

Augmentation de Données pour l'Entraînement de Réseaux de Neurones Artificiels Appliqués au Contrôle Non Destructif par Courants de Foucault

Romain CORMERAIS, Roberto LONGO, Aroune DUCLOS, Guillaume WASSELYNCK, Gérard BERTHIAU

Institut de Recherche en Énergie Électrique de Nantes Atlantiques, École Supérieure d'Électronique de l'Ouest,

Laboratoire d'Acoustique de l'Université du Mans

Le contrôle non destructif par courants de Foucault est très utilisé pour inspecter des matériaux métalliques. L'estimation de paramètres comme la profondeur ou la largeur d'un défaut est cependant difficile à cause de la complexité des modèles décrivant les phénomènes mis en jeu. Les réseaux de neurones artificiels permettent d'éviter ces difficultés en élaborant automatiquement un modèle à partir de données. L'entraînement d'un réseau demandant beaucoup d'exemples, des simulations sont souvent utilisées pour palier les limitations expérimentales, menant à de grands coûts de calculs. Pour répondre à ce problème, cet article propose une méthode d'augmentation de données permettant de réduire le nombre de simulations nécessaires à l'entraînement d'un réseau.

Courants de Foucault, Réseaux de Neurones Artificiels, Augmentation de données, Analyse en Composantes Principales.

1. INTRODUCTION

L'objectif du **contrôle non destructif (CND)** est de déterminer la présence voire la position et la taille de défauts afin d'évaluer la qualité et la sécurité des matériaux utilisés dans le bâtiment ou l'industrie du transport. Les **courants de Foucault (CF)** sont très utilisés pour tester les défauts surfaciques dans les matériaux métalliques. La présence d'un défaut dans une pièce modifie la circulation des courants induits et entraîne ainsi une perturbation du magnétique de réaction pouvant être détectée par la variation d'impédance du capteur. Les modèles physiques décrivant les **CF** sont complexes et difficiles à inverser, ce qui conduit à des estimations difficiles des dimensions des défauts. Des approches basées sur un **Réseau de Neurones Artificiels (RNA)** [1][2][3] donnent de bons résultats car elles s'appuient seulement sur des données [4][5][6]. De plus, les **RNA** sont implémentables dans des solutions embarquées et temps réel. Il est alors possible d'imaginer des capteurs **CF** intelligents capables d'estimer la nature, la taille et la position d'un défaut.

Cependant ces **RNA** nécessitent un nombre important de données pour leurs entraînements. Des simulations numériques sont alors souvent utilisées pour obtenir le volume de données nécessaire à leur entraînement, ce qui nécessite alors des temps et des ressources de calculs importants [7].

Dans cet article, les signaux **CF** sont obtenus avec une méthode à éléments finis détaillée dans la Section 2.

Pour réduire les temps de calculs, cette étude propose une méthode d'augmentation des données via l'**Analyse en Composantes Principales (ACP)** appliquée aux résistances et réactions.

La factorisation **ACP**, présentée dans la Section 3, vise à concentrer les informations utiles dans un petit ensemble de données permettant ensuite une interpolation en trois dimensions [9]. Les données originales et augmentées collectées sont utilisées comme entrées d'un **RNA** dont l'architecture est présentée dans la section 4. Les résultats, présentés dans la Section 5, montrent l'intérêt de l'**ACP** pour obtenir des entrées pertinentes pour les **RNA**, les performances de l'algorithme d'aug-

mentation et permet ainsi l'utilisation d'un ensemble de données d'entraînement réduit sans détériorer significativement les estimations du **RNA**.

2. SIMULATION DE COURANTS DE FOUCAULT EN PRÉSENCE DE DÉFAUTS

Cette section présente la procédure suivie pour obtenir les signaux issus de l'inspection de différents défauts traversants. Les **CF** sont simulés par éléments finis 3D via la formulation en vecteur potentiel électrique et potentiel scalaire magnétique $T-\Omega$ adaptée aux géométries multiples connexes [8]. Les variations d'impédance de l'inducteur dues aux défauts sont calculées à travers les puissances actives et réactives dissipées par le milieu. Les variations d'impédance de l'inducteur dues aux défauts sont alors calculées à travers les puissances actives et réactives dissipées Eq. (1) et Eq. (2). La sonde **CF** est une bobine de 2,25 mm de hauteur avec des rayons intérieurs et extérieurs de 2,22 et 2,48 mm, placée à 0,18 mm au dessus de la surface inspectée et commandée par un signal sinusoïdal de 1 kHz. Le milieu est un bloc d'aluminium de conductivité électrique $\sigma = 37,7 \text{ MS.m}^{-1}$ et de perméabilité magnétique relative $\mu_r = 1$ contenant des défauts cylindriques traversants, cf. Figure 1. Les rayons et profondeurs de ces défauts varient respectivement de 0,6 à 8 mm et de 0,1 à 4 mm, donnant 3000 différents signaux calculés en 2000 heures avec un PC équipé d'un processeur Intel I7, d'une unité de calcul graphique (GPU) NVIDIA Quadro P3000 et de 16 Go de RAM. La Figure 2 donne l'exemple d'impédances simulées pour trois défauts de 1, 2 et 3 mm de rayon situés à 1 mm de profondeur.

