



HAL
open science

Algorithmes d'apprentissage pour l'analyse de dispositifs radiofréquences dans un flot de conception

Mervyn Guillou, Benjamin Potelon, Cédric Quendo, Jean-Philippe Coupez,
Christian Person, Julien Haumant

► To cite this version:

Mervyn Guillou, Benjamin Potelon, Cédric Quendo, Jean-Philippe Coupez, Christian Person, et al.. Algorithmes d'apprentissage pour l'analyse de dispositifs radiofréquences dans un flot de conception. XXIIIèmes Journées Nationales Microondes, Jun 2024, Antibes (06), France. hal-04588482

HAL Id: hal-04588482

<https://hal.science/hal-04588482v1>

Submitted on 27 May 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.

Algorithmes d'apprentissage pour l'analyse de dispositifs radiofréquences dans un flot de conception

M. Guillou^{1,3}, B. Potelon¹, C. Quendo², J-P. Coupez¹, C. Person¹, J. Haumant³

¹ IMT Atlantique, Lab-STICC, UMR CNRS 6285, F-29238 Brest, France

² Univ. Brest, CNRS, Lab-STICC, UMR CNRS 6285, F-29238 Brest, France

³ Elliptika, GTID, F-29200 Brest, France

Résumé – Nous présentons l'utilisation de techniques d'apprentissage automatique permettant de procéder à l'automatisation d'un flot de conception de dispositifs radiofréquences. L'objectif visé par ces travaux est, à partir d'une réponse électrique donnée, et en connaissant le type de topologie (forme géométrique générique connue), d'obtenir les paramètres dimensionnels de la structure. Pour ce faire, nous proposons l'utilisation de réseaux de neurones. La nouveauté proposée dans cet article repose sur l'introduction d'indicateurs « métier » (au sens électromagnétique) extraits de la réponse électrique permettant de la décrire synthétiquement et permettant ainsi l'alimentation du réseau de neurones. Un exemple pour un filtre d'ordre 2 est décrit et analysé, puis l'extraction de paramètres dimensionnels à partir de réponses électriques mesurées est réalisée.

1. Introduction

L'apparition récente de technologies de fabrication additive a rendu possible la réalisation de formes complexes ouvrant ainsi la voie à de nombreuses expérimentations dans le domaine de l'électronique radiofréquence. Ces nouveaux procédés de fabrication (SLA, FDM, DLP, DLS...), grâce aux possibilités de réalisation rapide et à moindres coûts qu'elles permettent, ont rapidement attiré l'attention d'industriels désireux de réaliser facilement des prototypes ou des petites séries. Cependant, en raison des caractéristiques propres listées ci-avant (faible coût, rapidité de réalisation...), ces procédés sont bien souvent sujets à des dispersions dimensionnelles (retraits, déformations...), ce qui, dans le domaine des radiofréquences, se traduit inévitablement par des dérives des réponses électriques, impactant les performances fonctionnelles des pièces fabriquées. Aussi, il est indispensable de pouvoir suivre la qualité des pièces réalisées et d'identifier les défauts des pièces non conformes afin de pouvoir les corriger. Cette opération peut être réalisée par métrologie dimensionnelle fine mais ceci implique bien souvent des contrôles destructifs. Une autre solution consiste à utiliser les réponses électriques pour identifier les dispersions dimensionnelles.

