

Imagerie du sein par réseaux de neurones convolutionnels en cascade à partir de données conjointes micro-ondes et ultrasons

Culture Sciences
de l'Ingénieur

Valentin NÖEL

Édité le
31/10/2022

école —————
normale —————
supérieure —————
paris — saclay —————

Cette ressource est issue d'une publication du numéro 110 de La Revue 3EI d'octobre 2022 et fait partie du « Dossier Intelligence Artificielle » [12] sur Culture Sciences de l'Ingénieur. Valentin Noël est doctorant en imagerie médicale au Laboratoire SATIE de l'ENS Paris-Saclay.

Dans le contexte de la caractérisation précoce des tumeurs du sein, il est intéressant de combiner les modalités électromagnétiques (EM) et ultrasonores (US), car elles sont toutes deux non ionisantes et peu coûteuses, et offrent des caractéristiques de résolution complémentaires.

Cette ressource propose une nouvelle structure de réseau neuronal convolutif (CNN), appelée réseau neuronal complexe en cascade tenant compte de la structure (SACC-CNN). Il se compose de deux parties, le réseau de reconstruction (SARNet) et le réseau de classification (SACNet). Le SACNet produit la carte des types de tissus qui est ensuite transmise au SARNet, qui reconstruit les paramètres EM et US. Ces deux parties peuvent être considérées comme deux modules indépendants. Une fonction de perte guidée par la physique est mise en œuvre dans le réseau SARNet pour améliorer la similarité structurelle. Les principales caractéristiques de ces approches, illustrées par des simulations, sont décrites.

1 – Introduction

Les tumeurs mammaires font partie des tumeurs les plus courantes chez les femmes et leur détection précoce est essentielle à un stade précoce de la progression du cancer [1]. Le développement de technologies permettant d'imager une petite tumeur à faible coût et à faible risque est donc une question importante. Actuellement, la mammographie à rayons X reste l'approche la plus étendue pour cette détection. Malgré la haute résolution des résultats d'imagerie, la mammographie à rayons X présente un certain nombre de limites, notamment une faible sensibilité, des rayonnements ionisants, l'inconfort dû à la compression du sein et une détection très affectée par la densité du sein. La fusion de données multimodales (données ultrasonores et électromagnétiques) complémentaires a été étudiée [2]. Cependant, l'inversion conjointe est une autre façon de fusionner les données où celles-ci sont inversées simultanément. La similarité structurelle peut également être utilisée afin de combiner les paramètres de différentes modalités dans la procédure d'inversion [3]. Les réseaux de neurones convolutionnels (CNN) peuvent être une bonne solution. À titre d'exemple, parmi beaucoup d'autres, dans [4], une structure CNN est conçue pour utiliser les champs mesurés comme entrée et prédire directement la carte de diffusion. Les réseaux de pointe pour la détection de tumeurs et/ou la reconstruction d'images du sein comprennent le réseau U-Net et certaines de ses extensions développées dans [5], ainsi que les réseaux de neurones artificiels (ANN) présentés dans [6]. Ce type de méthodes peut fournir des résultats de reconstruction en temps réel tout en tirant peu de profit des connaissances physiques disponibles.

C'est pourquoi on s'intéresse de plus en plus à la construction de réseaux de neurones afin qu'ils bénéficient de la physique du problème à résoudre. Dans ce contexte, plusieurs travaux se

