noter avec le UNet et UNet* que l'entraînement d'un modèle sous le cadre cGANs donne de meilleures performances dans la tâche RMP.

La figure 5 montre les prédictions de l'E-IRGAN sur différents plans. Comparé à la réalité de terrain générée via le modèle DPM, on peut observer la cohérence et la capacité de notre modèle à traiter des plans non vus lors de l'apprentissage. Le tableau 3 montre la sensibilité de notre modèle en fonction du type de matériau des murs.

Comme l'illustre la figure 1, le nombre de paramètres et la complexité du modèle E-IRGAN dépendent du nombre de blocs d'encodage/décodage et du nombre de blocs dilués. La figure. 4 donne la valeur du RMSE en fonction du nombre de blocs d'encodage et de blocs dilués. Nous pouvons observer une amélioration des performances avec l'augmentation de ces 2 paramètres.

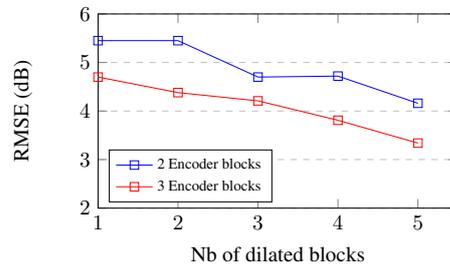


FIGURE 4 : Analyse de complexité.

5 Conclusion

Dans ces travaux, nous avons proposé une approche cGAN pour la prédiction de cartes radio en indoor avec plusieurs avantages : facilité d'utilisation, temps de calcul réduit (moins de 1 seconde face à plusieurs minutes pour les cartes radio simulées par RT ou DPM), précision, prise en compte de différents types de matériaux et généralisable. La méthode proposée génère des cartes radio de haute qualité avec comme seules données d'entrée une image du plan de l'habitat, la position des points d'accès et des informations telles que les dimensions physiques, les types de matériaux des murs et portes. Nous obtenons une RMSE d'environ 3 dB, ce qui représente une amélioration d'environ 1 dB par rapport à l'état de l'art. Dans nos futurs travaux, nous prévoyons d'étendre et d'entraîner notre modèle sur plus de fréquences et de l'ajuster aussi sur des mesures réelles radio.

TABLEAU 2 : Performance des modèles sur les jeux de données RT et DPM.

Models	RT						DPM						#parameters	Inference time
	Test set			Train set			Test set			Train set				
	PSNR	SSIM	RMSE		seconds									
SegNet	24.15	0.922	6.23	26.10	0.936	5.83	25.96	0.944	4.72	26.88	0.951	4.81	15 M	0.17
DeepRay	25.83	0.923	4.95	26.52	0.928	5.47	25.24	0.936	5.18	25.98	0.946	5.34	21 M	0.19
UNet	25.11	0.927	5.84	25.93	0.933	5.93	26.29	0.950	4.57	28.88	0.960	3.79	54 M	0.19
UNet*	28.54	0.956	3.82	35.86	0.979	1.86	28.24	0.969	3.72	27.9	0.968	4.36	54 M	0.19
E-IRGAN*	30.77	0.963	2.94	36.11	0.985	1.95	30.47	0.975	3.02	37.55	0.992	1.50	39 M	0.26

TABLEAU 3 : Performance de l'E-IRGAN en fonction du type de matériau sur les jeux de test DPM.

Matériaux (Externe - Interne)	PSNR	SSIM	RMSE
brique - brique	31.56	0.964	2.49
brique - placo	32.43	0.972	2.08
béton - brique	29.34	0.955	3.79
béton - placo	29.76	0.960	3.41

