
L'application des réseaux neuronaux artificiels pour l'identification et la détection de l'endommagement dans les ponts

Kamel Henchi * — Mario Fafard * — Martin Talbot **
David Langis ***

* GIREF et Département de Génie Civil, Université Laval
Pavillon Adrien-Pouliot, Québec, Canada, G1K 7P4

** Ministère des transports du Québec, Direction des structures
930, Chemin Ste-Foy, Québec, Canada, G1S 4X9

*** Safi Informatique, 2900, Chemin Ste-Foy
Ste-Foy, Québec, Canada, G1V 1Y4

RÉSUMÉ. Cet article présente le développement d'une méthode d'identification d'endommagement dans les structures. Cette étude est basée sur l'utilisation des réseaux neuronaux artificiels et de leur auto-organisation dans l'évaluation de l'endommagement structural. L'idée de base est d'entraîner le réseau pour comprendre le comportement de la structure avec différents états d'endommagement. Quand les résultats expérimentaux seront présentés au réseau, il sera capable de détecter avec succès la présence ou non de l'endommagement dans la structure. Trois exemples sont examinés et les résultats obtenus sont prometteurs.

ABSTRACT. This paper presents the development of an automatic monitoring method for the detection of structural damage. In this feasibility study, we have explored the use of self-organisation of artificial neural networks in structural damage assessment combined with the finite element method. The basic strategy is to train the network to recognise the behaviour of the structure with various possible damage states. When the trained network is subjected to the measurements of the structural response, it should be able to detect any existing damage. Three examples are examined and the results are promising.

MOTS-CLÉS : dynamique, éléments finis, identification, réseaux de neurones, rétro-propagation, structures.

KEY WORDS : back propagation, dynamic, finite elements, identification, neural networks, structural.

1. Introduction

Dans le contexte nord-américain, plusieurs ponts actuellement en service ont été conçus dans les années 50-60 pour des charges routières largement inférieures à celles actuellement en vigueur. Afin d'assurer la sécurité du public, ces ponts doivent être évalués avec les charges routières actuelles afin de déterminer le scénario de réparation, de renforcement ou de remplacement. Pour ce faire, basé sur des méthodes de calcul simplifiées, les ponts jugés faibles sont testés afin de comprendre le comportement de la structure et de caler un modèle éléments finis qui servira, par la suite, à faire des études détaillées du comportement.

L'utilisation de méthodes de recalage et d'identification pour le calage de modèles numériques complexes à partir de résultats de tests expérimentaux, est une étape très importante dans le domaine des applications industrielles. En particulier, l'utilisation des méthodes classiques et rigoureuses d'optimisation ont fait leurs preuves pour l'analyse de plusieurs types de problèmes. Ces techniques sont utilisées pour l'identification de quelques paramètres des systèmes, tels que les fréquences, les rigidités et l'amortissement. Les algorithmes adaptés sont généralement complexes et leur utilisation n'est pas souhaitable dans les situations où les données mesurées sont incomplètes ou manquent de précision. Il est en effet difficile, voire impossible, avec ces méthodes de déterminer un nombre de constantes matérielles supérieur au nombre de mesures disponibles. De plus, les calculs reliés à l'identification se complexifient à mesure que le nombre de paramètres à déterminer augmente.

Ainsi, l'évaluation détaillée de l'état structural actuel de vieux ouvrages d'art constitue un défi de taille lorsque l'on cherche à caler, le plus précisément possible, un modèle éléments finis 3-D complet avec des résultats expérimentaux obtenus *in situ*. En effet, à la lumière de la collecte de résultats expérimentaux obtenus sur site, il semble qu'il soit très difficile de faire appel à une méthode d'optimisation classique pour identifier les paramètres d'un modèle éléments finis. C'est pour cette raison qu'une approche de recalage des paramètres influençant le comportement des ponts en régimes statique et dynamique [HEN 95, 97a, 97b], [AKO 97], [FAF 98], [BOU 96] à l'aide de réseaux neuronaux [BAR 95], [HAJ 91], [LIP 87], est ici développée et présentée dans le cadre d'un projet de recherche conjoint université-industrie [HEN 96] impliquant l'Université Laval et le Ministère des Transports du Québec. Les développements récents dans le domaine des réseaux de neurones artificiels ouvrent la porte à de nouvelles possibilités d'application dans le domaine du calcul des structures [HAJ 91]. Entre autres, ces techniques sont tout à fait appropriées pour des problèmes de l'identification de paramètres physiques de structures complexes en génie civil comme les ponts [LIP 87] et les bâtiments [HEN 96]. La figure 1 illustre schématiquement la problématique globale liée au calage de modèles éléments finis de ponts.

