



**HAL**  
open science

## Conception de filtres RF en utilisant l'Intelligence Artificielle

Karabaghli Mouatez Bellah, Frigui Kamel, Moctar Mouhamadou, Bila Stephane, Baillargeat Dominique

► **To cite this version:**

Karabaghli Mouatez Bellah, Frigui Kamel, Moctar Mouhamadou, Bila Stephane, Baillargeat Dominique. Conception de filtres RF en utilisant l'Intelligence Artificielle. 22ème édition des Journées Nationales Microondes (JNM), Jun 2022, Limoges, France. hal-04548177

**HAL Id: hal-04548177**

**<https://hal.science/hal-04548177>**

Submitted on 16 Apr 2024

**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.

## Conception de filtres RF en utilisant l'Intelligence Artificielle

M.B Karabaghli<sup>1</sup>, K Frigui<sup>1,2</sup>, M Mouhamadou<sup>1,2</sup>, S Bila<sup>1</sup>, D Baillargeat<sup>1</sup>

<sup>1</sup> XLIM UMR CNRS 7252, 123 avenue Albert Thomas, 87060 Limoges

<sup>2</sup> Groupe 3IL, école d'ingénieur, 43 Rue de Sainte-Anne, 87000 Limoges  
karabaghli@xlim.fr

**Résumé** — Dans cet article, nous présentons une méthode d'optimisation de filtres RF en utilisant l'intelligence artificielle (IA). Cette approche permet de prédire les dimensions géométriques de filtres RF en utilisant les paramètres  $S$  comme données d'entrée. Une validation de cette méthode est détaillée en concevant un filtre quatre pôles en guide d'onde rectangulaire.

### 1. Introduction

Ces dernières années, le besoin d'algorithmes complexes et intelligents est devenu indispensable pour traiter de grandes quantités de données afin d'extraire des informations utiles à des fins de conception, d'amélioration et d'optimisation dans divers domaines tels que la santé, les transports et les systèmes de radiofréquence.

Les réseaux de neurones sont définis comme une méthode sophistiquée pour concevoir et optimiser avec une grande précision de nombreux dispositifs RF tels que des antennes [1], des filtres actifs/passifs [2] et des résonateurs [3]. Dans [2], une approche de réseau neuronal pour la conception de filtres RF actifs à  $Q$  élevé est présentée. Dans [3], les auteurs présentent un modèle de réseau de neurones artificiel (RNA) pour prédire les paramètres géométriques d'un filtre à partir des paramètres de conception du filtre d'entrée. L'article [3] s'applique à la première étape de conception, qui consiste à déterminer les paramètres géométriques du premier résonateur d'un filtre. Dans ce travail, une méthode d'optimisation basée sur l'apprentissage profond est proposée pour prédire les paramètres géométriques d'un filtre passif. Notre approche est basée sur les paramètres  $S$  comme entrée du modèle.

### 2. Méthodologies de conception par réseau de neurones

L'apprentissage automatique (de l'anglais Machine Learning : ML) est la clé de la révolution de la fabrication industrielle, les méthodes traditionnelles de conception et de modélisation des dispositifs nécessitent du temps et des expériences d'ingénierie avec de nombreuses étapes d'optimisation pour valider la conception préfabriquée. Dans notre cas, nous avons utilisé un modèle d'apprentissage profond (de l'anglais Deep Learning : DL) qui est un sous-système de ML et qui est efficace pour les structures complexes.

Dans ce travail, nous proposons un DL incluant un algorithme de réseaux de neurones pour prédire les paramètres géométriques d'un filtre RF passif. Sur la figure 1, nous montrons un exemple de structure de réseau de neurones pour la modélisation de filtre RF/micro-ondes. Les neurones d'entrée sont la réponse électrique du filtre. Les neurones de sortie sont les dimensions du filtre. Les neurones cachés reçoivent des stimuli des neurones d'entrée et produisent des sorties qui sont des stimuli pour les neurones de sortie. Des paramètres de poids associés aux interconnexions entre neurones sont entraînés à l'aide de données d'entraînement fournies de sorte que les sorties de modèle neuronal correspondent au mieux aux sorties de données d'entraînement. Les données d'apprentissage peuvent être des données de mesure ou des données de simulation basées sur l'EM. Dans cet article, nous avons utilisé uniquement des données de simulation basées sur l'EM. En tant que nouvelle approche de prédiction basée sur la méthode de régression d'apprentissage en profondeur, nous avons utilisé  $S_{21}$  des paramètres  $S$ .




