

Modélisation cognitive de l'application des réseaux de neurones artificiels sur l'étude des caractéristiques des matériaux

Randriamamonjisoa S. R.¹, Randimbindrainibe F.², Robinson M.³

Laboratoire de Recherche en Sciences Cognitives et Applications (LR-SCA)

École Doctorale en Sciences et Techniques de l'Ingénierie et de l'Innovation (ED-STII)

Équipe d'Accueil Doctorale Sciences Cognitives et Applications (EAD-SCA)

Université d'Antananarivo

BP 1500, Ankatso – Antananarivo 101 – Madagascar

¹vonjyninih@yahoo.fr, ²falimanana@mail.ru, ³mat_robinson@yahoo.fr

Résumé

Cet article qui est une recherche dans le domaine de Sciences des matériaux présente une approche de modélisation de processus de la déformation d'une poutre. Une modélisation se fait en utilisant les Réseaux de Neurones Artificiels en basant sur les études expérimentales déjà existantes et des résultats connus à l'aide de l'étude de la résistance des matériaux. Les études comparatives de ces deux méthodes sont de trouver les valeurs approximatives et minimisation de la déformation. Nous avons beaucoup d'avantages avec l'utilisation de Réseaux de Neurones Artificiels en ingénierie. L'étude de cas se fait dans le domaine des matériaux en génie civil.

Mots-clés : *Sciences des matériaux, Réseaux de Neurones Artificiels, résistance des matériaux, minimisation des valeurs de la déformation.*

Abstract

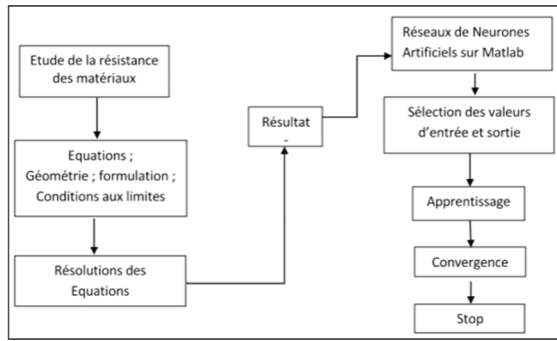
This paper which is a research in the field of Materials Science presents an approach to process modeling of beam deformation. Modeling is done using Artificial Neural Networks by basing on existing experimental studies with known results using the study of the resistance of materials. The comparative studies of these two methods are to find the approximate values and minimization of the deformation. We have many advantages of using Artificial Neural Networks in engineering. A case study is within in the field of civil engineering materials.

Keywords: *Materials sciences, Artificial Neural Networks, strength of materials, minimizing the values of the deformation.*

1. Introduction

L'utilisation des Réseaux Neurones Artificielles passe d'abord par une compréhension du principe de fonctionnement

du constituant élémentaire des réseaux de



neurones qui est la cellule nerveuse. A cet effet, cette recherche a été donnée une approche de modélisation de processus de la déformation d'une poutre et continue la recherche dans le domaine de sciences des matériaux. Par la suite, on a présenté les études comparatives de ces deux méthodes qui sont finies par trouver les valeurs approximatives et la minimisation de la déformation.

Cette modélisation se fait en utilisant les Réseaux Neurones Artificiels, en se basant sur un modèle de résistance déjà existant, et grâce à des données expérimentales provenant d'une part, et de la littérature avec une compagne d'étude spécifique réalisée avec des formules de la résistance des matériaux, d'autre part.

Les Réseaux Neurones Artificielles ont la capacité de classifier des connaissances, de simuler et de prendre des décisions qui leur ont conféré un champ d'application en ingénierie, notamment dans le domaine des matériaux en génie civil.

2. Méthodologie

Nous exposerons la méthodologie de la détermination du comportement mécanique des matériaux en deux étapes :

➤ Etude de la résistance des matériaux

➤ Réseaux de Neurones Artificiels

Figure 01 : Méthodologie de l'association de la résistance des matériaux et RNA

2.1 Etude de la résistance des matériaux

Nous prenons le cas d'une poutre mono-encastree et ensuite nous déterminons la modélisation du comportement linéaire et non linéaire des structures en béton armé. Ci-après la figure d'une poutre encastree de dimension de 3m de longueur, d'épaisseur 20cm et 50cm de hauteur :




Figure 02 : Poutre encastree à une extrémité et soumise une force à l'autre extrémité

2.2 Présentation des variables et équations

Parmi les paramètres qui définissent les valeurs des sollicitations, on distingue les moments fléchissants, les efforts tranchants. Ces valeurs sont données suivant les résultats obtenus et en fonction de la longueur de la poutre. Dans ce cas, les contraintes généralisées et la déformation sont présentées par :

$$M(x) = -Fx$$

$$T(x) = -F$$

$$U(x) = \frac{-Fx^2}{6EI} (2D - x)$$

$$I = \frac{bh^3}{12}$$

Où x varie de 0 à D , tels que D est la longueur de la poutre.