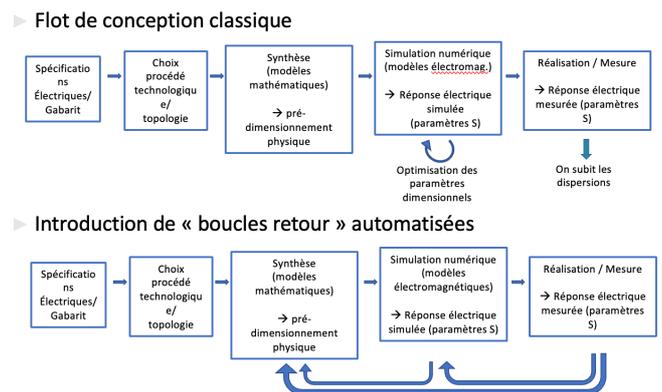


Figure 1. Introduction de boucles retour basées sur l'apprentissage dans le processus de conception/réalisation

Cette solution nécessite néanmoins de résoudre le « problème inverse », c'est-à-dire de pouvoir remonter, à partir d'une réponse électrique donnée, et en connaissant la topologie du dispositif visé, aux dimensions correspondantes. C'est cet aspect que nous adressons ici.

La résolution de problèmes inverses peut être abordée de différentes façons, le choix étant assez dépendant du cas d'usage et de la connaissance (existence de théories, modèles analytiques ou physiques, ...) du problème direct. Nous nous sommes tournés vers l'utilisation de réseaux de neurones, notamment en raison de leur versatilité et parce que de telles solutions ne nécessitent pas de modélisation du problème direct. Nous proposons donc l'utilisation d'un réseau de neurones pour apprendre à analyser la réponse d'un dispositif radiofréquence et en extraire les paramètres dimensionnels. Sur la base de cette phase d'apprentissage, l'idée est d'insérer dans les flots de conception/réalisation des boucles de retour automatisées permettant ainsi de converger vers une conception anticipant les artefacts technologiques. Une synthèse de cet objectif est présentée en Figure 1.

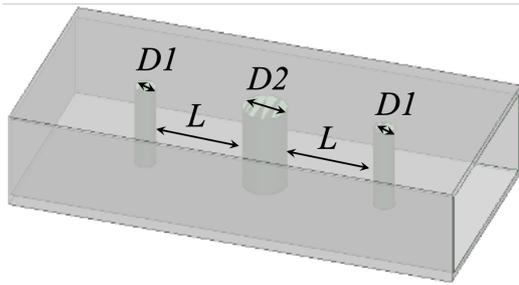


Figure 2. Vue en 3D du filtre considéré

2. Présentation du problème et création d'une base de données

Afin de démontrer la pertinence du choix d'un réseau de neurones, nous nous sommes intéressés à un cas simple de dispositif radiofréquence : un filtre passe-bande d'ordre deux. La topologie retenue est un filtre volumique en guide d'ondes métallique avec des cavités délimitées par des posts (piliers) métalliques verticaux [1]. Le diamètre et le positionnement de ces posts, réalisés sous forme de vias traversants de diamètres contrôlés, permettent d'ajuster la fréquence de fonctionnement des cavités et la bande passante relative présentée par ce dispositif. Le filtre sélectionné est destiné à fonctionner en bande X, autour de 10 GHz (Figure 2). Le filtre sera réalisé en fabrication additive plastique métallisée selon le procédé de réalisation disponible au sein de l'entreprise Elliptika™/groupe GTID™ [2]. Une fois le choix de la topologie effectuée, il s'agit d'obtenir une base de données sur laquelle le réseau de neurones va pouvoir être entraîné, c'est-à-dire construire un méta-modèle paramétré représentatif du comportement de cette structure. En d'autres termes, l'algorithme va utiliser une base de données pour évaluer et modéliser la sensibilité de la réponse électrique aux différents paramètres dimensionnels. Ces paramètres dimensionnels peuvent être multiples et la taille de la base de données est étroitement corrélée au choix de ces derniers. En effet, la base de données d'entraînement est constituée d'un ensemble de points, chacun d'entre eux représentant un jeu de valeurs des paramètres dimensionnels associés aux éléments constituant la réponse électrique de la structure, *i.e.* les paramètres [S] pour un filtre. La constitution et la complétude de la base de données d'entraînement est un des sujets de recherche pour la communauté scientifique travaillant sur les problématiques d'intelligence artificielle [3]. Dans notre cas, une difficulté supplémentaire réside l'obtention de multiples réponses électriques de filtres présentant des dimensions connues a priori, mais surtout multiples variées selon un espace de dimensions donné. En effet, ceci impliquerait de réaliser de nombreux dispositifs avec des dimensions variées, de les mesurer électriquement puis de les caractériser dimensionnellement avec précision, ce qui signifie faire appel à des moyens coûteux (tomographie à rayons X par exemple) et/ou à des moyens destructifs. En outre, constituer une telle base serait extrêmement long et soumis aux aléas liés aux dispersions de fabrication.