déroulant dans un cadre physique différent ont mis en œuvre des réseaux neuronaux inspirés de la physique (Physics-Inspired Neural Network ou PINN). Les efforts se sont principalement concentrés sur la conception d'un cadre physique qui peut être traduit de différentes manières. Dans l'imagerie du sein, il faut reconstruire l'image du sein et avant tout classer ses composants en tant que tissus avec ou sans tumeur. Des travaux antérieurs ont illustré différentes approches pour résoudre un tel problème, certaines avec l'apprentissage profond. À notre connaissance, aucun de ces réseaux n'a été inspiré/guidé par la physique de ce même problème malgré le fait qu'ils soient clairement bénéfiques à la qualité de la reconstruction et/ou de la classification. Dans cette contribution, on s'intéresse particulièrement à la précision de l'image du sein reconstruite et surtout à la similarité structurelle entre l'image du sein et la vérité terrain. En effet, une amélioration de la similarité structurelle entre l'image du sein et la vérité terrain devrait indiquer une amélioration de la qualité de l'image par rapport aux structures internes existantes du sein ainsi qu'une amélioration concernant la fiabilité du diagnostic par le biais d'une amélioration de la fiabilité de sa physique. Le réseau neuronal doit donc être configuré de manière à favoriser une reconstruction maximisant la similarité structurelle de l'image reconstruite. À partir d'un réseau de neurones multi-tâches développé précédemment, deux approches visant à améliorer la signification physique susmentionnée sont proposées. Le réseau ainsi développé est un réseau neuronal multi-tâches en cascade influencé par la physique (plus précisément, avec une fonction de coût comportant des contraintes physiques inhérentes au problème étudié), composé d'un réseau neuronal principal divisé en deux réseaux neuronaux secondaires, comme illustré dans la figure Fig.1. Les entrées de ce réseau correspondant aux parties réelles et imaginaires de trois modalités différentes : ondes EM (1 Gz), ondes US (100 et 200 kHz).

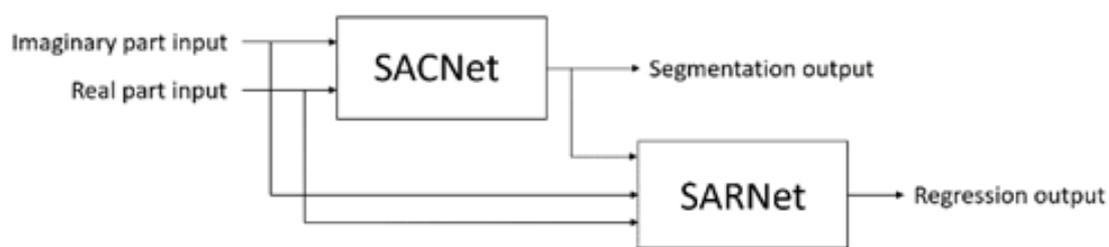


Figure 1 : Schéma de l'architecture du réseau SACC-CNN

En se concentrant sur la fusion des données électromagnétiques (EM) et ultrasonores (US), un cadre de réseau neuronal convolutif complexe en cascade à double flux avec « conscience structurelle » est proposé ici. Dans les expériences numériques, on suppose qu'il s'agit d'un sein en suspens - contrairement au sein compressé de la mammographie à rayons X - immergé dans un milieu de couplage non limité. La contribution est organisée comme suit. Dans la section 2, la modélisation est présentée. Dans la section 3, la structure du réseau est esquissée. Dans la section 4, des expériences numériques sur des fantômes de seins sont proposées. La conclusion est la section 5. Notez que les travaux récents sur l'imagerie du sein et la fusion de données par les collègues mentionnés précédemment [7] ont été illustrés sur des fantômes mammaires et des ensembles de données comme ceux d'aujourd'hui, mais le passage à un CNN sur mesure contraste avec ces recherches antérieures.

2 – Modélisation électromagnétique et ultrasonore

Une géométrie bidimensionnelle est considérée, les matériaux de type fluide supportant uniquement les ondes de compression dans le cas US, tandis que le cas EM est concerné uniquement par la polarisation magnétique transversale.