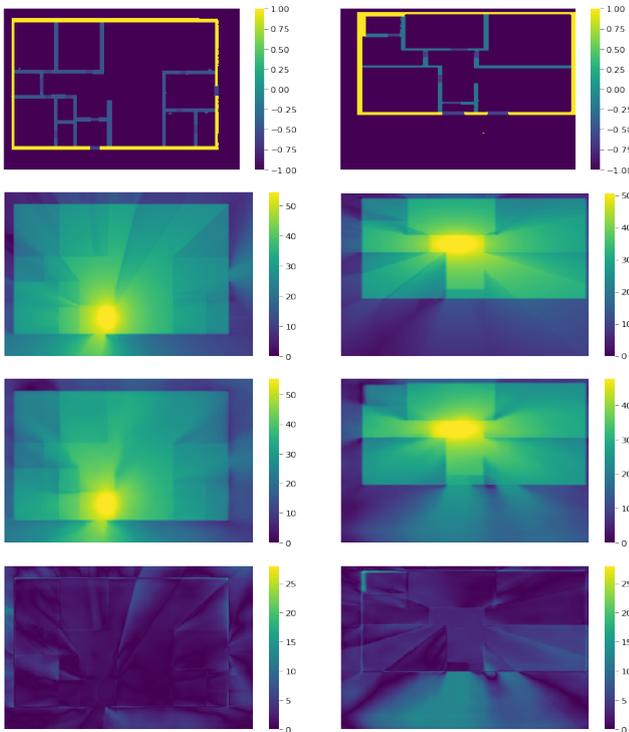


FIGURE 5 : Prédiction de l'E-IRGAN pour différents plans. 1ère ligne : plan, 2nde ligne : cible, 3ème ligne : prédictions, 4ème ligne : erreur absolue (dB).

Références

[1] M. Kacou, V. Guillet, G. El Zein, and G. Zaharia, "A multi-wall and multi-frequency home environment path loss characterization and modeling," *European Conference on Antennas and Propagation (EuCAP)*, 2018.

[2] J. M. Keenan and A. J. Motley, "Radio coverage in buildings," *British telecom technology Journal*, vol. 8, no. 1, pp. 19–24, 1990.

[3] R. Wahl, G. Wölflé, P. Wertz, P. Wildbolz, and F. Land-

storfer, "Dominant path prediction model for urban scenarios," in *14th IST Mobile and Wireless Communications Summit*, 2005.

[4] K. Rizk, J.-F. Wagen, and F. Gardiol, "Two-dimensional ray-tracing modeling for propagation prediction in micro-cellular environments," *IEEE Transactions on Vehicular Technology*, vol. 46, no. 2, pp. 508–518, 1997.

[5] S. Bakirtzis, J. Chen, K. Qiu, J. Zhang, and I. Wassell, "Em deepRay : An expedient, generalizable and realistic data-driven indoor propagation model," *IEEE Transactions on Antennas and Propagation*, 2022.

[6] R. Levie, Ç. Yapar, G. Kutyniok, and G. Caire, "Radionet : Fast radio map estimation with convolutional neural networks," *IEEE Transactions on Wireless Communications*, vol. 20, no. 6, pp. 4001–4015, 2021.

[7] S. K. Vankayala, S. Kumar, I. Roy, D. Thirumulanathan, S. Yoon, and I. S. Kanakaraj, "Radio map estimation using a generative adversarial network and related business aspects," in *2021 24th International Symposium on Wireless Personal Multimedia Communications (WPMC)*, pp. 1–6, IEEE, 2021.

[8] S. Zhang, A. Wijesinghe, and Z. Ding, "Rme-gan : A learning framework for radio map estimation based on conditional generative adversarial network," *arXiv preprint arXiv :2212.12817*, 2022.

[9] C.-H. Liu, H. Chang, and T. Park, "Da-cgan : A framework for indoor radio design using a dimension-aware conditional generative adversarial network," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, pp. 498–499, 2020.

[10] W.-Y. Kim, S.-H. Tae, and D.-H. Seo, "Access-point centered window-based radio-map generation network," *Sensors*, vol. 21, no. 18, p. 6107, 2021.

[11] Z. Wang, E. P. Simoncelli, and A. C. Bovik, "Multiscale structural similarity for image quality assessment," in *The Thirty-Seventh Asilomar Conference on Signals, Systems & Computers, 2003*, vol. 2, pp. 1398–1402, Ieee, 2003.

[12] K. Qiu, S. Bakirtzis, H. Song, J. Zhang, and I. Wassell, "Pseudo ray-tracing : Deep learning assisted outdoor mm-wave path loss prediction," *IEEE Wireless Communications Letters*, vol. 11, no. 8, pp. 1699–1702, 2022.