Les figures Figure 3 et Figure 4 montrent le bon comportement des variation d'impédance simulées par rapport à des mesures expérimentales. L'impédance de l'inducteur est calculée pour 51 pas de un millimètre chacun. Les écarts observés sont liés à la non-prise en compte de la réaction d'induit sur les courants d'alimentation de la bobine ; il s'agit d'un compromis pour limiter les temps de calcul. L'utilisation d'une sonde réceptrice aurait permis de limiter l'impact de cette hypothèse simplificatrice.

$$RI_{source}^2 = \int_{D_c} \vec{E} \cdot \vec{J} dD_c = \int_{D_c} \sigma^{-1} \vec{J} \cdot \vec{J} dD_c \quad (1)$$

$$XI_{source}^2 = \int_D \frac{\partial \vec{B}}{\partial t} \cdot \vec{H} dD = w \int_D \mu^{-1} \vec{B} \cdot \vec{B} dD \quad (2)$$

3. ALGORITHME D'AUGMENTATION DE DONNÉES BASÉ SUR LES COMPOSANTES PRINCIPALES

Ce paragraphe détaille la procédure d'augmentation de données utilisée pour traiter les signaux simulés en Section 2. L'**ACP** est une méthode statistique qui traduit des observations corrélées en variables linéairement orthogonales triées selon




Fig. 1. Schéma d'un bloc d'aluminium simulé contenant un défaut cylindrique traversant.




Fig. 2. Résistances (—) et réactances (---) simulées pour trois défauts de 1, 2 et 3 mm de rayon situés à 1 mm de profondeur.




Fig. 3. Résistances (noir) et réactances (gris) simulées (—) et expérimentales (---) pour un défaut de 2.5 mm de rayon situés à 1 mm de profondeur.




Fig. 4. Résistances (noir) et réactances (gris) simulées (—) et expérimentales (---) pour un défaut de 2.5 mm de rayon situés à 3 mm de profondeur.

leur variance et appelées **Composantes Principales (CPs)** [9]. Cette transformation est définie de telle sorte que la première composante principale présente la plus grande variance possible, et que chaque composante suivante présente à son tour la plus grande variance possible dans la base orthogonale [9]. La Figure 5 montre les 20 premières transformées en CPs pour des défauts de 3 mm à différentes profondeurs. 99 % de l'information est située dans les deux premières composantes, il est alors possible de réduire les 102 caractéristiques des signaux CF (51 pas $\times$ 2 parties actives et réactives) à seulement deux données.

La Figure 6 donne l'exemple de l'évolution des deux CPs en fonction des rayons des défauts. Partant de cette nouvelle représentation des signaux, l'algorithme d'augmentation proposé ajoute des données supplémentaires aux profondeurs et aux rayons voulus. Les abscisses des nouvelles données sont calculées par interpolation cubique sur les premières CPs des données simulées [10]. Ensuite, les ordonnées sont calculées par une interpolation linéaire entre l'abscisse et les deuxièmes CPs [11]. Cette procédure permet de multiplier le nombre de données par un facteur arbitraire. La Figure 7 donne l'exemple d'un facteur 5.

4. ESTIMATION DES DIMENSIONS DES DÉFAUTS PAR RÉSEAUX DE NEURONES ARTIFICIELS

Cette section décrit l'utilisation de **RNA** pour estimer les profondeurs et rayons des défauts à partir des signaux CF simulés en Section 2. Cette méthode offre une alternative à l'inversion par modèles physiques. Le **RNA** utilisé, cf. Figure 8, est composé de deux entrées. Ces entrées sont connectées à une couche cachée de 20 neurones définie empiriquement. La couche de sortie est constituée de deux neurones correspondant aux profondeurs et rayons à estimer. Chaque neurone retourne l'image de la somme pondérée de ses entrées par une fonction prédéfinie. Les poids v_{ij} et w_{ij} , initialisés aléatoirement, sont calculés en présentant des données d'entraînement au réseau. Ce calcul est réalisé en minimisant l'**Erreur Quadratique Moyenne (EQM)** entre les sorties obtenues pour chaque exemple et celles atten-




Fig. 5. Transformées des signaux des défauts de 3 mm de rayon enfouis à des profondeurs allant de 1 (noir) à 8 mm (gris) tracés en fonction des 20 premières composantes principales obtenues avec l'ACP des CFs.