Les ondes harmoniques temporelles sont supposées avec une dépendance temporelle $\exp(-i\omega t)$ pour les US et les EM. Le sein est situé dans un domaine d'intérêt (DoI) \mathcal{D} . Le milieu de fond connu

a une permittivité relative complexe de ϵ_b , une perméabilité de μ_b et, en conséquence, un nombre d'onde de $k_b^{EM} = \omega\sqrt{\epsilon_0\epsilon_b\mu_b}$

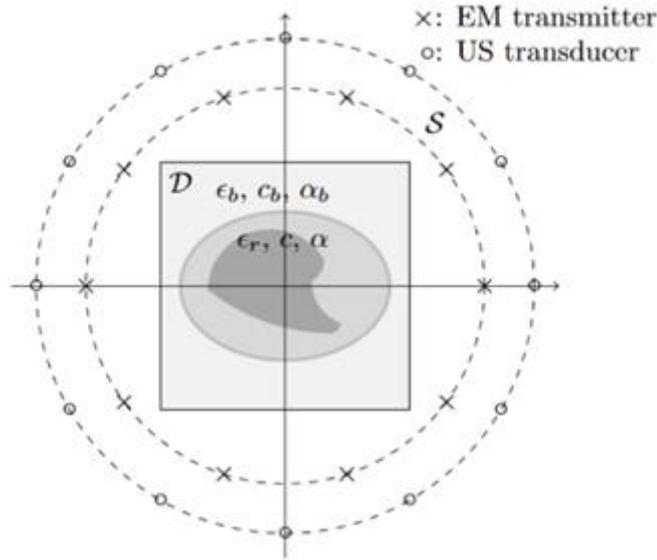


Figure 2 : Schéma de la configuration

en EM, une vitesse du son de c_b , atténuation α_b , et nombre d'onde $k_b^{AC} = \omega/c_b + \alpha_b$ en US. La perméabilité et la densité sont constantes partout. Les distributions spatiales de la permittivité relative complexe $\epsilon_r(r) = \epsilon'_r(r) + i\epsilon''_r(r)$ de la vitesse du son $c(r)$ et de l'atténuation $\alpha(r)$ sont les inconnues. Pour chaque modalité, N_i sondes sont situées à r'_v , $v = 1, 2, \dots, N_i$ sur un cercle S , comme l'indique la figure Fig.2. Chacune illumine la DoI et les champs diffusés sont collectés par tous.

Pour travailler numériquement avec ce modèle, \mathcal{D} est discrétisé en $M = H \times W$ petits pixels carrés centrés sur $r_{j,m} = 1, 2, \dots, M$, dont la taille est différente entre le problème direct (acquisition des données) et le problème inverse (sondage du sein).

Les contrastes US et EM sont définis comme suit

$$\chi^{AC}(r) = \frac{(k^{ac}(r))^2 - (k_b^{ac})^2}{(k_b^{ac})^2}$$

$$\chi^{EM}(r) = \frac{(k^{em}(r))^2 - (k_b^{em})^2}{(k_b^{em})^2}$$

et la source de contraste pour l'incidence v comme suit

$$J_v(r) = \chi(r)F_v^t(r)$$

avec F champ de pression P ou champ électrique E . L'exposant "t" indique le champ total.

3 – Approche du problème réseau de neurones convolutionnel

La tâche principale est de renforcer la similarité structurelle (cohérence entre la structure de l'image reconstruite et celle de la vérité terrain - la structure peut être dans ce cas considérée comme correspondant aux contours de l'image de référence) de l'image, il est donc intéressant de comparer d'abord une structure CNN spécialisée non cascadée avec une entrée multi-flux et une stratégie d'apprentissage multi-tâches (CNN-MM) avec sa version cascadée (SACC-CNN) qui prend plus en compte la structure morphologique de l'objet basée sur la segmentation, puis de définir un

réseau à fonction de coût guidé par la physique (PG SACC-CNN) guidant vers une meilleure similarité structurelle (et donc vers une physique plus réaliste).

a) Architectures des réseaux de neurones

Comme indiqué, la structure du CNN-MM est inspirée d'un CNN à deux flux (similaire au CNN représenté dans la figure Fig.4). Dans le présent travail, des données EM à une seule fréquence et des données US à deux fréquences sont utilisées.