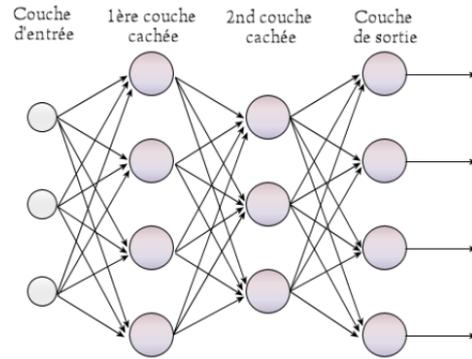


Figure 3. Réseau de neurones artificiel multicouches [1].

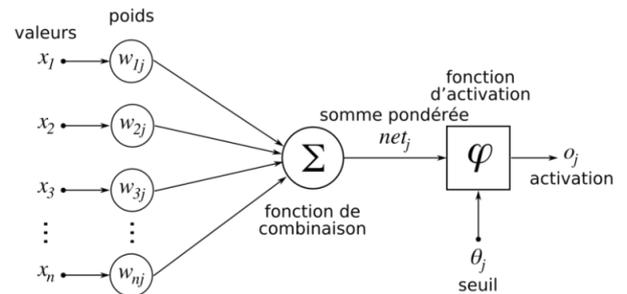


Figure 4. Fonctionnement d'un neurone (perceptron)

Aussi, pour nous affranchir de ces problématiques, nous avons fait le choix de constituer une base de données reposant sur des simulations électromagnétiques. En plus de pallier les problèmes listés ci-avant, un tel choix nous permet de choisir les paramètres variables et de des paramètres figés suivant leur niveau de sensibilités dans la réponse globale du dispositif. Ainsi, nous avons choisi trois paramètres : $D1$, le diamètre du premier post métallique (et également du dernier post puisque la structure est symétrique), $D2$, le diamètre du post central et L , la distance entre les posts extérieurs et le post central. Pour chaque dimension, les plages de variation ont été fixées (entre 0,8 et 6,92 mm pour $D1$ et $D2$ et entre 18,225 et 22,275 mm pour L) et divisées en neuf intervalles également répartis sur ces plages (soit dix points linéairement répartis). Ceci constitue une base d'apprentissage avec un nombre certes faible mais déjà important de couple de données (1000). Pour chaque triplet de valeurs dimensionnelles, la structure a été simulée électromagnétiquement et le couple (3 valeurs dimensionnelles/réponse électromagnétique) représentant un point de donnée ajouté à la base. La base de données consiste donc en un ensemble de 1000 simulations électromagnétiques, chacune étant associée au triplet de dimensions correspondantes. Une fois cette base de données créée, il s'agit de l'utiliser pour permettre au réseau de neurones de réaliser l'apprentissage permettant d'obtenir un méta-modèle représentant le comportement de notre structure vis-à-vis des variations de $D1$, $D2$ et L .

3. Entraînement du réseau de neurones

3.a. Présentation générique d'un réseau de neurones et de son entraînement

Un réseau de neurones informatique est un système biomimétique comportant une multitude d'agents automatiques interconnectés et organisés en couches. Chaque agent, aussi appelé perceptron, applique une fonction de transfert aux données qui lui sont fournies en entrée (issues de la couche précédente ou en entrée pour la première couche) et fournit un résultat qui est lui-même proposé en entrée de tous les perceptrons constituant la couche suivante (Figure 3) [3]-[5].