Fig. 6. Signaux CF simulés représentés avec les deux CPs montrant l'évolution des rayons des défauts (rayon de 8 mm en rouge à 0.1 mm en orange).




Fig. 7. Signaux CF simulés et augmentés par un facteur 5 représentés avec les deux CPs montrant l'évolution des rayons des défauts (rayon de 8 mm en rouge à 0.1 mm en orange).

dues [4].

Une validation croisée est utilisée pour estimer les performances du **RNA**. Les données simulées sont divisées en 10 jeux. A tour de rôle, 9 jeux sont utilisés pour la phase d'apprentissage (entraînement et validation) et le dernier pour la phase de test. Cette approche permet de s'assurer de la non-sensibilité aux données d'entraînement.




Fig. 8. Schéma du **RNA** utilisé composé de deux entrées, d'une couche cachée de vingt neurones et deux sorties.

5. RÉSULTATS ET DISCUSSION

Dans cette partie les principaux résultats sont présentés et discutés. Dans un premier temps, l'apport de l'analyse en CPs sur l'estimation d'erreur est discuté. Ensuite, les performances de l'algorithme d'augmentation de données seront montrées. Pour finir, l'estimation des dimensions de défaut via l'augmentation de données sera analysée.

5.1. Apport de l'analyse en composante principale

La base de données est considérée complète dans ce paragraphe, la réduction de cette base sera discutée ensuite. Le **RNA** possède deux neurones d'entrées. L'utilisation la plus simple des données est d'utiliser sur ces entrées le maximum de la variation d'impédance de la partie active et réactive. Cependant, cette méthode fait perdre beaucoup d'information car seules deux mesures sur 102 sont utilisés. Utiliser les **CPs** permet de conserver plus d'information sans changer l'architecture du **RNA**.

La figure Figure 12 montre les estimations des rayons et profondeur par rapport au valeurs simulées en utilisant les maxima des variations d'impédance et les **CPs**. Le tableau 1 donnent les moyennes et déviations standards des **EQM** obtenues par validation croisée. Les **CPs** permettent bien une meilleure estimation des dimensions des défauts.

L'utilisation des **RNA** permet également d'avoir une estimation des performances d'identification des défauts. Les Figure 10 et Figure 11 montre une cartographie des **Erreur Absolue Moyenne (EAM)**; L'estimation des rayons de défaut important est moins bonne car leurs tailles sont bien plus importantes que celle du capteur. De même, pour les profondeurs de défauts importants, l'estimation se dégrade à cause du phénomène d'épaisseur de peau qui réduit la sensibilité des **CF**.




Fig. 9. Comparaison des estimations des rayons et profondeurs du **RNA** (cercles) avec les paramètres réels (croix) pour les données de test

Tableau 1 – Moyennes et déviations standard des **EQM** obtenues par validation croisée

	Maxima	CPs
Ensemble d'entraînement	$0.014 \pm 0.002mm^2$	$0.0024 \pm 0.004mm^2$
Ensemble de validation	$0.014 \pm 0.003mm^2$	$0.0024 \pm 0.003mm^2$
Ensemble de test	$0.014 \pm 0.004mm^2$	$0.0024 \pm 0.005mm^2$




Fig. 10. Cartes de l'**EAM** d'estimation des rayons en fonction des paramètres réels des défauts




Fig. 11. Cartes de l'**EAM** d'estimation des profondeurs en fonction des paramètres réels des défauts.

5.2. Erreur sur l'augmentation de donnée

Dans la partie 3, un algorithme d'augmentation de donnée a été proposé afin de pouvoir créer une base de donnée conséquente à partir d'une campagne de mesure ou simulation plus réduite. Avant de se servir de cette base données augmentée, il convient de vérifier la qualité de l'augmentation. Pour ce faire, des points simulés dans la base de données originale sont retirés puis remplacés par des points estimés à partir de l'algorithme. Ces points sont retirés de manière homogène et selon un facteur de décimation. Par exemple, un facteur de décimation de 10 signifie que seulement 1 point sur les 10 originaux est conservé, les 9 autres sont "augmentés".

La figure Figure 12 montre la comparaison des points décimés de la base de données originales (bleus) et des points générés par l'augmentation de données (rouges) pour un facteur de décimation de 10. L'**EQM** obtenue est alors de $1.6 \times 10^{-3} \Omega^2$ ce qui démontre la bonne performance de la procédure d'augmentation de données.

La figure Figure 13 présente **EQM** entre les points décimés et les points générés par l'augmentation de données en fonction du facteur de décimation. Cette erreur croît en fonction du facteur de décimation et n'est pas monotone par la suppression de certains diamètres lors de la décimation. Ces pertes sont visibles par les coupures observables Figure 12.