Pour introduire la connaissance physique, l'entrée du réseau choisie est la source de contraste et la quantité de champ ω et f . Ces variables se trouvent à l'intérieur du DoI et sont obtenues par rétropropagation. Remarquez que dans les méthodes de rétropropagation, un paramètre complexe est utilisé pour minimiser l'erreur quadratique dans le champ diffusé, ici ce paramètre de rétroprojection spécifique EM normalisé est simplement fixé à 1.

Pour chaque modalité à une fréquence donnée, ω_v et f_v sont remodelés en images $H \times W$ et permettront de limiter la longue corrélation au niveau des données et également de rendre le réseau efficace avec moins de couches ou avec des tailles de noyau plus petites. Les $R\{\omega_v\}$, $I\{\omega_v\}$, $R\{f_v\}$ et $I\{f_v\}$ (parties réelles et imaginaires de la source de contraste et de la quantité de champ) obtenus à partir de toutes les incidences sont séparés en entrée partie imaginaire et entrée partie réelle avec une taille de $H \times W \times 4N_i$. Pour réaliser la reconstruction, le réseau SARNet a une sortie de taille $H \times W \times 4$ pour prédire les paramètres EM ϵ'_r et ϵ''_r (perméabilités relatives complexes), et les paramètres US c et α (vitesse dans le milieu et atténuation) simultanément.

Outre la tâche de régression, un classificateur auxiliaire (SACNet) est introduit pour fournir une image de segmentation. Un classificateur softmax donne la distribution de probabilité sur les classes de sortie prédites (types de tissus et arrière-plan) pour chaque pixel et ledit pixel est classé dans la classe ayant le score le plus élevé. Cette tâche de segmentation est tout à fait pertinente pour la tâche de régression. Cet apprentissage multitâche peut faciliter la formation du réseau et améliorer sa capacité de généralisation. Un autre intérêt s'ajoute, puisque, toujours dans l'objectif d'alimenter le réseau en connaissances physiques, la sortie de la classification pourrait informer la reconstruction et donc potentiellement augmenter sa qualité. Une telle architecture est l'architecture dite en cascade esquissée dans les Fig.2, 3 et 4. Le CNN en cascade résultant est composé de deux blocs principaux, l'un étant le premier CNN en charge de la classification dont la sortie est directement entrée dans le second, en charge de la reconstruction. Ici, BN correspond à Batch Normalization.

