



HAL
open science

Modélisation de cellules de réseaux réflecteurs par réseaux de neurones artificiels

V Richard, Renaud Loison, R. Gillard, H. Legay, M. Romier

► **To cite this version:**

V Richard, Renaud Loison, R. Gillard, H. Legay, M. Romier. Modélisation de cellules de réseaux réflecteurs par réseaux de neurones artificiels. JNM2017, May 2017, Saint Malo, France. hal-01723718

HAL Id: hal-01723718

<https://hal.science/hal-01723718>

Submitted on 5 Mar 2018

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.

Modélisation de cellules de réseaux réflecteurs par réseaux de neurones artificiels

V. Richard¹, R. Loison¹, R. Gillard¹, H. Legay², M. Romier³

¹Institut d'Electronique et de Télécommunications de Rennes, INSA, 20 avenue des Buttes de Coësmes, 35708 Rennes

²Thales Alenia Space, 26 Avenue Jean François Champollion, BP1187, 31037 Toulouse Cedex

³Centre National d'Etudes Spatiales, 18 Avenue Edouard Belin, 31400 Toulouse

Vincent.richard@insa-rennes.fr

Résumé – Cette communication propose une méthodologie pour l'optimisation de réseaux de neurones artificiels (ANN) pour la modélisation de cellules de réseaux réflecteurs. Elle est appliquée à deux types de cellules Phoenix, capacitive et inductive, définies par cinq entrées. Les résultats démontrent que les modèles finaux sont fiables et précis pour la modélisation de la phase et de l'amplitude sur les paramètres directs et croisés de la matrice de réflexion.

1. Introduction

Les antennes à réseau réflecteur (reflectarray), dont le schéma de principe est rappelé figure 1, constituent une solution innovante notamment pour les antennes spatiales [1-3]. Elles combinent les atouts des antennes réseaux pour la réalisation de diagrammes directifs ou formés et ceux des antennes réflecteurs n'utilisant qu'une seule source primaire. Une antenne reflectarray est composée d'une source primaire placée devant un réseau de cellules contrôlant les propriétés du champ réfléchi. Il est ainsi possible d'agir simplement sur le rayonnement de l'antenne en contrôlant les propriétés électromagnétiques (EM) des cellules disposées sur le panneau. Les reflectarrays passifs - dont les coût, masse et encombrement sont faibles - seraient donc en mesure de remplacer à terme les réflecteurs formés utilisés aujourd'hui.




Figure 1. Principe d'une antenne à réseau réflecteur

L'une des problématiques majeures rencontrées dans la conception de telles antennes est de choisir la géométrie des nombreuses cellules juxtaposées pour contrôler les propriétés locales de réflexion et ainsi réaliser un diagramme de rayonnement souhaité. Les outils de simulation rigoureuse utilisés sont en effet très coûteux en termes de temps de calcul. C'est pourquoi il est nécessaire d'utiliser des modèles rapides donnant

accès aux propriétés EM des cellules, particulièrement pour la synthèse finale.

Plusieurs modèles comportementaux basés sur l'utilisation des réseaux de neurones artificiels (ANN) ont déjà été proposés pour réduire ces temps de calcul [4, 5]. Ces systèmes ne modélisent cependant que la phase et les erreurs observées dans les zones de résonance sont fortes. L'algorithme proposé dans cette étude consiste à optimiser la complexité des différents ANN pour avoir la meilleure prédiction. Cette communication s'articule autour de deux parties distinctes. La cellule d'étude et l'algorithme de conception des ANN seront d'abord présentés, les performances seront ensuite détaillées.

2. Structure des ANN et algorithme de conception

2.a. Cellules étudiées

La figure 2 présente les deux configurations de la cellule étudiée. Ces structures capacitive (a) et inductive (b) sont issues du principe général de la cellule Phoenix [6], dont les propriétés EM sont intéressantes du fait de leur métallisation monocouche, de l'accessibilité à l'ensemble des plages de phases (-180° jusqu'à 180°) et de la possibilité d'utilisation en large bande. Plus précisément, les cas capacitif et inductif ont respectivement des géométries de type anneau métallique et fente annulaire. Le substrat est caractérisé par une permittivité de $\epsilon_r = 1,03 - j3,09 \cdot 10^{-3}$ et d'une hauteur $h=20,9\text{mm}$. Aussi, dans un objectif de conception de modèle comportemental, on propose de caractériser chaque cellule par cinq entrées : deux pour la géométrie de cellule où C_1 et C_2 varient de 0mm à la taille de maille ($l=25,6\text{mm}$), deux pour l'angle d'excitation (θ et φ varient respectivement de 0° à 40° et de -180° à -135° du fait des symétries) et une pour la fréquence de fonctionnement (de 3,4 GHz à 4,2GHz). Les sorties souhaitées sont les paramètres de phase et d'amplitude des quatre coefficients de la matrice de réflexion (1) pour les polarisations directes et croisées. Classiquement, cette matrice permet de relier l'onde réfléchie à l'onde incidente, dans l'hypothèse de l'excitation par onde plane d'un réseau périodique infini de cellules identiques.