Figure 1. Modèle d'apprentissage en profondeur proposé.

### 3. Conception de filtres RF par RNA

Les différentes étapes de conception du filtre RF utilisant RNA sont détaillées ci-dessous et résumées par l'organigramme de la Fig. 2.

#### 3.a. Calcul des dimensions initiales

L'objectif de cette étape est de déterminer les dimensions initiales de la structure RF en utilisant la simulation EM (étape A de l'organigramme). Cette étape comprend les sous-étapes suivantes.

- Simulation en mode propre d'un résonateur seul : pour calculer la longueur du résonateur à la fréquence centrale.
- Simulation forcée d'un résonateur avec un couplage à l'entrée : pour calculer la dimension du couplage d'entrée.

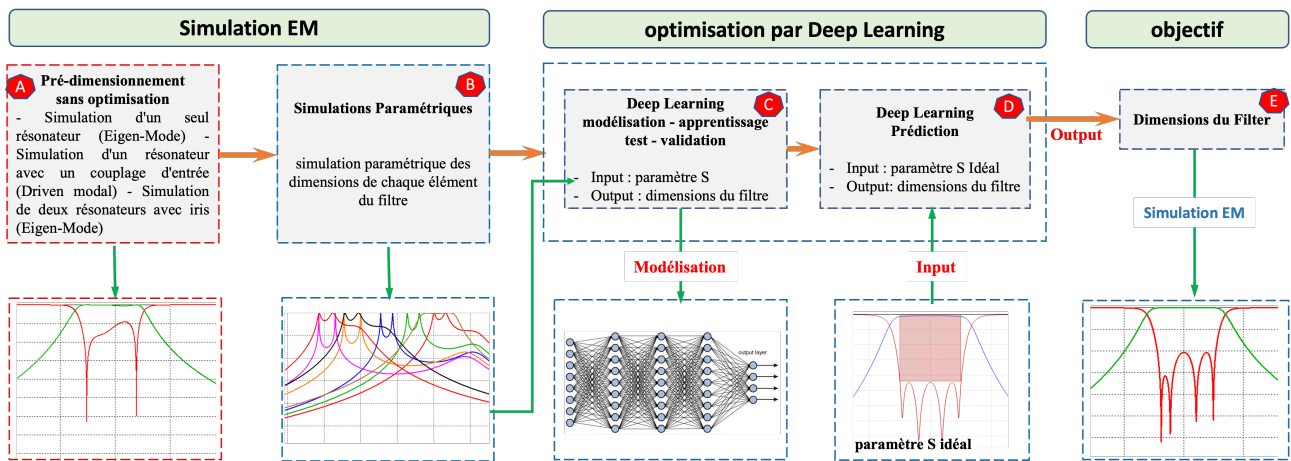


Figure 2. Organigramme de conception de filtres RF par réseau de neurones artificiel .

- Simulation en mode propre de deux résonateurs avec couplage inter-résonateurs : pour calculer le couplage inter-résonateurs.
- Simulation de la structure globale.

### 3.b. Simulation paramétrique

Pour créer une base de données de simulation basée sur l'EM, nous avons effectué des simulations paramétriques de chaque dimension géométrique du filtre (étape B de l'organigramme). Sachant que l'apprentissage profond nécessite la plupart du temps un gros volume de données, ce qui permet de disposer d'une grande puissance de traitement pour construire et exploiter un réseau de neurones.

### 3.c. Apprentissage profond : modélisation - apprentissage - tests

Après avoir généré la base de données, nous avons considéré un modèle d'apprentissage profond afin d'optimiser la réponse du filtre (étape C de l'organigramme). Le modèle est constitué d'une couche d'entrée avec un nombre de neurones égal à la taille du vecteur de  $S_{21}$ , le nombre de neurones de la couche de sortie est égal aux dimensions géométriques du filtre.

Afin d'optimiser le réseau de neurones et atteindre une erreur minimale, les performances des réseaux de neurones ont été testées avec un nombre différent de couches cachées et de neurones cachés. Pour chaque étape, un nombre particulier de neurones cachés a été trouvé pour donner la meilleure performance globale.