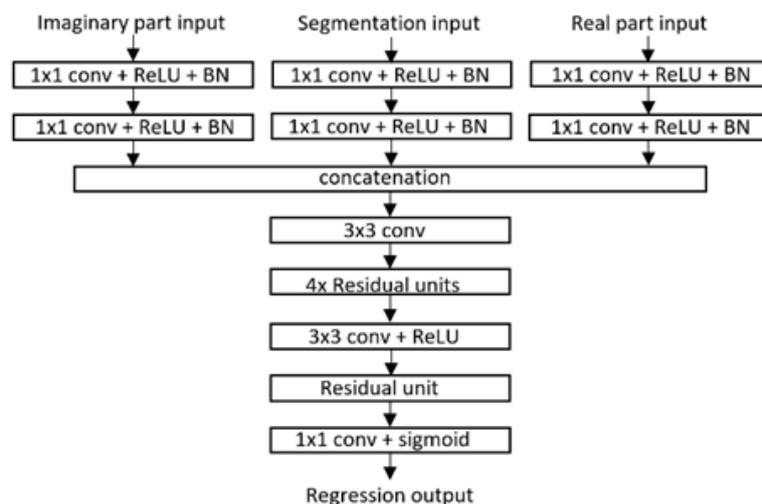


Figure 3 : Schéma de l'architecture du sous-réseau SARNet

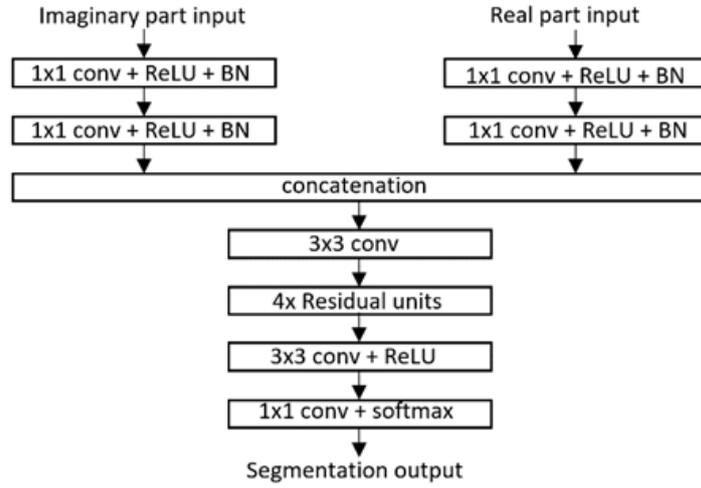


Figure 4 : Schéma de l'architecture du sous-réseau SACNet

b) Fonction de coût

Les réseaux considérés, c'est-à-dire CNN-MM et SACC-CNN (guidé par la physique), utilisent des fonctions de perte différentes. La fonction de perte pour la tâche de régression dans CNN-MM est choisie comme la moyenne de l'erreur absolue et de l'erreur au carré, comme suit

$$L_{\text{reg}} = \frac{1}{2NHW} \sum_n \sum_{h,w} \left(\left| \widehat{\zeta}_{h,w}^n - \zeta_{h,w}^n \right| + \left| \widehat{\zeta}_{h,w}^n - \zeta_{h,w}^n \right|^2 \right)$$

pour le paramètre ζ , où $\widehat{\zeta}_{h,w}^n$ est la valeur prédite du n -ième échantillon situé à (h, w) et $\zeta_{h,w}^n$ est la vérité terrain. N est le nombre d'échantillons dans un lot d'apprentissage. Pour le SARNet, la même fonction de perte a d'abord été utilisée. Cependant, comme nous l'avons vu dans le chapitre "Physique", une fonction de perte peut être ajustée et utilisée comme guide physique pour la tâche d'apprentissage d'un réseau. Dans ce contexte précis, il serait particulièrement intéressant d'entraîner le SARNet de telle sorte qu'il se concentre sur la similarité structurelle entre l'ensemble d'entraînement et leurs vérités de base afin d'améliorer la définition des contours (internes et externes) reconstruits.

Dans cette optique, une métrique SSIM (Structural Similarity Index Metric) est mise en œuvre dans la fonction de perte guidée par la physique proposée pour comparer la similarité structurelle de l'image complète et de la vérité terrain (respectivement désignées par x et y), avec

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1) + (2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}$$

dans laquelle μ_x et μ_y sont des moyennes locales des images, σ_x et σ_y sont des écarts types locaux, σ_{xy} est une covariance croisée locale, et C_1 et C_2 sont des constantes de régularisation. D'autres implémentations, par exemple une fenêtre glissante SSIM de plus petite taille, pourraient hypothétiquement donner une meilleure granularité à la similarité structurelle. En conséquence, cette connaissance conduit à la nouvelle fonction de perte

$$L_{\text{regnew}} = L_{\text{reg}} + \beta(1 - SSIM(x, y))$$

β étant un terme de régularisation réglé à chaque époque par le biais d'un algorithme Hyperband tel que présenté dans [9]. Cette fonction de perte donnera donc la priorité à la similarité structurelle plutôt qu'à l'erreur quadratique.

Dans la tâche de segmentation, chaque pixel est classé dans un type de tissu ou un milieu de fond. Le classificateur Softmax est utilisé pour ce problème de classification multi-classes. La fonction de perte est l'entropie croisée comme suit

$$L_{seg} = -\frac{1}{NHW} \sum_n \sum_{h,w} \sum_k t_{h,w;k}^n \log(s_{h,w;k}^n)$$

en laissant $t_{h,w;k}^n$ et $s_{h,w;k}^n$ la vérité de terrain et la probabilité prédite du pixel pour la classe k .