$$R = \begin{bmatrix} R_{11} & R_{12} \\ R_{21} & R_{22} \end{bmatrix} \quad (1)$$




Figure 2. Structures des cellules étudiées
(a) capacitive
(b) inductive

2.b. Optimisation et algorithme de conception

Les ANN sont utilisés pour la modélisation de systèmes non linéaires où le principe est d'apprendre par l'exemple. Cela signifie qu'à partir d'un jeu de paramètres entrées / sorties connu, défini comme une base d'apprentissage, le modèle neuronal est construit afin d'être en mesure de fournir la réponse approximée de tout autre jeu d'entrées [7]. Cette partie montre comment obtenir la structure finale des ANN pour la modélisation de la cellule Phoenix dans les cas capacitif et inductif.

La figure 3 présente un exemple de structure typique de modèle neuronal de type Multi Layer Perceptron (MLP) [8]. Il est constitué de couches cachées dont le nombre de neurones par couche est donné par N_i .

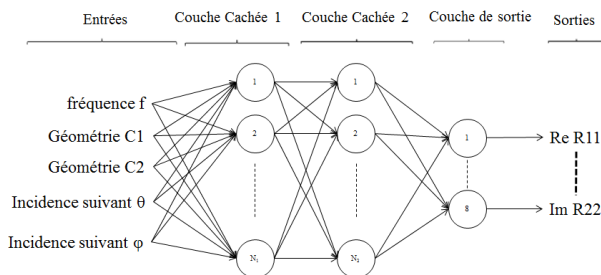


Figure 3. Structure d'ANN de type MLP

La méthode d'optimisation du réseau de la figure 3 s'inspire de [9], où le principe est d'optimiser la complexité du réseau (nombre de neurones dans les couches cachées) pour obtenir les meilleures performances en termes de prédiction EM et en temps d'exploitation. La prédiction est définie par les équations (2) et (3). Elles consistent à exprimer l'erreur moyenne sur les coefficients de la matrice de réflexion (2) de laquelle on tire l'erreur de phase (3) générée par le réseau de neurones sur l'ensemble d'une base de test de N_T échantillons.

$$\epsilon_{R_{11}} = \frac{1}{N_T \cdot |R_{11Ref}|^{max}} \cdot \sum_{i=1}^{N_T} |R_{11ANN}^i - R_{11Ref}^i| \quad (2)$$

$$\epsilon_{\phi R_{11}} = \frac{1}{N_T} \cdot \sum_{i=1}^{N_T} |\phi R_{11ANN}^i - \phi R_{11Ref}^i| \quad (3)$$

Cette base de test, au même titre que la base d'apprentissage d'ailleurs, est construite à partir de simulations rigoureuses à l'aide d'un logiciel interne. Ainsi, la base d'apprentissage est constituée de 3168 et 13246 échantillons pour les cas capacitif et inductif, ce qui correspond respectivement à 22 et 92 géométries caractérisées chacune pour 36 incidences et 4 fréquences. On note par ailleurs que l'échantillonnage du cas inductif est plus dense du fait des plus fortes résonances de ces cellules (donc des variations plus rapides des réponses), particulièrement les grandes fentes étroites.

La courbe bleue de la figure 4 présente l'évolution typique de la courbe d'erreur moyenne pour le coefficient de réflexion R_{11} (paramètre de sortie le plus important puisqu'il fournit la phase réfléchi par la cellule) pour la cellule capacitive, en fonction du nombre de neurones N_1 dans l'unique couche cachée. On note que, de manière classique, l'erreur décroît fortement jusqu'à atteindre un palier, puis augmente de nouveau avec l'apparition du phénomène dit de sur-apprentissage [7].

L'algorithme d'optimisation de la complexité du réseau consiste simplement à augmenter le nombre de neurones dans la couche cachée jusqu'à ce que la dérivée première de cette fonction d'erreur (courbe rouge) s'annule, c'est-à-dire lorsque le palier est atteint. On note que pour chaque complexité, le processus d'apprentissage est répété 25 fois du fait du caractère aléatoire de l'initialisation des paramètres du réseau. En ce qui concerne la modélisation de la phase de la cellule capacitive, les résultats montrent que l'annulation de la première dérivée est observée pour $N_1=15$, ce qui semble satisfaisant car l'erreur sur le paramètre direct de réflexion est de $\text{EPS}_{R_{11}} = 3.10^{-2}$ (lin) correspondant à $1,48^\circ$ d'erreur moyenne de phase.

