

## Faire progresser l'imagerie du sein grâce à la fusion de données et à l'apprentissage par transfert : une exploration complète

V. Noël<sup>1,2</sup>, T. Rodet<sup>2</sup>, D. Lesselier<sup>1</sup>

<sup>1</sup> : Université Paris-Saclay, CNRS, CentraleSupélec, Laboratoire des signaux et systèmes

<sup>2</sup> : Université Paris-Saclay, ENS Paris-Saclay, CNRS, Systèmes et Applications des Technologies de l'Information et de l'Energie

### Résumé

La convergence entre la physique et les réseaux neuronaux transforme profondément l'imagerie du sein. Nos travaux ont pour but de reconstruire de manière conjointe deux modalités afin d'augmenter la détection précoce des tumeurs du sein. Nous avons développé des algorithmes permettant reconstruire conjointement une image micro-onde, une image acoustique et une image de segmentation conjointe aux deux modalités. Les algorithmes que l'on propose utilisent l'apprentissage par transfert pour améliorer l'apprentissage de d'une modalité à partir de l'autre. Ceci améliore la classification des lésions mammaires en transférant des connaissances entre différentes physiques et modalités.

### 1. Introduction

En imagerie médicale, l'apprentissage à partir de réseaux de neurones a fait progresser beaucoup de problématiques et en particulier les problèmes de segmentation d'images. Le transfert learning des perspectives très intéressantes dans le cas où nous ne possédons pas assez de données une modalité.

Dans notre cas d'étude nous allons compléter l'information provenant de la tomographie micro-onde, qui a beaucoup de difficultés pour capter les hautes fréquences de l'image par une imagerie complémentaire : l'imagerie acoustique. Nous avons déjà développé un algorithme de reconstruction conjoint basé sur une inférence bayésienne [1]. Ici nous allons résoudre le même problème en utilisant des méthodes d'apprentissage basées sur les données. Le principe de notre approche consiste à avoir deux réseaux de neurones l'un pour résoudre le problème électromagnétique et l'autre pour résoudre le problème acoustique. Afin d'améliorer les performances de ces réseaux en particulier sur la modalité électromagnétique ou la collecte des données est plus difficile, nous avons développé un troisième réseau de neurones qui permet de connecter les deux espaces latents des précédents réseaux. Nous pouvons de cette manière faire un transfert d'apprentissage entre les deux modalités.

### 2. Description de la structure étudiée

Nous considérons dans notre étude que le sein est plongé dans un liquide ayant de bonnes propriétés de transmission des ondes acoustiques et électromagnétique afin de pouvoir faire les acquisitions simultanément. Le problème que l'on étudie est considéré comme bidimensionnel nous excitons le système par des ondes de compression pour la modalité acoustique et par des ondes en polarisation Transverse -Magnétiques pour la modalité électromagnétique. On stimule le système par des ondes harmoniques dans les deux modalités, ce qui nous conduit à résoudre les mêmes équations appliquées à deux modalités différentes. A l'aide de ces mesures nous pouvons remonter aux propriétés du sein en particulier à sa permittivité complexe relative pour les ondes magnétiques (permittivité et conductivité), et à la vitesse du son et son atténuation pour les ondes acoustiques. Les différents transducteurs permettant de faire ces mesures sont placés sur deux cercles concentriques placés autour de l'objet d'intérêt comme le décrit sur la figure 1 ci-dessous.




Figure 1 : Schéma de la configuration.

### 3. Description des Réseaux de Neurones étudiés

#### 3.a) Réseau de Neurones en Cascade

Dans un premier temps nous avons résolu le problème en utilisant des réseaux de neurones permettant de résoudre le problème conjoint. On suppose donc que l'on possède à la fois les données acoustiques et les données électromagnétique pour les phases d'apprentissage et de test de l'algorithme. Pour ce faire nous avons utilisé des réseaux de neurones de l'état de l'art comme le réseau Res-Net. Mais nous avons aussi développé des réseaux qui tiennent mieux compte de la physique des problèmes (CNN-MM) et des réseaux cascades qui permettent de mieux prendre le compte la morphologie commune aux deux modalités (SACC-CNN). Les différents résultats de ces approches sont résumés dans le tableau 1.

#### 3.b) Apprentissage par Transfert Bayésien (Fusion)

Notre seconde approche consiste à faire de l'apprentissage par transfert entre les deux modalités qui nous intéressent. Ici, nous avons deux réseaux dont les espaces latents sont connectés ensemble par un troisième réseau bayésien. Après une phase d'apprentissage ou l'on possède toutes les données pour entraîner les trois réseaux. On peut reconstruire les images acoustique et électromagnétique uniquement avec les données acoustiques grâce à l'apprentissage par transfert que nous avons mis en place. Cette approche améliore la qualité des résultats et établit un cadre précis et complet pour l'apprentissage par transfert de la fusion des données. Le cadre exploite la nature complémentaire des données électromagnétiques et ultrasonores, aboutissant à une analyse améliorée de l'imagerie mammaire via deux réseaux, nommés BBTL et BBFTL (Bayesian Bridge (Fusion) Transfer Learning).

### 4. Résultats

Les résultats d'intersection sur l'union (dite IoU) démontrent la supériorité des approches proposées dans les problèmes d'inversion de fusion de données et d'intégration de connaissances physiques par rapport aux réseaux de pointe. L'approche en cascade excelle en termes d'IoU pour différents types de tissus, illustrant sa robustesse (c.f. Tableau 1). Similairement, le RMSE de la prédiction des paramètres acoustiques et diélectriques est illustré dans le Tableau 2.

Network	Medium	Skin	Fat	Transition	Gland	Tumor	Average
Res-Net	0.9972	0.8361	0.8635	<b>0.4221</b>	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	<b>0.9989</b>	<b>0.8379</b>	<b>0.8660</b>	0.4219	<b>0.6798</b>	<b>0.7183</b>	<b>0.7545</b>

Network	$\epsilon'_r$	$\epsilon''_r$	$c$	$\alpha$
VGG-16	0.0805	0.0671	0.0371	0.0333
InceptionV3	<b>0.0602</b>	<b>0.0503</b>	<b>0.0278</b>	<b>0.0249</b>
AlexNet	0.0745	0.0621	0.0343	0.0308
EfficientNet	0.0671	0.0560	0.0309	0.0277
BBTL	0.0652	0.0544	-	-
BBFTL	<b>0.0544</b>	<b>0.0454</b>	<b>0.0251</b>	<b>0.0225</b>

Tableau 1 et 2 : IoU (gauche) et RMSE (droite) de différents réseaux de neurones sur le set de test

## 5. Conclusion

Ces méthodologies innovantes d'intégration de connaissances physiques dans les réseaux neuronaux produisent des résultats robustes en imagerie mammaire. Le réseau en cascade fusionne de manière robuste les sources de contraste et les quantités de champ, améliorant la sensibilité au cancer du sein. Les fonctions de perte ajustées de manière appropriée renforcent la résilience et l'interprétabilité du réseau.

## 6. Bibliographie

- [1] Qin, Y., *et al.*, "Fused microwave and ultrasonic breast imaging within the framework of a joint variational Bayesian approximation," *IEEE Trans. Antennas Propagat.*, Vol. 70, No. 12, 12199-12211, 2022.
- [2] Kononenko, I., "Bayesian neural networks," *Biol. Cybern.*, Vol. 61, No. 5, 361-370, 1989.
- [3] Noël, V., *et al.*, "Breast imaging by cascaded CNN from joint microwave and ultrasonic data," *IEEE EUSIPCO*, 917-921, 2022.