5.3. Estimation des dimensions et impact de la décimation

Ce paragraphe présente les erreurs d'estimations des dimensions des défauts obtenues en utilisant l'augmentation de don-




Fig. 12. Comparaison des points décimés de la base de données (bleus) et des points générés par l'augmentation de données (rouges) pour un facteur de décimation de 10




Fig. 13. Erreur quadratique moyenne entre les points décimés et les points générés par l'augmentation de données en fonction du facteur de décimation.

nées présentée dans la Section 3 et appliquée au RNA. L'EQM d'estimation des rayon et profondeurs des exemples de test est tracée en fonction du facteur de décimation des données d'entraînement en Figure 14. Ces erreurs sont comparées à celles obtenues en remplaçant les points décimés par augmentation de données avec une validation croisée ce qui permet d'obtenir les erreurs moyennes, minimums et maximums. L'EQM pour une décimation par huit est en moyenne de 1000% contre 9% avec l'utilisation de l'augmentation de données. De plus, l'utilisation de l'augmentation de données permet de réduire la variabilité des estimations des RNA. Ces résultats semblent valider l'approche utilisée. L'augmentation de données proposée permet donc de réduire le temps simulation par huit, passant de 2000 à 250 heures de calculs ici et permet également de réduire le temps d'entraînement.

6. CONCLUSION

Les RNA semblent être des outils prometteurs pour le CND par CF, ils peuvent être implémentés sur des systèmes embarqués et temps réel afin de créer des capteurs intelligents. De plus RNA permettent, en plus d'une estimation des tailles et positions des défauts, d'avoir une estimation de la qualité d'estimation. Néanmoins, le principal inconvénient de ces approches reste le besoin de disposer d'une grande base de données pour entraîner correctement un réseau, qu'elle soit expé-




Fig. 14. EQM maximale (+), moyenne (o) et minimale (x) obtenues sur cinquante entraînements en réduisant (courbe rouge) puis en augmentant les données d'entraînement (courbe bleu).

rim mentale ou simulée. La technique d'augmentation de données basé sur l'ACP présentée dans cet article pourrait permettre de fortement réduire les coûts de calculs d'une base de données simulée tout en limitant très fortement l'augmentation des erreurs d'estimation des dimensions des défauts. Cette méthode semble également permettre d'obtenir des RNA plus robuste. Les RNA sont également un outils puissant pour réaliser de la fusion de données. Il est possible de fusionner des données issues d'un capteur CF et d'un capteur ultrasons (US). Les CF ont une zone aveugle pour les fortes profondeur à cause de l'effet de peau tandis que les US ont une zone aveugle sur les très faible épaisseurs à cause du champ proche. Les données de ces deux méthodes sont donc complémentaires et les fusionner permettraient un contrôle plus performant et plus facile à mettre en oeuvre.

7. REMERCIEMENTS

Les auteurs remercient Matthieu FEUILLOY, Fabien CHHEL et Nicolas GUTOWSKI pour leur aide et commentaires. Ce travail est réalisé par des membres du GIS ECND PdL. Cette recherche est financée par le RFI-WISE, Pays de Loire, France.

8. RÉFÉRENCES

- [1] A. Babaei, A. A. Suratgar, and A. H. Salemi, Dimension estimation of rectangular cracks using impedance changes of the eddy current probe with a neural network. *Journal of Applied Research and Technology*, **11** (3), (2013), 397.
- [2] P. Ramuhalli, Neural network based iterative algorithms for solving electromagnetic NDE inverse problems. Iowa State University, (2002).
- [3] S. Harzallah, R. Rebhi, M. Chabaat, A. Rabehi, Eddy current modeling using multilayer perceptron neural networks for detecting surface cracks, *Frattura ed Integrità Strutturale*, **45**, (2018), 147.
- [4] Y. Lecun, Connectionist Learning Models. Universite P. et M. Curie, (1987).
- [5] M. T. Hagan, H. B. Demuth and M. H. Beale, Neural Network Design. Boston Massachusetts PWS, **2**, (1995), 734.
- [6] C. M. Bishop, Pattern Recognition and Machine Learning. Springer, (2006).
- [7] Y. Bengio, Learning Deep Architectures for AI. *Foundations and Trends® in Machine Learning*, **2**, (2009).
- [8] T. Henneron, S. Clenet, F. Piriou, Comparison 3D magnetodynamic formulations in term of potential with imposed electric global quantities. *COMPEL*, **23** (4), (2004)
- [9] I. Jolliffe, Principal Component Analysis. *International Encyclopedia of Statistical Science*. Springer, Berlin, Heidelberg, (2011).
- [10] H. Akima, A new method of interpolation and smooth curve fitting based on local procedures. *Journal of the ACM (JACM)*, **17**, (1970), 589.
- [11] I. Amidror, Scattered data interpolation methods for electronic imaging systems : a survey. *Journal of Electronic Imaging*, **11**, No. 2, (2002), 157.