La fonction de transfert réalisée par un perceptron est généralement constituée de deux opérations consécutives (Figure 4), d'abord une somme pondérée (par les poids/weights) de l'ensemble des sorties des perceptrons de la couche précédente (ou des données d'entrée) et ensuite d'une valeur additionnelle (le biais, non représenté sur la Figure 4). Le résultat de cette somme est ensuite utilisé comme argument d'une fonction d'activation. Cette dernière, souvent non-linéaire, peut prendre différentes formes et représente l'équivalent du potentiel d'activation d'un neurone biologique. Les *weights* et *bias* ont des valeurs propres à chaque perceptron alors que la fonction d'activation est généralement identique pour tous les neurones d'un même réseau.

Le nombre de couches, le nombre de neurones par couche, le type de fonction d'activation sont des hyperparamètres laissés au choix du concepteur.

Le réseau ainsi obtenu constitue une structure quasi-générique qui, en raison de sa grande plasticité, a la capacité de modéliser le comportement d'une multitude de dispositifs. Afin de le spécialiser pour qu'il modélise le comportement du dispositif choisi, il faut procéder à son entraînement, ce qui consiste en l'optimisation de la valeur des *weights* et du *bias* de chacun des perceptrons.

Cette opération d'apprentissage est réalisée par une suite d'itérations, chacune d'entre elle consistant en la suite d'opérations suivantes :

- Passage des données de la base d'apprentissage dans le réseau
- Calcul des paramètres (dimensions) de sortie du réseau
- Calcul d'une fonction de coût à partir de la différence (paramètres attendus - paramètres calculés)
- Correction des *weights* et *bias* du réseau
- Re-bouclage jusqu'à obtenir (idéalement) un coût nul

Cette étape permet ainsi d'obtenir un réseau modélisant le comportement du dispositif ayant alimenté la base de données.

3.b. Application au filtre d'ordre 2 et à la base de données générée

Dans notre cas, l'objectif est de fournir en entrée de notre réseau les éléments liés à la réponse électrique simulée et d'obtenir en sortie une estimation des dimensions correspondantes du dispositif.

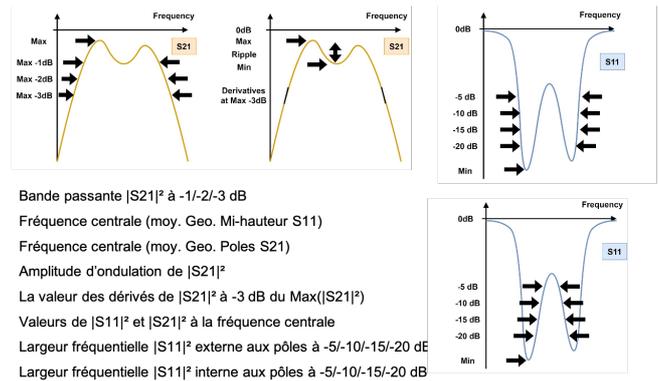


Figure 5. Liste des indicateurs retenus pour décrire la réponse électrique d'un filtre

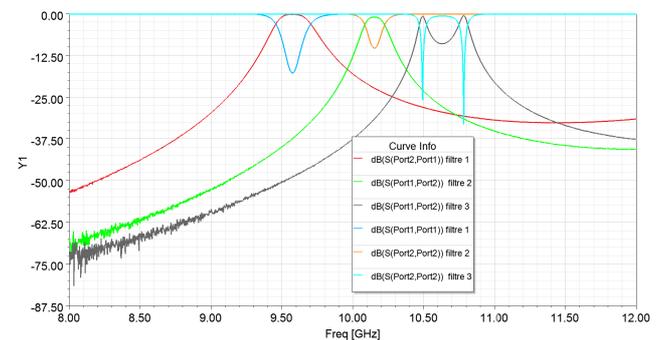


Figure 6. Réponses électriques mesurées (paramètres S) des trois filtres réalisés