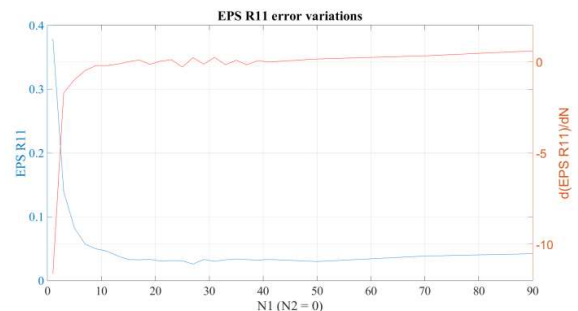


Figure 4. Erreur moyenne sur le coefficient de réflexion direct pour la cellule capacitive
Courbe bleue : meilleur résultat pour chaque complexité / Courbe rouge : dérivée première de la fonction d'erreur

Le processus est opéré de façon identique pour la modélisation de la cellule inductive. La complexité optimale du réseau est obtenue pour 31 neurones dans la couche cachée. Bien que la complexité ait été

augmentée, ce résultat reste cohérent avec la discrétisation plus fine de la base d'apprentissage.

Une fois que le nombre de neurones dans la couche cachée 1 a été défini, une deuxième étude est menée pour évaluer l'apport d'une deuxième couche. La Figure 5 montre l'erreur en fonction de la complexité N_2 pour N_1 fixé à 15 neurones. Par comparaison avec la figure 4, il n'y a pas d'amélioration sensible des performances, ce qui est en cohérence avec [8] qui stipule que tout système non linéaire peut être modélisé par un ANN constitué d'une unique couche cachée.




Figure 5. Erreur moyenne sur le coefficient de réflexion direct pour la cellule capacitive pour un ANN de 2 couches avec $N_1=15$ en fonction de N_2

Si l'erreur obtenue sur la phase du coefficient R_{11} est tout à fait acceptable, il n'en va pas de même pour les prédictions en amplitude. En effet, du fait de la très faible dynamique de variations des amplitudes des coefficients R_{11} et R_{12} ($|R_{11}|$ et $|R_{12}|$), comparativement à celle de la phase, l'utilisation d'un même réseau pour la prédiction de la phase et de l'amplitude semble impossible.

3. Optimisation de l'algorithme pour l'amplitude

On propose ainsi dans cette communication de résoudre cette problématique par la construction de deux réseaux différents pour chaque type de cellule, l'un modélisant la phase et l'autre modélisant l'amplitude [10]. Ainsi la figure 6 propose l'architecture des différents réseaux pour la modélisation des cellules capacitatives et inductives.

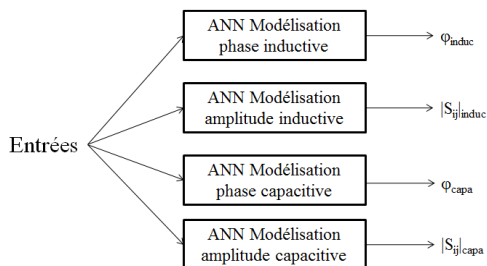


Figure 6. Architecture globale pour la modélisation des cellules capacitatives et inductives

S'agissant de la conception des ANN pour la modélisation d'amplitude, l'algorithme défini précédemment peut être appliqué de manière strictement

identique avec le calcul d'erreur moyenne sur la base de test décrit dans l'équation (3).

$$\epsilon_{|R_{11}|} = \frac{1}{N_T \cdot |R_{11}^{Ref}|_{max}} \cdot \sum_{i=1}^{N_T} ||R_{11,ANN}^i| - |R_{11,Ref}^i|| \quad (3)$$

Les résultats de la figure 7 présentent les complexités optimales N_1 . On observe l'annulation de la première dérivée pour $N_1 = 19$ pour les deux types de structures capacitive (Figure 7.a) et inductive (Figure 7.b).




Figure 7. Erreur moyenne d'amplitude
Courbe bleue : meilleur résultat pour chaque structure / Courbe rouge : dérivée première de la fonction d'erreur
(a) cellule capacitive
(b) cellule inductive

4. Analyse des performances

Les résultats finaux sont présentés dans le tableau I. Les valeurs numériques obtenues sur les erreurs des coefficients de la matrice de réflexion, des phases et des amplitudes sont satisfaisantes, tant sur les moyennes que sur les maxima d'erreur pour les deux types de structures étudiées. On note également que l'un des avantages des ANN concerne le temps d'exploitation, puisque le temps d'accès aux propriétés EM est de $10\mu s$ /cellule.