Les entrées et les sorties du modèle sont respectivement les données des paramètres  $S$  et les dimensions géométriques du filtre. Les données d'entrée sont divisées en trois ensembles comme suit 80% pour entraîner le modèle, 10% pour tester et 10% pour valider après chaque époque. Ces données sont mises à l'échelle par Standard Scaler [4], la fonction d'activation utilisée pour un objectif rapide et non linéaire est la fonction ReLU [5]. L'optimiseur d'apprentissage en profondeur utilisé dans l'étape d'entraînement est Adam [6] avec  $\beta_1 = 0,9$ ,  $\beta_2 = 0,999$ ,  $\epsilon = 10^{-7}$  et un taux d'apprentissage  $\eta = 0.001$  comme dans [7]. Après optimisation des différents paramètres du modèle, nous obtenons ces résultats : le nombre d'époques

utilisées pour l'apprentissage est de 200 (tableau 1) et 100 neurones pour chaque couche cachée (tableau 2). La taille du lot est fixée à 64 et nous avons utilisé la bibliothèque Tensorflow [6] pour développer le modèle DL. Avec ces paramètres, le modèle a appris plus rapidement, avec une grande précision et sans sur-apprentissage.

Epochs	100	200	300	400	500
MSE	0.039	<b>0.0024</b>	0.0024	0.0024	0.0024

Tableau 1. Erreur quadratique moyenne (MSE) par rapport au nombre d'époques .

Neurones	50	100	200	300	400	500
MSE	0.272	<b>0.002</b>	0.068	0.012	0.022	0.003

Tableau 2. Erreur quadratique moyenne (MSE) par rapport au nombre de neurones

### 3.d. Prédiction des dimensions géométrique du filtre

Après l'étape de modélisation et d'apprentissage profond, nous avons utilisé le même modèle pour prédire les dimensions du filtre (étape D de l'organigramme). L'entrée du modèle Deep Learning est la réponse électrique idéale souhaitée, les sorties sont les dimensions (longueurs des résonateurs, les couplages d'entrée/sortie et inter-résonateurs).


### 3.e. Simulation EM

Dans la dernière étape (E de l'organigramme), on simule la structure globale du filtre avec les dimensions obtenues par le modèle de l'apprentissage profond (à l'étape D) et on compare les résultats obtenus avec la réponse idéale.

## 4. RÉSULTATS


Pour valider notre approche, nous avons considéré un filtre guide d'ondes rectangulaire à quatre pôles de fréquence centrale  $f_0 = 10GHz$  et de bande passante

$BW = 100MHz$ . Le filtre et sa réponse électrique idéale sont illustrés à la Fig. 3.



**Figure 3. Filtre quatre pôles en guide d'onde rectangulaire et sa réponse électrique idéale .**

Comme détaillé dans le paragraphe précédent, la procédure de conception RF comprend les étapes suivantes (1) simulation en mode propre d'un résonateur seul, (2) simulation forcée d'un résonateur avec un couplage à l'entrée, (3) simulation en mode propre de deux résonateurs avec couplage inter-résonateurs, (4) simulation de la structure globale. En suivant ces étapes (1) - (4), nous obtenons la réponse électrique illustrée à la Fig.4 (A). Comme nous pouvons l'observer pour les dimensions initiales, la réponse électrique n'est pas optimisée. L'objectif est d'utiliser le modèle d'apprentissage profond pour obtenir les bonnes dimensions du filtre permettant d'atteindre la réponse électrique idéale.




**Figure 4. Réponse électrique du filtre, avant l'optimisation par l'IA (A) et optimisée par l'IA (B)**

Nous avons créé une base de données à l'aide des simulations paramétriques sur les différentes dimensions géométriques du filtre (étape B), puis nous avons travaillé sur la modélisation du deep learning (étape C) en cherchant une meilleure prédiction avec une erreur minimale. Après l'étape d'apprentissage de ce réseau, nous avons injecté dans son entrée les paramètres S idéaux (étape D). L'apprentissage profond prédit les dimensions du filtre (sortie de l'Intelligence Artificielle IA) pour atteindre la réponse électrique idéale. Avec ces dimensions nous avons fait une simulation EM du filtre (étape E), la réponse obtenue est présentée sur la Fig. 4 (B). On peut observer que la réponse est très satisfaisante.