2. Le concept de calage à l'aide des réseaux neuronaux artificiels (RNA)

La méthode de calage consiste à coupler un code d'éléments finis avec un logiciel de traitement utilisant des algorithmes de réseaux neuronaux (figure 2). Il existe deux étapes distinctes dans l'application d'un réseau neuronal aux problèmes de calage. La première étape est cruciale et consiste à entraîner le réseau (la phase d'apprentissage) à partir de résultats obtenus de plusieurs analyses par éléments finis du pont. Ces analyses sont effectuées en variant sur une plage donnée, les paramètres à caler. Ainsi, pour des paramètres donnés, le modèle éléments finis fournit la réponse (déplacements, fréquences, réponse dynamique) qui est l'entrée du réseau. L'apprentissage du réseau se fait en minimisant l'erreur entre la sortie du réseau (les paramètres à identifier) par rapport aux paramètres fournis au modèle éléments finis qui a permis d'établir une base de données pour le réseau.

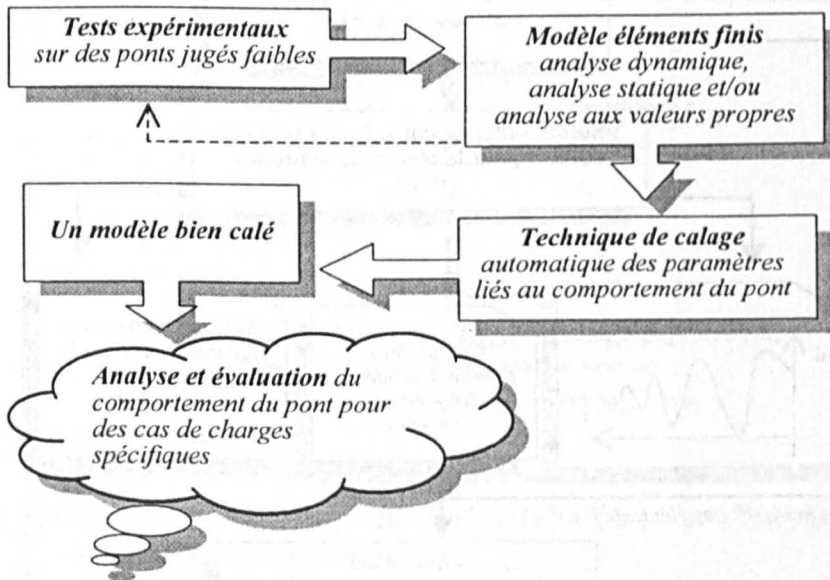


Figure 1. Processus de calage éléments finis versus tests expérimentaux

Par la suite, avec ce bagage de connaissances accumulées, le réseau de neurones est utilisé afin de détecter dans la structure, les dommages et/ou identifier les paramètres de calage, à partir de résultats de tests expérimentaux. Ces résultats de tests sont donnés au réseau afin de retrouver les paramètres à caler.

Dans la phase d'apprentissage, l'entrée du réseau est la réponse de la structure et la sortie, les paramètres à caler. Dans la phase de l'utilisation du réseau, l'entrée est la réponse de la structure déduite des tests expérimentaux et la sortie les paramètres recherchés.

Il existe différents types de réseaux de neurones [LIP 87]. Le perceptron multicouches est le réseau utilisé pour l'identification des paramètres dans le domaine du calcul des structures [BAR 95]. Il comporte un vecteur de données (neurones) porté par la couche d'entrée, un vecteur de sortie (résultats) et un nombre de couches intermédiaires (figure 3) [LIP 87].