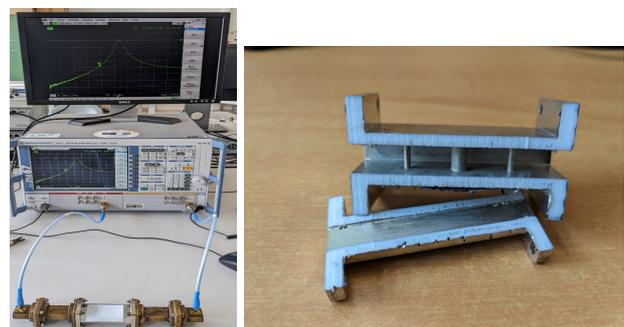


Figure 7. Mesure électrique (gauche) et dimensionnelle (droite) d'un dispositif réalisé

Pour se faire, le réseau a été configuré avec 5 couches cachées (soit 7 couches au total), 23 neurones par couche, et une fonction d'activation de type ReLu (Rectified Linear Unit). Les simulations constituant la base de données initiale contiennent 2001 points de fréquence situés entre 8 et 12 GHz. Ces 2001 points de fréquence pour chaque élément de la base de données pourraient être utilisés comme vecteur d'entrée de la couche d'entrée. Cependant, cette solution s'avère ne pas être optimale et mène à la non convergence de l'apprentissage en raison de la dilution des informations importantes du point de vue électrique (fréquence centrale, bande passante relative, adaptation, réjections...) sur l'ensemble de ces 2001 points de fréquences. Il s'agit ici de l'étape critique de l'apprentissage suivant les règles « métier ». Aussi, pour pallier ce problème et permettre un apprentissage rapide et efficace sur notre base de données, qui peut être considérée comme peu riche vis-à-vis de l'entropie

		D1	D2	L1
Filtre 1	Mesure	1,78	4,88	21,00
	Prédiction	1,69	4,96	21,01
	différence relative (%)	5,056	-1,639	0,000
Filtre 2	Mesure	2,62	6,38	20,47
	Prédiction	2,48	6,60	20,43
	différence relative (%)	5,344	-3,529	0,195
Filtre 3	Mesure	3,89	4,87	18,98
	Prédiction	3,93	4,94	19,04
	différence relative (%)	1,028	1,437	0,316

Table 1. Dimensions mesurées et prédites pour les trois filtres réalisés

intrinsic à chaque point, nous proposons une approche différente. En effet les paramètres [S] sur 2001 points fréquentiels comportent une multitude d'informations entremêlées, qui sont interprétables assez facilement par les experts du domaine, mais sont difficilement exploitables par des process automatisés. Aussi, nous proposons de pré-interpréter les réponses électriques obtenues en extrayant des indicateurs calculables à partir des paramètres [S] et électriquement porteurs de sens. La définition et le choix des indicateurs est une opération cruciale puisqu'ils doivent permettre une fine transcription du fonctionnement et des performances du dispositif radiofréquence considéré tout en étant suffisamment robustes vis-à-vis de possibles imperfections de fonctionnement (désadaptation, décalage en fréquence...). Par ailleurs, la généricité des indicateurs choisis par rapport à la topologie et à la fonction considérée est également un aspect important qu'il convient d'intégrer dans la sélection. Dans le cas précis que nous avons choisi, c'est-à-dire un filtre volumique d'ordre deux en bande X, les indicateurs que nous avons sélectionnés sont présentés à la figure 5. Les indicateurs pour chacune des simulations composant la base de données ont été extraits.