Avec cette approche, nous avons validé que l'IA peut prédire les dimensions du filtre pour atteindre une réponse objective. Pour étudier la précision et la limite de prédiction de cette méthode basée sur l'IA, nous avons considéré six autres filtres identiques au premier (Fig. 3) de  $BW = 100MHz$ , mais avec des fréquences centrales différentes (nous avons considéré des fréquences centrales à partir de  $9.7GHz$  à  $10.3GHz$  avec un pas de  $100MHz$ ). Pour déterminer les dimensions optimales de ces filtres,


nous avons utilisé la même base de données que pour le filtre centré à  $10GHz$  (Fig. 3). c'est-à-dire que nous n'avons pas fait de nouvelles simulations paramétriques et que nous n'avons pas modifié l'étape d'apprentissage de l'IA. Nous avons directement utilisé l'étape (D) : pour chaque filtre nous avons injecté à l'entrée de l'IA la réponse idéale souhaitée. L'apprentissage profond prédit les dimensions des filtres (sortie de l'IA) pour atteindre les réponses électriques idéales. Ensuite, des simulations EM sont effectuées en utilisant les dimensions prédites par l'IA (étape E). Nous montrons sur la Fig. 5 les résultats obtenus pour les six filtres. On peut observer que pour les fréquences centrales  $9.8, 9.9, 10.1$  et  $10.2GHz$  (Fig. 5 (a)-(d)) l'IA a permis de bien prédire les dimensions des filtres et les résultats pour ces quatre filtres sont très satisfaisantes. Pour les filtres censés être centrés à  $9.7GHz$  et  $10.3GHz$  (réponses idéales), on obtient des réponses moins satisfaisantes que les quatre autres filtres : ces deux réponses ne sont pas bien adaptées et elles sont décalées en fréquences ((Fig. 5 (e)-(f)). Cette limite de prédiction de l'IA s'explique par le fait que l'étude paramétrique a été faite sur la bande  $[9.75 - 10.25](GHz)$  donc les filtres (e) et (f) sont en dehors de la bande d'entraînement, ce qui nous a donné une réponse non optimisée.



**Figure 5. Réponse électrique des filtres optimisée par AI, avec des fréquences centrales :  $f_{01} = 9.9GHz$  (a),  $f_{02} = 10.1GHz$  (b),  $f_{03} = 9.8GHz$  (c),  $f_{04} = 10.2GHz$  (d),  $f_{05} = 9.7GHz$  (e),  $f_{06} = 10.3GHz$  (f),**

Pour avoir une idée de la précision des dimensions prédites par l'IA, nous avons optimisé les six filtres avec la méthode classique : optimisation par simulation EM et à l'aide des matrices de couplage. Nous avons comparé ces dimensions ( $Dim_{EM}$ ) avec celles obtenues par l'IA ( $Dim_{AI}$ ). Sur la Fig. 6, nous présentons l'Erreur Relative Moyenne (MRE) pour chaque filtre de la Fig. 5. Nous pouvons observer un bon accord entre les dimensions ( $Dim_{EM}$  et  $Dim_{AI}$ ) dans la bande  $[9.8 - 10.15]GHz$  où

le  $MRE < 0.5\%$ .



**Figure 6. Erreur relative moyenne (%) pour chaque filtre (de 9,7 à 10,3 GHz) .**

## 5. Conclusion

Dans ce travail, une méthode d'apprentissage profond proposée pour optimiser la conception de filtres RF. Cette méthode est basée sur  $S_{21}$  comme données d'entrée pour prédire les dimensions géométriques du filtre conçu avec une grande précision. Enfin, cette approche est validée par la conception d'un filtre quatre pôles en guide d'onde rectangulaire en utilisant l'intelligence artificielle. Le filtre peut être optimisé avec diverses fréquences centrales ou bandes passantes dans l'espace de conception.

## Références

- [1] H. M. E. Misilmani *et al.*, "A review on the design and optimization of antennas using machine learning algorithms and techniques," presented at the International Journal of RF and Microwave Computer-Aided Engineering., 2020.
- [2] A. L. L. Pantoli and Z. Marinković, "An approach for ai-based filter design by means of neural networks," presented at the 13th International Conference on Advanced Technologies, Systems and Services in Telecommunications (TELSIKS)., 2017.
- [3] A. R. Chapala and T. Ogunleye, "Artificial neural network for the first filter design stage using the reflected group delay method," presented at the 19th International Symposium on Antenna Technology and Applied Electromagnetics (ANTEM)., 2021.
- [4] D. Cournapeau. Scikit-learn. [Online]. Available : <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>
- [5] D. AI. Rectified linear units. [Online]. Available : <https://deepai.org/machine-learning-glossary-and-terms/rectified-linear-units>
- [6] G. Brain. (2015) Tensorflow. [Online]. Available : <https://www.tensorflow.org/?h=fr>
- [7] J. B. Diederik P. Kingma. (2014) Adam : A method for stochastic optimization. [Online]. Available : <https://arxiv.org/abs/1412.6980>