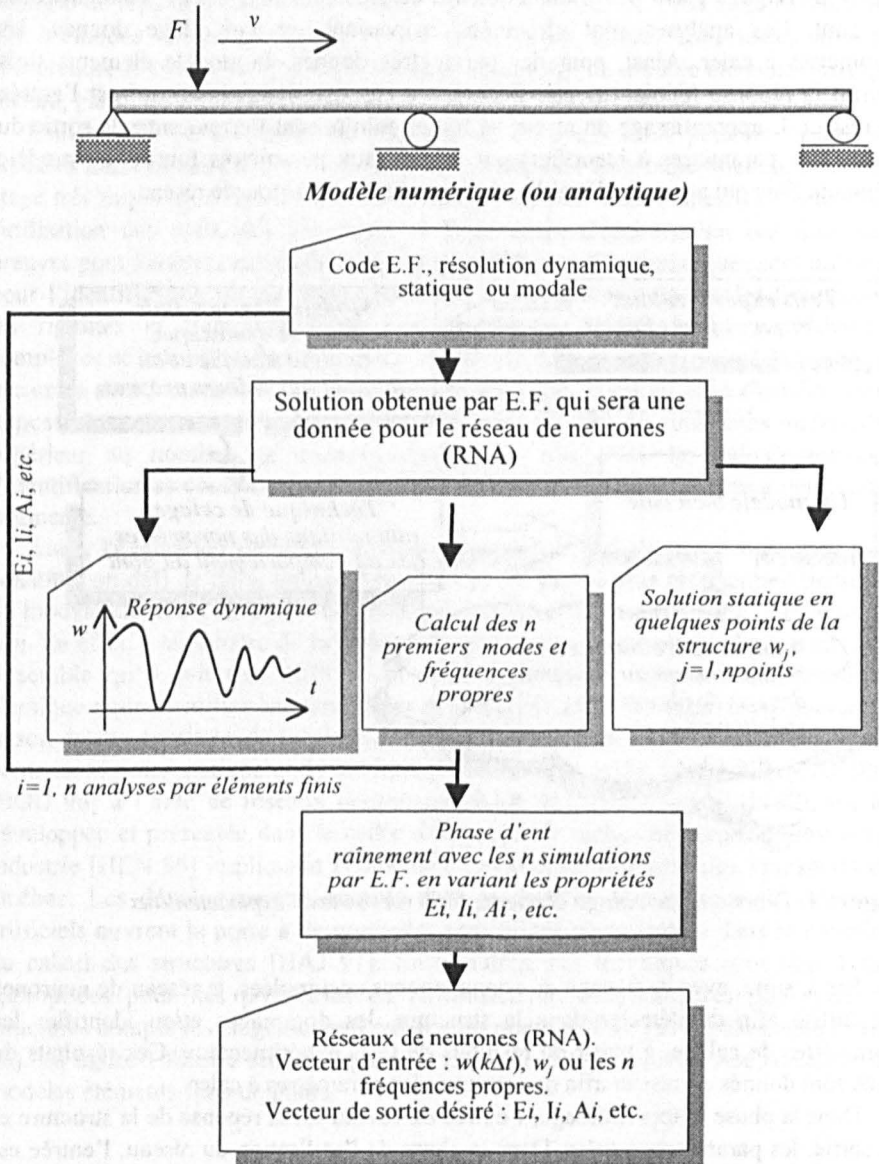


Figure 2. Phase d'apprentissage du réseau de neurones et démarche de résolution

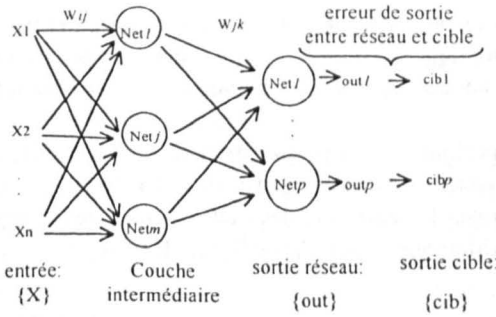


Figure 3. Exemple d'un RNA à algorithme à rétropropagation avec une couche intermédiaire




Figure 4. Neurone artificiel, $Net_i = W_{ji}X_j ; j=1, n$

- étape initiale : Données : $\{X_i\}, i=1, n ; \{Cib_i\}, i=1, p$

$n =$ nombre de neurones d'entrée

$p =$ nombre de neurones de sortie

$m =$ nombre de neurones de la couches intermédiaire nc

- choix aléatoire de $[W_{ij}]_{nc}$ entre -0.5 et $+0.5$ pour chaque couche nc

- étape d'apprentissage : $nc=1, nci$

- calcul des valeurs des potentiels des neurones de la couche nc

$$\{Net_k\}_{nc} = [W_{ij}]_{nc} \cdot \{X_i\} ; i=1, m_{nc}$$

- activation des potentiels par la fonction sigmoïde F

$$\{Out_k\}_{nc} = \{F(Net_k)\}_{nc} ; \text{avec}$$

$$F(Net_k) = 1/(1 + e^{-(Net_k + \theta_k)})$$

- calcul des potentiels des neurones de la couches de sortie $nc1$

$$\{Net_l\}_{nc1} = [W_{ij}]_{nc1} \{Out_k\}_{nc1} ; l=1, p \text{ et } \{Out_k\}_{nc1} = \{F(Net_k)\}_{nc1} ; \text{avec}$$

- Rétropropagation :

Calcul de l'erreur (méthode de gradient) entre la couche $nc1$ et la couche j

$$[\tilde{A}W_{ij}]_{j,nc1}^{t+1} = \zeta \{Out_k\}_{nc1} \langle d \rangle + \dot{a} [\tilde{A}W_{ij}]_{j,nc1}^t ; \langle d \rangle = \{(cib_k - out_k)(out_k)(1 - out_k)\}^T$$

Actualisation des valeurs des poids

$$[W_{ij}]_{j,nc1}^{t+1} = [W_{ij}]_{j,nc1}^t + [\tilde{A}W_{ij}]_{j,nc1}^{t+1}$$

Calcul de l'erreur entre la couche intermédiaire nc et la couche d'entrée

$$[\tilde{A}W_{ij}]_{j,nc}^{t+1} = \zeta \{X_k\}_{nc} \langle d^* \rangle + \dot{a} [\tilde{A}W_{ij}]_{j,nc}^t ; \langle d^* \rangle = \{(out_j)(1 - out_j)\}^T \text{ et } \{e\} = [W_{ij}]_{j,nc} \{d\}$$

Actualisation des valeurs des poids

$$[W_{ij}]_{j,nc}^{t+1} = [W_{ij}]_{j,nc}^t + [\tilde{A}W_{ij}]_{j,nc}^{t+1}$$

Test de convergence : l'algorithme continue jusqu'à ce que l'erreur entre la sortie et la cible soit respectée

Figure 5. Les différentes étapes de l'algorithme du RNA à rétropropagation

Chaque neurone reçoit une somme de poids W_{ij} des neurones de la couche précédente et se comporte comme une donnée d'entrée aux neurones de la couche suivante (figure 4). L'activation de chaque neurone est gouvernée par la fonction sigmoïde non linéaire (figure 5).

