

Surveillance de la santé structurale par apprentissage profond basé sur la matrice de covariance de la réponse temporelle stochastique

Rafic J. FADDOUL¹, Alaa CHATEAUNEUF^{2,3}

¹ Centre Libanais d'études et de recherches de la construction, Faculté d'ingénierie, Ecole Supérieure d'Ingénieurs de Beyrouth (ESIB), Université Saint-Joseph de Beyrouth, Beyrouth, Liban, rafic.faddoul@usj.edu.lb

² CIDECO, 2 avenue Blaise Pascal, Campus scientifique des Cézeaux, 63170 Aubière Cedex, alaa.chateauneuf@cideco.tech

³ Université Clermont Auvergne, Clermont-Auvergne-INP, Institut Pascal, 63000 Clermont-Ferrand, alaa.chateauneuf@uca.fr

RESUME

Cet article propose une approche innovante pour l'identification des désordres structuraux au sein des infrastructures de génie civil, soumises aux excitations ambiantes stochastiques. L'ouvrage est modélisé par éléments finis, afin de permettre la création de la base de données, comprenant les rigidités aléatoires des éléments, d'une part, et les matrices de covariance correspondantes, d'autre part. Ces matrices de covariance sont calculées à partir de la réponse temporelle de la structure sous les conditions normales de trafic.

L'ensemble d'apprentissage permet l'entraînement du réseau de neurones, qui est composé de six couches convolutives suivies de deux couches totalement connectées. Etant entraîné et validé, ce réseau de neurones permet l'identification, la localisation et la quantification des désordres dans l'ouvrage.

La capacité prédictive du modèle est démontrée au moyen de l'analyse du pont de Longues au département du Puy-de-Dôme, sous différentes conditions de trafic et d'ampleur des désordres. Les résultats montrent le grand potentiel du modèle élaboré dans la surveillance de la santé structurale.

Mots-clés : surveillance, santé structurale, détection de défauts structuraux, réseau de neurones convolutif, apprentissage profond.

I. INTRODUCTION

Au cours du temps, le domaine de l'optimisation des processus d'inspection, de maintenance et de rénovation (IM&R) a connu un développement considérable, donnant naissance à de nombreuses approches scientifiques innovantes. L'engouement pour ce secteur ne cesse de croître, alimenté par

plusieurs facteurs convergents, tels que : (i) l'évolution constante des technologies de calcul et d'instrumentation ; (ii) la nécessité croissante de gérer efficacement les infrastructures de génie civil vieillissantes ; (iii) la recherche de solutions durables et respectueuses de l'environnement ; et (iv) la reconnaissance, tant par les professionnels que par le grand public, de l'importance des données et des méthodes d'analyse associées pour éclairer les prises de décision.

Assurer la fiabilité des structures existantes est d'une importance cruciale pour garantir leur intégrité, leur durabilité et leur sécurité. En effet, dans de nombreux domaines, notamment les bâtiments et les infrastructures de génie civil, la détection précoce des défauts structuraux permet de prévenir les accidents potentiels, d'optimiser la maintenance et de réduire les coûts de réparation.

Par conséquent, la surveillance en temps réel et la détection des défauts structuraux jouent un rôle clé dans la gestion proactive des risques associés aux défaillances potentielles. Dans ce contexte, cet article propose une méthodologie basée sur les réseaux neuronaux pour identifier les défauts dans les structures soumises aux excitations ambiantes (i.e. charges naturelles ou opérationnelles, telles que le vent, le trafic,...). L'ensemble d'apprentissage du réseau de neurones (RN) sera employé en utilisant la modélisation par éléments finis (EF) et les matrices de covariance.

II. METHODOLOGIES DE SURVEILLANCE

Les méthodologies de surveillance de la santé structurale (structural health monitoring SHM en anglais) peuvent être classées en deux catégories principales : locales et globales.

Les méthodologies de SHM locale se concentrent sur l'évaluation et la surveillance de zones spécifiques ou de composants individuels d'une structure. Elles utilisent des capteurs et des techniques d'inspection dédiés pour détecter et quantifier les défauts et les dommages à l'échelle locale, tels que les fissures, la corrosion ou la dégradation des matériaux. Les méthodes de SHM locale sont généralement très précises et offrent une résolution élevée, car elles sont spécifiquement conçues pour évaluer des problèmes particuliers ou des zones d'intérêt bien déterminées (Kralovec & Schagerl, 2020). Cependant, elles peuvent être coûteuses et difficiles à mettre en œuvre à grande échelle, en particulier sur les grandes infrastructures.