4 – Simulations numériques

Dans cette section, des simulations numériques sont effectuées pour évaluer les performances des réseaux conçus dans la section précédente.

a) Configuration des expérimentations et set de données

Les réseaux sont entraînés et testés avec des fantômes de seins réalistes disponibles dans le référentiel en ligne de l'UWCEM (University of Wisconsin Cross-Disciplinary Electromagnetics Laboratory) [10]. La composition du sein varie d'une personne à l'autre et les fantômes du référentiel sont classés en quatre classes en fonction de la densité radiographique : tissu presque entièrement gras, tissu fibroglandulaire épars, sein à densité hétérogène et tissu extrêmement dense.

Comme les seins denses présentent un risque plus élevé de cancers, les fantômes de seins classés dans les deux dernières classes, appelées classes 3 et 4, sont utilisés pour générer l'ensemble de données. Ceux-ci étant exempts de tumeurs, une tumeur artificielle est ajoutée dans la partie glandulaire avec une localisation aléatoire. Sa taille est fixée de manière aléatoire avec un rayon compris entre 6 mm et 8 mm pour ajouter de la variabilité.

Dans les simulations, pour le cas EM, 20 antennes sont disposées uniformément sur un cercle de rayon 0,1 m, fonctionnant comme des sources et des récepteurs idéaux simultanément à une seule fréquence 1 GHz. Pour le cas américain, 64 transducteurs fonctionnent à 100 et 200 kHz sur un cercle de 0,12 m de rayon. La DoI pour la simulation a une résolution de 0,5 mm, comme indiqué dans le référentiel, ce qui implique 300 × 300 pixels. Les champs diffus sont obtenus en résolvant le problème avant. Les calculs correspondants sont exécutés dans Matlab.

L'augmentation des données (opérations géométriques sur les données d'entraînement afin d'augmenter leur nombre) est utilisée pour élargir l'ensemble des données. Différents niveaux de bruit sont ajoutés aux champs diffusés, de 15 dB à 30 dB au-dessus du SNR moyen. La DoI est discrétisée en 75 × 75 pixels pour calculer les données d'entrée ω et f . L'image du type de tissu et la distribution des paramètres EM et US avec la même discrétisation sont utilisées comme sortie. Une rotation et un retournement sont effectués sur l'entrée et la sortie d'un échantillon pour générer de nouvelles données. L'ensemble des données contient 2 920 d'échantillons, dont 1 536 d'échantillons de la classe 3 et 1 384 de la classe 4, divisés ensuite en un ensemble d'apprentissage de 2 336 échantillons et un ensemble de test de 584 échantillons.

Les plages de normalisation des paramètres sont de [1,70], [0,30], [1450,1650] et [0,5] pour ϵ'_r , ϵ''_r , c et α , respectivement. Ici, l'atténuation à 200 kHz est prédite. Dans la tâche de segmentation, les pixels sont classés en six catégories selon le type de tissu indiqué dans le référentiel, à savoir le tissu de fond, la peau, la graisse, le tissu de transition, le tissu glandulaire et le tissu tumoral.

b) Détails d'implémentation

Tous les réseaux sont implémentés dans Keras avec le backend Tensorflow, exécutés sur un ordinateur portable avec un CPU NVIDIA Quadro P620. Les poids des pertes de segmentation et de régression sont fixés à 1 et 8, respectivement. La régularisation L_2 est choisie pour tous les réseaux avec un paramètre de régularisation $\gamma = 0.01$. Les poids dans les couches convolutionnelles sont initialisés par l'initialisation de Xavier. Les réseaux sont entraînés avec le solveur ADAM avec un taux d'apprentissage initial de $5e^{-4}$ qui décroît avec un facteur de 0,15 toutes les 10 époques. La taille du lot est de 10 et 60 époques sont exécutées au total.