L'algorithme utilisé est appelé algorithme à rétro-propagation où l'erreur calculée à la sortie du réseau est propagée à travers les couches à partir de la couche de sortie pour la mise à jour des poids W_{ij} formant les éléments des matrices d'apprentissage (pour plus de détails sur l'aspect algorithmique voir [LAN 97], [BAR 95]).

3. Exemples d'application

Dans cet article, nous présentons les techniques d'application des réseaux neuronaux aux problèmes d'identification de paramètres dans les ponts. Trois exemples sont présentés.

Le choix des exemples d'apprentissage est effectué de la façon suivante. Les valeurs des paramètres d'identification des éléments susceptibles d'être endommagés sont variés, entre 10 % et 100 % des valeurs originales (sans endommagement). Dans tous les exemples les entrées et les sorties seront normalisées. Si u_o est une valeur du neurone i , u_o^{min} et u_o^{max} sont les valeurs minimale et maximale des neurones d'une telle couche, la quantité du neurone i normalisée est donnée par :

$$u_{o,nor} = (u_o - u_o^{min}) / (u_o^{max} - u_o^{min})$$

Cette normalisation doit être effectuée afin de maintenir des poids W_{ij} compris entre -1 et 1. La plupart des logiciels commerciaux se base sur une telle normalisation.

3.1. Détection de l'endommagement dans une poutre cantilever

Le premier exemple consiste en une poutre en béton endommagée encastree-libre, modélisée par des éléments finis avec formulation en rigidité dynamiques exacte [HEN 97a] pour identifier les paramètres EI et ρ de deux zones fissurées (figure 6). Les données sont:

$$L = 3.048 \text{ m}, I = 0.5 \times 10^{-7} \text{ m}^4, E = 2.1 \times 10^{11} \text{ N/m}^2, \rho = 275 \text{ kg/m}.$$




Figure 6. Poutre cantilever endommagée aux niveaux des éléments 1 et 3

La poutre est supposée endommagée par la réduction de la rigidité et de la masse de l'élément 1 et de l'élément 3. Les résultats des tests expérimentaux de la vibration de la poutre endommagée donnent les 5 premières pulsations propres (tableau 1). Les valeurs des rigidités et des masses des éléments endommagés (expérimentales) sont : élément 1 : $EI = 7,35 \times 10^6 \text{ Nm}^{-2}$, $\rho = 275 \text{ kg/m}$, élément 3 : $EI = 5,25 \times 10^6 \text{ Nm}^{-2}$, $\rho = 150 \text{ kg/m}$. Le but de cet exemple est d'identifier les paramètres EI et ρ des éléments endommagés par l'approche des réseaux neuronaux. On se sert seulement de quelques exemples par éléments finis exacts [HEN 97a] comme exemples d'apprentissage et des résultats expérimentaux comme exemple de test. Pour le choix des exemples d'apprentissage, la rigidité et la masse des éléments susceptibles d'être endommagés ont été changées. L'architecture du réseau de neurones utilisée est de la forme 5- n - m -4 où 5 représente le nombre de neurones d'entrée. Ce sont les 5 premières pulsations propres de la vibration libre de la poutre, notées par ω_i (tableau 1). Le chiffre 4 représente les neurones de sortie (cibles). Ce sont les 4 paramètres : EI_1 , ρ_1 , EI_2 et ρ_2 respectivement des éléments 1 et 3 (figure 7). Les variables n et m représentent le nombre de neurones des couches intermédiaires.

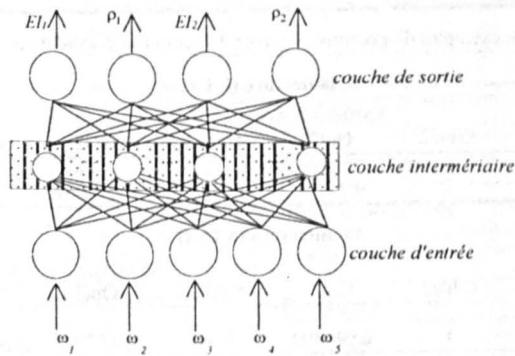


Figure 7. RNA à 3 couches avec 5 neurones dans la couche d'entrée et 3 neurones dans la sortie

Nous avons varié ici le nombre de couches intermédiaires et le nombre de neurones par couche pour un nombre de seize exemples d'apprentissage. Le tableau 2 présente les résultats. Les résultats obtenus de cet exemple sont généralement excellents, surtout pour les réseaux à deux couches intermédiaires (5-8-8-4). Or dans le cas de 6 exemples d'apprentissage qui n'est pas présenté dans cet article (voir [HEN 96]), les résultats sont moins bons. En règle générale, un bon choix du nombre d'exemples est primordial pour obtenir un bon réseau. Les exemples doivent être choisis d'une manière répartie et homogène pour éviter la concentration et la répétition des données. Les réseaux à une seule couche intermédiaire donnent des résultats acceptables, si on augmente le nombre de neurones intermédiaires jusqu'à un certain nombre optimal, qui dépend du nombre d'exemples d'apprentissage.