Tableau 1 : Ordre de grandeur du comportement mécanique du béton

Matériaux	Module d'Young E (Mpa)	Coefficient de poisson	Limite à rupture (Mpa)
Béton	30 000	0.2	20 à 40 (compression) 2 à 5 (traction)

2.3 Valeurs des sollicitations

Les résultats des moments fléchissants et efforts tranchants sont représentées dans la Figure 3 et 4.




Figure 03 : Diagramme des moments fléchissants




Figure 04 : Diagramme des efforts tranchants

2.4 Réseaux de Neurones Artificiels

a) Modèle Réseau de Neurones Artificiels

Le réseau de neurones multicouche à rétropropagation a été choisi dans cette étude en

raison de sa popularité et de sa capacité de réussite en termes de classification, de prédiction et d'optimisation des modèles. L'emploi de l'apprentissage supervisé exige la connaissance d'une sortie désirée pour tout élément de l'ensemble des données d'entrée. Le modèle multicouche à rétropropagation se compose de trois types de couches, la couche d'entrée, une ou plusieurs couches cachées et une couche de sortie.

Dans la prévision de la déformation d'une poutre, l'ensemble des données d'entrée est représenté par les moments fléchissant, les efforts tranchants. Cela représente les paramètres de la couche d'entrée qui sont transmis à la couche cachée. Enfin, la couche de sortie reçoit son entrée des couches cachées. Dans notre cas la sortie des couches cachées représente la déformation.

b) Méthodologie et mise en œuvre

La première étape consiste à identifier les paramètres à employer pour les modèles de prévision. Les données sont divisées en trois parties. 70% des données sont employées pour l'apprentissage, 15% pour la phase de test et 15% pour la validation. La mise en œuvre d'un modèle RNA inclut ces trois phases : l'apprentissage, le test et la validation.

La phase d'apprentissage ou d'entraînement a pour but de déterminer les paramètres de connexion du réseau à l'aide de la technique d'optimisation. La phase de test consiste à vérifier le réseau déterminé lors de la phase d'apprentissage sur des données non utilisées lors de cette dernière, et à examiner la capacité

du réseau à généraliser les exemples d'apprentissage (en comparant la sortie réelle du réseau avec la sortie désirée). La phase de validation est effectuée sur la dernière partie des données. Cet apprentissage est supervisé.

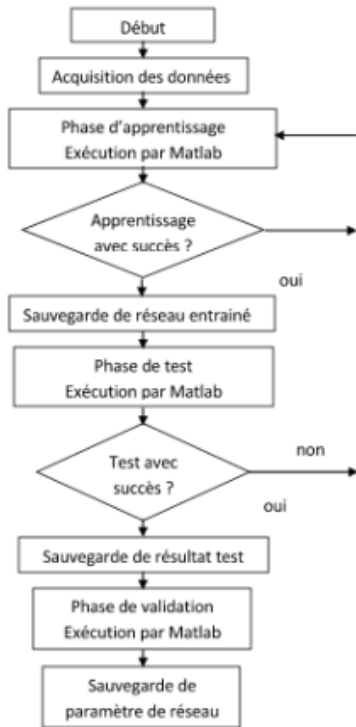


Figure 05 : Méthodologie de développement du RNA

Dans un premier temps, on procède à la détermination du type d'algorithme d'apprentissage à utiliser dans notre recherche. Après plusieurs tentatives, l'algorithme de Levenberg-Marquardt s'avère le plus efficace et le plus fiable. Dans ce cas, nous avons vu 110 itérations comme étant la limite du processus de convergence.

L'apprentissage a été basé sur l'algorithme de Levenberg-Marquardt à rétropropagation du gradient de l'erreur avec les fonctions de transfert standard Tansigmoïde correspondant

respectivement aux couches cachées et de sortie.




Figure 06 : Architecture adoptée

3. Résultats

3.1 Somme pondérée des entrées du neurone de la couche de sortie

La sortie calculée par le RNA est défini par :

$$y(h) = f(\sum_{i=1}^n W_i x_j)$$

La somme pondérée des entrées du neurone de la couche de sortie est donnée par la formule suivante :

$$h = \sum_{i=1}^n W_i x_j$$

W_i est la matrice du poids et on donne le résultat suivante :