	Capacitive		Inductive	
$\epsilon_{R_{11}}(\text{lin})$	3.10^{-2}		$3,8.10^{-2}$	
$\epsilon_{\phi R_{11}}(^{\circ})$	1,48		1,6	
$\epsilon_{ R_{11} }(\text{lin/dB})$	$4,9.10^{-4}$	-66	$3,4.10^{-4}$	-69
$\max(\epsilon_{ R_{11} })(\text{lin/dB})$	$7,3.10^{-3}$	-42	$1,8.10^{-2}$	-34
$\sigma(\epsilon_{ R_{11} })(\text{lin})$	10^{-5}		$2,8.10^{-5}$	

Tableau I. Performances des ANN

Afin d'illustrer ces résultats numériques, on se propose d'observer quelques exemples.

La figure 8 présente la variation de la phase en fonction du coefficient géométrique C_2 pour la simulation ANN et la simulation rigoureuse (Full-wave) dans le cas de la cellule capacitive (figure 8.a) et inductive (figure 8.b). Cet exemple est obtenu à 3,4GHz, en incidence normale et pour une valeur de C_1 fixée à 23,7mm. Les courbes sont parfaitement superposées, y compris dans les zones de résonances des cellules. On note que la variation de phase est plus forte dans le cas inductif, particulièrement lorsque la fente devient plus fine. On observe même que l'ANN régularise les petites fluctuations aléatoires observées sur la simulation rigoureuse pour C_2 voisin de 10mm dans le cas inductif.




Figure 8. Variation de phase ANN et full-wave
(a) cellule capacitive
(b) cellule inductive

La figure 9 présente enfin, dans les mêmes conditions que la figure 8, les variations d'amplitude des paramètres direct et croisé dans le cas de la cellule inductive. On note que les performances obtenues par la modélisation sont cohérentes avec les simulations rigoureuses, y compris dans le cas de la polarisation croisée sur laquelle le réseau n'a pas été entraîné (on rappelle qu'uniquement $|R_{11}|$ a été pris en compte dans la fonction coût (3) pour construire l'ANN)


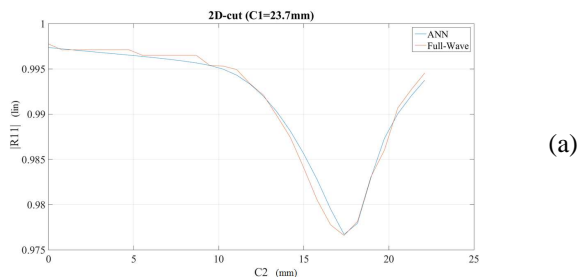


Figure 9. Variation d'amplitude ANN et full-wave
(a) $|R_{11}|$ (b) $|R_{12}|$

5. Conclusion

Cette communication rend compte des travaux effectués sur la modélisation d'une cellule de réseaux réflecteurs par la méthode des réseaux de neurones.

Les différents modèles créés, pour la modélisation de la phase et de l'amplitude, prédisent rapidement et avec précision le comportement EM des cellules capacitive et inductive, que cela soit en termes de phase ou d'amplitude sur les paramètres direct et croisé. Une des perspectives de ces travaux serait d'utiliser de tels modèles comportementaux au sein d'un outil d'optimisation pour la synthèse de réseaux réflecteurs.

Ce travail a été réalisé dans le cadre de MERLIN, laboratoire commun à Thales et l'IETR avec le support du CNES.

Références

- [1] D.G. Berry, R.G. Malech and W.A. Kennedy; "The reflectarray antenna", IEEE TAP, Vol 11, pp. 645-671, 1963
- [2] Huang and J.A. Encinar, "Reflectarray Antennas", Wiley IEEE Press, 2007.
- [3] A. Z. Elsherbeni and Al., "Reflectarray Antennas for Space Applications", IEEE International Conference on Ultra-Wideband, 2012
- [4] P. Robustillo and Al., "ANN characterization of multi-layer reflectarray elements for contoured-beam space antennas in the Ku-band", IEEE Antennas and Propagations, Vol. 60, no. 7, pp. 3205-3214, 2012.
- [5] A. Freni and Al., "Neural network characterization of reflectarray antennas," Int. J. Antennas Propag., vol. 2012, pp. 541354-1-541354-10, 2012.
- [6] L. Moustafa and Al., "The phoenix cell: A new reflectarray cell with large bandwidth and rebirth capabilities", IEEE Antenna and Wireless Propag. Letters, Vol 10, pp. 71-74, 2011.
- [7] S. Haykin, "Neural networks: a comprehensive foundation", McMillan, Englewood Cliffs, NJ, 1994
- [8] Hornik and Al, "Multilayer Feedforward Networks are Universal Approximators", Neural Networks Vol. 2, pp. 359-366, 1989
- [9] V. Richard and Al., "Optimized Artificial Neural Network for reflectarray cell modelling", IEEE Antennas and Propagations Symposium, 2016
- [10] G. Gosal and Al., "Transmitarray Antenna Design Using Forward and Inverse Neural Network Modeling", Vol. 15, pp. 1483-1486, 2016