L'étape suivante concerne l'entraînement du réseau, cette étape étant réalisée en utilisant 75% des données de la base, les 25% restants étant réservés à l'évaluation de la qualité du modèle produit, cette répartition étant celle habituellement appliquée dans l'entraînement de réseaux de neurones. Ces conditions d'entraînement, le choix des hyperparamètres et le paramétrage de l'optimiseur permettent d'accéder à de bonnes convergences, c'est-à-dire l'obtention rapide d'un modèle qui apparait comme satisfaisant du point de vue de l'optimiseur choisi (ADAM). Ceci signifie que nous disposons maintenant d'un modèle a priori représentatif du comportement des dimensions des dispositifs lorsque les réponses électriques simulées changent. Ceci constitue une sortie intéressante, mais il convient néanmoins d'évaluer la validité de ce modèle sur des mesures réalisées sur des dispositifs réels et de pouvoir comparer les dimensions prédites aux dimensions mesurées. Pour ce faire, nous avons choisi de tester la robustesse et la précision du modèle obtenu sur trois filtres.

4. Résultats et discussion

Pour avoir des résultats les plus représentatifs possibles, les filtres réalisés présentent des fréquences centrales, des couplages inter-résonateurs et des niveaux d'adaptation variés. Les mesures des trois filtres réalisés

sont présentées sur la Figure 6. Les indicateurs listés en Figure 5 ont ensuite été extraits de ces réponses électriques mesurées et introduits dans le réseau de neurones préalablement entraîné, tel que présenté ci-avant. Les dispositifs réalisés ont ensuite été caractérisés dimensionnellement (Figure 7) et ces valeurs ont été comparées aux dimensions prédites par le réseau de neurones. Une synthèse des résultats est présentée en Table 1. Sur l'ensemble des trois dispositifs, la différence relative entre les dimensions mesurées et celles prédites est inférieure à 6%, pour des filtres relativement divers en termes de réponse électrique. Ceci semble valider la méthodologie adoptée et la pertinence des indicateurs sélectionnés. En outre, l'entraînement sur une base issue de simulations puis l'utilisation du modèle créé sur des réponses mesurées ne semble pas poser de problème, malgré des dispersions sur des dimensions dont les variations n'ont pas été intégrées au modèle. Ainsi, par exemple, les dimensions de la section transversale mesurées sur les dispositifs réalisés font apparaître des dispersions de l'ordre de 0,5% de la valeur nominale.

5. Conclusion

Dans cet article, nous avons présenté le développement d'un modèle basé sur un réseau de neurones, lequel permet de modéliser le comportement d'un filtre d'ordre 2 et d'extraire, à partir de la réponse électrique, les paramètres dimensionnels correspondants. L'originalité proposée se base sur l'extraction d'indicateurs des réponses électriques, qui sont introduits en entrée du réseau de neurones. Cette méthode repose sur une analyse préalable des données « métier », permettant de sélectionner les indicateurs porteurs d'information et ainsi d'aider l'algorithme d'intelligence artificielle à interpréter les réponses électriques.

La principale limitation liée à cette méthode réside dans la constitution de la base de données, relativement longue et consommatrice de ressources en raison du nombre élevé de simulations. Ainsi, si seules trois variations dimensionnelles ont été intégrées dans cet exemple pour des raisons de temps de simulation, les perspectives envisagées sont d'étendre une telle méthode à des ordres de filtres plus élevés, à des topologies plus complexes et subséquentement à un nombre plus élevé de paramètres dimensionnels.

Références

- [1] G. Matthaei & al. « *Microwave filters, impedance-matching networks, and coupling structures* ». Artech House, 1985
- [2] <https://elliptika.com>
- [3] P.A. Flach « *Machine learning: the art and science of algorithms that make sense of data* » Cambridge University Press, 2017
- [4] https://fr.wikipedia.org/wiki/Perceptron_multicouche
- [5] F. Feng, W. Na, J. Jin, J. Zhang, W. Zhang, et Q.-J. Zhang « *Artificial Neural Networks for Microwave Computer-Aided Design: The State of the Art* » IEEE Trans. Microw. Theory Tech., vol. 70, no 11, p. 4597-4619, nov. 2022.