$$\begin{pmatrix} 0,04 \\ 0,04 \\ 0,04 \\ 0,04 \\ 0,04 \\ 0,04 \\ 0,04 \\ 0,04 \\ \dots \\ -2,19 \end{pmatrix} = \begin{pmatrix} 1,8555 & -1,8348 & 1,4466 \\ -1,3528 & -0,30181 & 2,7212 \\ 2,3116 & 1,3146 & 1,5314 \\ 2,5643 & 0,092914 & -1,658 \\ 0,78149 & -1,7302 & 1,5021 \\ 1,6514 & 1,74 & -1,8474 \\ 2,574 & 1,74 & -0,39068 \\ 0,37876 & 2,7016 & 1,2925 \\ 1,3723 & -0,77091 & 2,5704 \\ 0,56448 & 0,97221 & 2,9413 \end{pmatrix} \times \begin{pmatrix} 0,20 & 0,00 & 18,16 \\ 0,22 & 0,00 & 18,05 \\ 0,24 & 0,00 & 17,94 \\ 0,26 & 0,00 & 17,83 \\ 0,28 & 0,00 & 17,72 \\ 0,30 & 0,00 & 17,61 \\ 0,34 & 0,00 & 17,39 \\ 0,36 & 0,00 & 17,28 \\ \dots & \dots & \dots \\ 3,20 & 25,05 & -1,20 \end{pmatrix}$$

3.2 Mean Squared Error (MSE)

En effet, la variation de l'erreur est montrée par la Figure 07. Cette variation converge vers une

valeur minimale de l'erreur quadratique moyenne ou MSE, ce qui vérifie la qualité de la simulation. Nous avons trouvé la MSE égal à $9,4953 \times 10^{-7}$.

$$MSE = \frac{1}{n} \sum_{i=1}^n (c_i - o_i)^2$$




Figure 07 : Courbe de la performance

3.3 Gradient à l'erreur

Le gradient de l'erreur est notée par :

$$\nabla E = \frac{\partial E}{\partial W_i}$$

On peut écrire E sous la forme :

$$E = \frac{1}{2} \delta^2$$

D'où:

$$E = \frac{1}{2} (d - y(h))^2$$

Supposons que la couche de sortie ne comporte qu'un neurone. L'erreur quadratique moyenne E vaut:

$$\frac{\partial E}{\partial W_i} = \delta \cdot f'(\sum_{i=1}^n W_i x_i) \cdot x_i$$




Figure 08 : Courbe de gradient à l'erreur

3.4 Régression

La régression suivante illustre que la relation entre la sortie simulée et la sortie réelle est d'environ à 1. Nous avons trouvé $R = 0,99986$.




Figure 09 : Courbe de régression

3.5 Sortie désirée et simulée en même fréquence

Soit l'erreur à la sortie du neurone k :

$$e_k = d_k - z_k$$

Avec :

d_k : Sortie désirée

z_k : Sortie simulée par le RNA

Les deux réponses seront en même fréquences la sortie désirée et simulée représenté par la figure suivante :




Figure 10 : Chronogramme de la sortie désirée et simulée

3.6 Comparaison des résultats

Les calculs ont été bien faite afin d'obtenir les valeurs de déformation à partir de la géométrie et l'effort appliqué à la poutre. La valeur maximale de la sortie désirée de la poutre est supérieure à la sortie simulée. La méthode RNA est plus performante par rapport à la méthode de la résistance des matériaux.

4. Conclusions et perspectives

Nous avons constaté que le RNA donne un meilleur résultat par rapport à la résistance des matériaux. Pour notre prochaine recherche, nous aimerions appliquer la méthode de Newton Raphson pour trouver le meilleur résultat.

5. Discussions

Pour notre prochaine recherche, nous pourrions améliorer des résultats trouvés en appliquant d'autres méthodes. Nous avons remarqué pendant cette recherche le manque des données. Les données collectés ne sont pas satisfaisants d'appliquer.

6. Références

- [1]. I. Flood, "Next generation artificial neural network for civil Engineering", Journal of computing in Civil Engineering, pp.305-307, September - October 2006.
- [2]. F. Rosenblatt, "A probabilistic model for information storage and organization in the brain", Phys. Rev. 65,386, (1958).
- [3]. B. Windrow, and M. E. Hoff, "Adaptive witching circuits", IRE Wescon Convention Record, part 4. 96-104, 1960.
- [4]. S. G. Nash and A. Sofer, "Linear and Nonlinear Programming". McGraw-Hill, New York, N.Y., (1996). Nonlinear Programming". McGraw-Hill, New York, N.Y., (1996).
- [5]. D. Rumelhart, G. Hinton & R. Williams, "Learning internal representations by error propagation", Parallel Distributed Processing, Vol. 1, D. Rumelhart and J. McClelland Eds. Cambridge: MIT Press, pp. 318-362, 1986.
- [6]. L. Ivan, "Modélisation et Simulation des Systèmes Multi-Physiques avec MATLAB/Simulink R2015b", Nice (2016).
- [7]. Brandtzaeg, A., "Contraintes de compression admissibles dans les sections de béton armé rectangulaires sollicitées

excentriquement", Ein Dienst der ETH-
Bibliothek, ETH Zürich, Rämistrasse 101, 8092
Zürich, Schweiz, www.library.ethz.ch, (2017).



MADA-ETI