Neurones d'entrée					
	ω_5	ω_4	ω_3	ω_2	ω_1
Valeurs réelles	4100.5	2463.6	1248.6	425.00	69.046
Valeurs normalisées	0.62971	0.53351	0.64559	0.6066	0.8215
Neurones de sortie					
	EI_1	ρ_1	EI_2	ρ_2	
Valeurs réelles	7.3500×10^6	275.00	5.25×10^6	150.00	
Valeurs normalisées	0.67000	1.0000	0.45000	0.500	

Tableau 1. Poutre encastree-libre : résultats expérimentaux pour le test du réseau

16 exemples d'apprentissage avec 2 exemples de validation							
Architecture (5 4 4)							
Cible1	Out1	Cible2	Out2	Cible3	Out3	Cible4	Out4
0.67	0.748993	1	0.75491	0.45	0.413509	0.5	0.744
Architecture (5 10 4)							
Cible1	Out1	Cible2	Out2	Cible3	Out3	Cible4	Out4
0.67	0.738204	1	0.946194	0.45	0.357599	0.5	0.5689
Architecture (5 20 4)							
Cible1	Out1	Cible2	Out2	Cible3	Out3	Cible4	Out4
0.67	0.717315	1	0.935606	0.45	0.531201	0.5	0.6514
Architecture (5 25 4)							
Cible1	Out1	Cible2	Out2	Cible3	Out3	Cible4	Out4
0.67	0.676017	1	0.984134	0.45	0.43134	0.5	0.6262
Architecture (5 8 8 4)							
Cible1	Out1	Cible2	Out2	Cible3	Out3	Cible4	Out4
0.67	0.6608	1	0.976149	0.45	0.431603	0.5	0.5038

Tableau 2. Poutre encastree-libre endommagée : résultats obtenus du RNA

3.2. Poutre en T en béton

Le second exemple est une poutre en béton en forme de T sur appuis simples modélisée par des éléments de coques. Le maillage comporte 4 278 degrés de liberté, pour identifier les paramètres et les zones d'endommagement en comportement statique et en vibrations libres [LAN 97]. Les paramètres à identifier sont les modules de Young dans la zone centrale de l'âme de la poutre. Par symétrie, on prend comme inconnues les 7 modules de Young selon les isolignes de la cible sur la figure 8.

L'architecture du RNA est de la forme 4-(4)-(4)-7 avec 33 exemples d'apprentissage par éléments finis pour les analyses statiques et 73 exemples pour le calage sur les fréquences. Les entrées du réseau pour l'apprentissage sont respectivement les déplacements situés aux points $L/8$, $L/4$, $3L/8$ et $L/2$ pour les analyses en statique, et les quatre premières fréquences pour les analyses en vibrations libres. Le tableau 3 fournit les données de base pour l'apprentissage. Les facteurs d'apprentissage et d'oubli sont 0,05 et 0,9. D'après la figure 8, les résultats obtenus sont excellents et on remarque aussi qu'un RNA entraîné à partir des analyses statiques donne de meilleurs résultats que celui entraîné en se basant sur des analyses en vibrations libres.

<i>Analyse en vibrations libres</i>	
<i>Nombre de neurones d'entrée</i>	<i>4 premières fréquences</i>
<i>Nombre de neurones de sortie</i>	<i>7 modules de Young</i>
<i>Nombre d'exemples d'apprentissage</i>	<i>73 exemples</i>
<i>Facteurs d'apprentissage α et d'oubli γ</i>	<i>0.05 et 0.9</i>
<i>Architecture du réseau</i>	<i>4-(4)-(4)-7</i>
<i>Durée relative des analyses par E.F</i>	<i>1.0</i>
<i>Durée relative d'apprentissage du RNA</i>	<i>0.555</i>
<i>Analyse statique</i>	
<i>Nombre de neurones d'entrée</i>	<i>4 déplacements verticaux</i>
<i>Nombre de neurones de sortie</i>	<i>7 modules de Young</i>
<i>Nombre d'exemples d'apprentissage</i>	<i>33 exemples</i>
<i>Facteurs d'apprentissage α et d'oubli γ</i>	<i>0.05 et 0.9</i>
<i>Architecture du réseau</i>	<i>4-(4)-(4)-7</i>
<i>Durée relative des analyses par E.F</i>	<i>1.0</i>
<i>Durée relative d'apprentissage du RNA</i>	<i>0.60</i>

Tableau 3. Résultats obtenus avec un RNA des deux analyses de la poutre

Ceci est dû au fait qu'il manque des fréquences influençant d'une manière significative la vibration de la partie endommagée. Il apparaît important de vérifier, à ce stade-ci, des analyses si la méthode des réseaux de neurones donne des résultats suffisamment précis pour répondre aux objectifs recherchés. Il est essentiel que les résultats d'une analyse en fréquence par exemple puissent être utilisés pour mener des analyses statiques sans qu'il y ait une trop grande dégradation de la précision des calculs. Les déflexions calculées pour les modules élastiques calés à partir des analyses en fréquences sont comparées aux déflexions théoriques. De même, les fréquences obtenues à partir des modules élastiques calés sur des analyses statiques sont comparées aux fréquences théoriques. L'erreur maximale se situe au niveau de la première fréquence et est inférieure à 0,5 %.