Tous les réseaux sont entraînés sur le même set de données d'entraînement avec la même configuration. Pour les réseaux en cascade, chaque sous-réseau a été entraîné avec le jeu de données de base correspondant.

Il est à noter que différents jeux de données ont été testés sur les deux réseaux afin de quantifier leur efficacité de calcul, ce que nous aborderons à la fin de la partie évaluation quantitative.

c) Évaluation quantitative

La performance du réseau est évaluée par deux mesures pour différentes tâches. Pour la segmentation, l'Intersection-sur-Union (IoU) pour la classe i est calculée comme suit

$$IoU_i = \frac{1}{N} \sum_n \frac{p_{ii}^n + 1}{\sum_{k=1}^K p_{ik}^n + \sum_{k=1}^K p_{ki}^n - p_{ii}^n + 1}$$

où p_{ik}^n est le nombre de pixels dans l'échantillon de test n étiqueté comme classe i mais prédit dans la classe k , et K est le nombre de classes. Notez que, dans le calcul, un nombre de lissage de 1 est utilisé. Pour la régression, l'erreur relative est utilisée pour l'évaluation.

Les évaluations quantitatives, IoU, Err et SSIM sur l'ensemble de test sont données dans les tableaux Tab. 1, 2 et 3 respectivement. Pour fournir de meilleures comparaisons, un CNN inspiré de [11] appelé Res-Net 50, basé sur un modèle U-Net utilisant des connexions par saut, a également été implémenté, car il a donné de bons résultats pour la reconstruction d'images.

Network	Medium	Skin	Fat	Transition	Gland	Tumor	Average
Res-Net	0.9972	0.8361	0.8635	0.4221	0.6779	0.7089	0.7533
CNN-MM	0.9948	0.8341	0.8604	0.4192	0.6768	0.7151	0.7511
SACC-CNN	0.9967	0.8358	0.8621	0.4200	0.6781	0.7165	0.7529
PG-SACC-CNN	0.9989	0.8379	0.8660	0.4219	0.6798	0.7183	0.7545

Tableau 1 : IoU obtenue par les différents réseaux sur les données de test

Network	Medium	Skin	Fat	Transition	Gland	Tumor	Average
Res-Net	0.997	0.836	0.863	0.422	0.678	0.709	0.753
CNN-MM	0.995	0.834	0.860	0.419	0.677	0.715	0.751
SACC-CNN	0.997	0.836	0.862	0.420	0.678	0.717	0.753
PG-SACC-CNN	0.999	0.838	0.866	0.422	0.680	0.718	0.755

Tableau 2 : Précision obtenue par les différents réseaux sur les données de test

Network	mean-SSIM	lowest SSIM	highest SSIM
Res-Net	0.796	0.504	0.892
CNN-MM	0.723	0.512	0.875
SACC-CNN	0.771	0.510	0.882
PG-SACC-CNN	0.810	0.511	0.903

Tableau 3 : Similarité structurelle obtenue par les différents réseaux entre les images reconstruites et leurs vérités terrain

De l'évaluation quantitative, on peut voir que le SAC Cascaded CNN pour reconstruire le type de tissu et la valeur du paramètre fonctionne le mieux sur l'ensemble de test. Le SACC-CNN guidé par la physique surpasse aussi légèrement le SACC-CNN dans la classification et la reconstruction. Il faut noter que les résultats SSIM montrés ici sont les SSIM moyens de l'ensemble du jeu d'essai et comprennent de fortes variations avec au moins une aberration correspondant au SSIM le plus bas rapporté dans le tableau Tab.3.

On peut conclure qu'un SACC-CNN n'est que légèrement plus performant sur ce jeu de données qu'un CNN-MM, tandis qu'un SACC-CNN guidé par la physique est modérément plus performant que les deux et est plus performant que le Res-Net pour la partie reconstruction, tout en menant à des résultats légèrement meilleurs, mais pas de manière significative, pour la partie classification. Il est possible d'obtenir une reconstruction en temps réel. En moyenne, avec l'implémentation de la transformation de Fourier rapide, les données d'entrée du réseau peuvent être calculées en 0,5681 secondes et il faut 0,2718 secondes pour obtenir les résultats de prédiction d'un échantillon sur un CPU Intel Core i7 10875H (2,30 GHz).