Figure 8. Résultats obtenus à partir d'un RNA représentés par des isolignes

3.3. Pont de Senneterre

Comme première application réelle d'un réseau neuromimétique sur une structure, un pont en béton armé ayant cinq poutres longitudinales a été choisi. Ce pont, situé à Senneterre, province de Québec, Canada, est simplement appuyé à ses extrémités et renforcé aux appuis par des poutres de rigidité de 300 mm x 300 mm (figure 9).

L'évaluation visuelle du pont montre des mécanismes d'appuis en bonnes conditions de même qu'un état général peu endommagé. Le pont a une portée de 22,289 m et une largeur de 12,575 m. Les poutres d'inertie constante, ont une hauteur de 1,580 m, une épaisseur de 45 mm et sont espacées de 2,590 m. Le tablier du pont a 190 mm d'épaisseur à laquelle s'ajoute 70 mm de bitume. Pour les besoins de l'analyse, les modules de Young sont supposés symétriques par rapport à l'axe longitudinal du pont. En outre, les modules élastiques sont considérés uniformes en tous points d'une même membrure. Ainsi, ces modules sont déterminés pour le tablier du pont (E_1), les poutres de rives (E_2), la poutre centrale (E_3) et les poutres intermédiaires (E_4). Le pont étant peu endommagé, des modules élastiques variant entre 18 000 MPa et 30 000 MPa ont été considérés possibles.

L'entraînement du réseau neuronal a été effectué, dans un premier temps, à l'aide de 175 combinaisons de modules élastiques dans les quatre zones du pont (figure 9), chaque exemple d'apprentissage étant formé d'une combinaison de modules élastiques et des fréquences correspondant à ces modules élastiques.

<i>Nombre de neurones d'entrée</i>	<i>3 premières fréquences</i>
<i>Nombre de neurones de sortie</i>	<i>4 modules de Young</i>
<i>Nombre d'exemples d'apprentissage</i>	<i>175, 32 exemples</i>
<i>Facteurs d'apprentissage α et d'oubli γ</i>	<i>0.05 et 0.9</i>
<i>Architecture du réseau</i>	<i>3-(10)-(10)-4 3-(3)-(4)-4</i>
<i>Durée relative des analyses par E.F</i>	<i>1.0</i>
<i>Durée relative d'apprentissage du RNA</i>	<i>0.21, 0.125</i>

Tableau 4. Caractéristiques et données du RNA utilisées dans l'exemple du pont de Senneterre




Figure 9. Section transversale et modèle éléments finis du pont de Senneterre

Les modes retenus pour l'entraînement du réseau sont ceux détectés expérimentalement, soit les modes 1, 3 et 5 (tableau 5). Aux exemples d'apprentissage s'adjoignent 6 exemples de validation pour éviter le phénomène de sur-apprentissage (figure 10).

Les 181 analyses par éléments finis servant à générer la base de données d'apprentissage ont duré près de 120 minutes sur un Pentium 75.

Différents réseaux à une, deux et même trois couches intermédiaires ont été utilisés, les meilleurs résultats étant obtenus avec des réseaux à deux ou trois couches intermédiaires. L'apprentissage des réseaux à deux couches intermédiaires étant beaucoup plus rapide (par un facteur 2 parfois), ces derniers ont été privilégiés. Dans le cas présent, l'architecture présentant le meilleur compromis entre précision (erreur d'apprentissage) et temps de calcul est 3-(10)-(10)-4 soit un réseau à deux couches intermédiaires comportant 10 neurones chacune. Le temps de calcul requis pour l'entraînement du réseau est de l'ordre de 25 minutes et le nombre de cycles d'apprentissage d'environ 60 000.




Figure 10. Courbes d'erreurs moyennes d'apprentissage et de validation en fonction du nombre d'itérations (phénomène de sur-apprentissage)

Il est intéressant d'étudier, à ce stade-ci, l'effet du nombre d'exemples d'apprentissage sur les résultats. Pour ce faire, seuls 32 exemples d'apprentissage des 175 utilisés précédemment sont conservés ce qui constitue, avec les 6 exemples de validation, la nouvelle base de données d'apprentissage. Encore ici, les combinaisons de modules élastiques constituant la base de données d'apprentissage doivent englober le cas réel. Le temps de calcul des analyses par éléments finis, pour les 32 exemples d'apprentissage et les 6 exemples de validation, est estimé à 30 minutes. Le réseau neuronal proposant la convergence optimale est composé de 2 couches intermédiaires de 3 et 4 neurones respectivement.

L'entraînement du réseau a nécessité quelques 40 000 itérations sur la base de données d'apprentissage, les temps de calcul requis étant de 10 minutes.

Les résultats obtenus de ce réseau neuronal sont plus logiques d'un point de vue pratique. En effet, les poutres de rives d'un pont sont plus sollicitées que les autres poutres et sont donc sujettes à un endommagement plus prononcé. Cette remarque est aussi valable lorsque les poutres intermédiaires sont comparées à la poutre centrale.

En se basant sur la signification physique des fréquences et des modes de vibration, il apparaît essentiel, pour bien caler les propriétés des matériaux à divers endroits d'un pont, que les premières fréquences de chacun des modes de vibration soient détectées expérimentalement. En effet, alors que la première fréquence de flexion longitudinale permet de déterminer la rigidité moyenne des poutres et du tablier et que le mode de flexion transversale permet de départager la rigidité de la dalle de celles des poutres, c'est le mode de torsion qui permet de distinguer les poutres les unes des autres.

<i>Résultats obtenus par le RNA pour :</i>	<i>175 exemples d'apprentissage</i>	<i>32 exemples d'apprentissage</i>
<i>Module élastique de la dalle E_1</i>	<i>29 335 MPa</i>	<i>29 060 MPa</i>
<i>Module élastique des poutres de rives E_4</i>	<i>20 252 MPa</i>	<i>20 176 MPa</i>
<i>Module élastique des poutres internes E_3</i>	<i>24 810 MPa</i>	<i>25 670 MPa</i>
<i>Module élastique de la poutre centrale E_2</i>	<i>27 986 MPa</i>	<i>28 3696 MPa</i>
<i>Les trois premières fréquences (flexion long., flexion trans. et flexion trans.) (Hz)</i>	<i>4.8, 7.6 et 11.7</i>	<i>4.8, 7.6 et 11.7</i>

Tableau 5. Résultats obtenus par le RNA pour deux cas d'apprentissage pour le pont de Senneterre (architecture du réseau est 3-(10)-(10)-4)

Les résultats du réseau entraîné avec 175 exemples d'apprentissage présentés au tableau 4 présentent un module de Young moyen pour les cinq poutres de 23 622 MPa. Il est possible d'établir une combinaison de modules de Young moyen de 23 622 MPa mais où la poutre centrale est plus endommagée que les poutres intermédiaires qui sont, elles, plus endommagées que les poutres de rives. Par exemple, la combinaison présentée au tableau 6 permet d'obtenir des fréquences similaires à celles obtenues des tests. Les fréquences associées à cette dernière combinaison sont présentées au tableau 7 avec celles calculées à partir des résultats du réseau neuromimétique entraîné avec 175 exemples d'apprentissage. Il apparaît, sur ce tableau, que la différence entre la combinaison présentée au tableau 6 et celle présentée au tableau 5 se situe principalement au niveau du mode de torsion.

<i>Zone</i>	<i>E (MPa)</i>
<i>Tablier (E_1)</i>	<i>29 335 MPa</i>
<i>Poutre centrale (E_2)</i>	<i>18 000 MPa</i>
<i>Poutres intermédiaires (E_3)</i>	<i>24 000 MPa</i>
<i>Poutres de rives (E_4)</i>	<i>26 000 MPa</i>

Tableau 6. Modules de Young utilisés pour le calcul de la première fréquence de torsion

Mode	f (données du RNA avec 175 exemples)	f (données du tableau 6)	Type de mode
1	4.8 Hz	4.8 Hz	Flexion longitudinale
2	5.9 Hz	6.2 Hz	Torsion
3	7.6 Hz	7.5 Hz	Flexion transversale
4	11.7 HZ	11.8 Hz	Flexion transversale

Tableau 7. Fréquences calculées à partir de la combinaison de modules de Young présentée au tableau 5 et fréquences calculées à partir de la combinaison de modules de Young présentée au tableau 6

4. Conclusion

D'après les résultats obtenus, le réseau multicouche à rétropropagation semble très bien adapté au domaine d'identification de l'endommagement dans les structures et les résultats sont prometteurs. Nous avons étudié l'efficacité des architectures des réseaux. Généralement, les réseaux avec deux couches intermédiaires donnent de meilleurs résultats qu'avec une ou zéro couche intermédiaire.

Le nombre de neurones des couches internes dépend en général du nombre d'exemples d'apprentissage, car l'ajustement des coefficients ou des poids W_{ij} dépend du nombre d'exemples d'apprentissage.

Parmi les avantages de cette méthode, on cite : la non-limitation dans le choix du nombre de paramètres à identifier, un minimum de mesures expérimentales sur site nécessaire pour caler les paramètres et le couplage facile de l'algorithme avec n'importe quel logiciel commercial d'éléments finis. Enfin, l'apprentissage du RNA permet le stockage des données sous forme d'une signature du pont pour identifier les zones de détérioration au cours des années suivantes.