5 – Conclusion

En vue de l'imagerie mammaire en temps réel, une structure cascadée guidée par la physique a été proposée pour combiner les données EM et US. Outre la tâche de régression pour prédire les valeurs des paramètres, un classificateur auxiliaire est utilisé pour classer chaque pixel afin de réaliser la segmentation du modèle. L'architecture en cascade améliore la similarité structurelle de l'image fournie, tandis que la mise en œuvre d'une fonction de perte guidée par la physique réduit l'erreur sur les valeurs des paramètres prédits et améliore la similarité structurelle de l'image.

Il est cependant possible d'imaginer de nombreuses fonctions de perte guidées par la physique pour les problèmes de diffusion inverse, et il est nécessaire d'étudier leur complémentarité afin de créer une fonction de perte guidée par la physique menant à un meilleur apprentissage.

Références :

- [1]: G. Baldassarre and B. Belletti, "Molecular biology of breast tumors and prognosis", F1000Research, vol. 5, 2016
- [2]: Y. Qin, T. Rodet, M. Lambert, and D. Lesselier, "Microwave breast imaging with prior ultrasound information", IEEE Open Journal of Antennas and Propagation, vol. 1, pp. 472-482, 2020.
- [3]: L. A. Gallardo and M. A. Meju, "Joint two-dimensional DC resistivity and seismic travel time inversion with cross-gradients constraints", Journal of Geophysical Research: Solid Earth, vol. 109, no. B3, 2004
- [4]: P. Ran, Y. Qin, D. Lesselier, and M. Serhir, "Subwavelength microstructure probing by binary-specialized methods: Contrast source and convolutional neural networks", IEEE Transactions on Antennas and Propagation, vol. 69, no. 2, pp. 1030-1039, 2021

- [5]: G. Du, X. Cao, J. Liang, X. Chen, and Y. Zhan, “Medical image segmentation based on u-net: A review”, *Journal of Imaging Science and Technology*, vol. 64, no. 2, pp. 20508-1, 2020.
- [6]: M. Ambrosanio, S. Franceschini, V. Pascazio, and F. Baselice, “Microwave breast imaging via neural networks for almost real-time applications”, arXiv preprint arXiv:2103.12522, 2021.
- [7]: Y. Qin, T. Rodet, M. Lambert, and D. Lesselier, “Joint inversion of electromagnetic and acoustic data with edge-preserving regularization for breast imaging”, *IEEE Transactions on Computational Imaging*, vol. 7, pp. 349-360, 2021
- [8]: Y. Qin, T. Rodet, M. Lambert, and D. Lesselier, “Microwave breast imaging with prior ultrasound information”, *IEEE Open Journal of Antennas and Propagation*, vol. 1, pp. 472-482, 2020
- [9]: L. Li, K. Jamieson, G. DeSalvo, A. Rostamizadeh, and A. Talwalkar, “Hyperband: A novel bandit-based approach to hyperparameter optimization”, *The Journal of Machine Learning Research*, vol. 18, no. 1, pp. 6765-6816, 2017
- [10]: E. Zastrow, S. Davis, M. Lazebnik, F. Kelcz, B. Van Veen, and S. Hagness, “Database of 3D grid-based numerical breast phantoms for use in computational electromagnetics simulations”, tech. rep., Department of Electrical and Computer Engineering University of Wisconsin-Madison, 2008.
- [11]: K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition”, in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, (Las Vegas, United States), pp. 770-778, 2016
- [12]: Dossier Intelligence Artificielle, juin 2022, https://eduscol.education.fr/sti/si-ens-paris-saclay/ressources_pedagogiques/dossier-intelligence-artificielle