La méthode, bien que très performante, n'est pas une méthode miracle car elle est très sensible aux données manquantes comme, par exemple, la première fréquence de torsion du pont de Senneterre (section 3.3). Pour éviter de tels problèmes, la connaissance de données alternatives est un atout non négligeable. Dans le cas du pont de Senneterre, des mesures de déplacements statiques auraient sans doute permis un meilleur calage des constantes du matériau. Contrairement aux méthodes déterministes, la méthode des réseaux neuromimétiques est indépendante de la physique du problème, plusieurs types de mesures pouvant ainsi être combinés sans pour autant augmenter la complexité des calculs. Enfin, la méthode permet de caler un nombre quelconque de paramètres sans qu'il y ait nécessairement un nombre égal ou supérieur de données d'entrée pour y parvenir.

L'architecture des réseaux à deux couches intermédiaires est optimale pour un nombre de poids W_{ij} à calibrer à peu près égal au nombre d'exemples d'apprentissage avec une distribution uniforme des neurones dans chaque couche intermédiaire. Dans le cas de réseaux à une seule couche intermédiaire, le nombre de neurones requis dans la couche intermédiaire est à peu près égal à la somme du nombre d'entrées et du nombre de sorties. Ces guides ne doivent pas être vus

comme une règle précise mais comme une base pour débiter la recherche de la configuration optimale du réseau neuromimétique.

Mentionnons pour terminer que cette technique a été appliquée avec succès à l'identification des paramètres d'amortissement via un modèle viscoélastique à partir de tests en vibrations libres pour lesquels, en plus des fréquences, les déplacements en fonction du temps avaient été enregistrés [BOU 97], [FAF 97].

5. Bibliographie

- [AKO 97] AKOUSSAH E., FAFARD M., TALBOT M., BEAULIEU D. (1997). "Étude paramétrique du facteur d'amplification dynamique des charges pour les ponts à travée simple en béton armé". *Revue canadienne de génie civil*, Vol. 24(2), pp.313-322.
- [BAR 95] BARAI S. V., PANDEY P. C. (1995). "Vibration Signature Analysis Using Artificial Neural Networks", *ASCE, J. of Comp. Civil Engng.* 9, 259-265.
- [BOU 96] BOUDJELAL M.T., FAFARD M. & GAKWAYA A. (1996). "Modelling of Damping and its Applications to Dynamic Bridge-Vehicle Interaction", Proceedings of 3rd European Conference on Structural Dynamics (EURODYN), Ed. by G. Augusti et al. (Published by Balkema, Rotterdam), Florence, Italie, 5-8 Juin, pp 767-774.
- [BOU 97] BOUDJELAL M.T., FAFARD M., GAKWAYA A. (1997). "Modélisation de l'amortissement par une approche thermodynamique et son application à l'interaction dynamique pont-véhicules", Rapport GCS-97-10, GIREF et Dép. de Génie civil, Université Laval, Québec.
- [FAF 97] FAFARD M., BOUDJELAL M.T. (1997). "Modélisation de l'amortissement dans les structures". Actes du troisième colloque national en calcul des structures, 20-23 mai, Giens, France, Presses Académiques de l'ouest, Vol. I, pp. 113-118.
- [FAF 98] FAFARD M., LAFLAMME M., SAVARD M., BENNUR M. (1998). "Dynamic analysis of an existing continuous bridge", *ASCE, J. of Bridge Eng.* (in press).
- [HAJ 91] HAJELA P., BERKE L. (1991). "Neurobiological Computational Models in Structural Analysis and Design", *Comp. & Struct.*, Vol. 41(4), 657-667.
- [HEN 95] HENCHI K. (1995). "Analyse dynamique des ponts par éléments finis sous la sollicitation des véhicules mobiles", Thèse de doctorat, Université de Technologie de Compiègne, France.
- [HEN 96] HENCHI K., FAFARD M. (1996). "Identification paramétrique des ponts en comportements statique et dynamique avec l'utilisation des réseaux neuronaux artificiels", Rapport GCS-96-07, Dép. de Génie civil. Université Laval, Québec.
- [HEN 97a] HENCHI K., DHATT G., TALBOT M., FAFARD M. (1997). "Dynamic Behaviour of Multi-span Beams Under Moving Loads", *Journal of Sound and Vibration.*, Vol. 199(1), pp. 33-50.
- [HEN 97b] HENCHI K., FAFARD M., TALBOT M., LANGIS D. (1997). "L'application des réseaux neuronaux artificiels pour l'identification et la détection de l'endommagement dans les ponts". Actes du troisième colloque national en calcul des structures, 20-23 mai, Giens, France, Presses Académiques de l'Ouest, Vol. II, pp. 831-836.
- [LAN 97] LANGIS D., FAFARD M., HENCHI K. (1997). "Identification structural et réseaux neuromimétiques : calibration de modèles éléments finis", Rapport GCS-97-09, GIREF et Dép. de Génie civil, Université Laval, Québec.
- [LIP 87] LIPPMANN R. P. (1987). "An introduction to computing with neural nets", *IEEE ASSP Magazine*, 4-22, avril.