Les méthodologies de SHM globale visent, en revanche, l'évaluation de l'état général d'une structure dans son ensemble (Doebling, Farrar, & Prime, 1998). Plutôt que de se concentrer sur des zones spécifiques ou des composants individuels, les méthodes de SHM globale utilisent des capteurs et des techniques d'analyse qui permettent de surveiller l'état de la structure, en tenant compte des interactions entre ses différents éléments. Les méthodologies de SHM globale sont généralement moins coûteuses et plus faciles à mettre en œuvre à grande échelle, car elles nécessitent moins de capteurs et d'équipements spécialisés (Farrar & Worden, 2007). Cependant, elles peuvent être moins précises et moins sensibles aux petits défauts ou dommages localisés (Sohn et al. 2003).

En fonction des besoins spécifiques d'un projet de surveillance, il peut être nécessaire d'adopter une combinaison des méthodes locales et globales pour obtenir une image complète de l'état de la structure (Carden & Fanning, 2004, Balasubramaniam, 2023). La sélection des capteurs, des techniques de mesure doit aller de pair avec le choix et le développement des algorithmes

d'analyse appropriés pour tout système de SHM, qu'il soit local ou global (Brownjohn, 2007, Lynch & Loh, 2006).

Faddoul et al. (2013) ont proposé une méthodologie d'Inspection-Maintenance et Réparation (IM&R) intégrant les réseaux bayésiens dans un processus de décision markovien partiellement observable. L'objectif de cette approche est de pouvoir prendre en compte, de manière dynamique, les informations pertinentes sur le processus de détérioration. Ces informations peuvent provenir des conditions météorologiques, des sollicitations enregistrées par un système de capteurs sur la structure et/ou des états de condition des éléments observés sur une structure similaire. Cette méthodologie vise à améliorer la prise de décision en matière d'IM&R en tenant compte des données en temps réel et en adaptant les actions de maintenance et de réhabilitation en conséquence. En s'appuyant sur des recherches intégrant les arbres de décision dans un cadre de programmation dynamique visant à optimiser les décisions IM&R relatives aux structures de génie civil (Faddoul et al., 2011, 2013, 2015), Geara et al. (2020) ont proposé une approche bayésienne pour actualiser les distributions de probabilité concernant les éléments structuraux en fonction des données fournies par les capteurs. Cette approche bayésienne permet de prendre en compte de manière précise les incertitudes et les variations associées aux informations collectées par les capteurs, en mettant à jour les distributions de probabilité à mesure que de nouvelles données sont disponibles.

III. METHODOLOGIE PROPOSEE

La méthodologie proposée est décrite sur la figure 1. Elle s'appuie sur la modélisation de la structure par éléments finis (EF), afin de permettre l'apprentissage du réseau de neurones profond. Les accélérations aux nœuds, correspondant aux capteurs sur la structure réelle, sont évaluées sous l'effet d'une excitation ambiante stochastique (i.e. trafic aléatoire). Dans cette démarche, nous admettons que le désordre structural sur un élément se traduit par une perte de rigidité de cet élément, c'est-à-dire que nous modélisons un défaut par la diminution relative du module d'élasticité de l'élément (ce qui est équivalent à la diminution de sa rigidité).




FIGURE 1. Méthodologie d'apprentissage profond pour l'identification de l'ouvrage.

Le comportement de la structure peut être décrit par l'équation :

$$\mathbf{a}(t) = \mathbf{M}(\mathbf{E}, \mathbf{L}(t)) \quad (1)$$

où $\mathbf{a}(t)$ est le vecteur accélération en fonction du temps des nœuds obtenu de la structure, \mathbf{M} représente la fonction de transfert de la structure, \mathbf{E} est le vecteur des modules de Young des éléments et $\mathbf{L}(t)$ est un vecteur aléatoire qui représente l'excitation stochastique ambiante à laquelle la structure est soumise.

Étant donné que les accéléromètres couramment utilisés dans la pratique sont numériques avec un taux d'échantillonnage fini t_e et pour une durée du signal finie T , le vecteur $\mathbf{a}(t)$ sera remplacé par une matrice \mathbf{A} de dimensions $S \times N$, où S est le nombre de capteurs et N est le nombre de points échantillonnés dans le temps, qui est égal à : $N = t_e \times T$.

$$\mathbf{A} = \mathbf{M}(\mathbf{E}, \mathbf{L}(t)) \quad (2)$$

Les matrices de covariance, pour un décalage temporel τ , sont exprimées par :

$$(c_{i,j}(\tau))_{\substack{i=1\dots S, \\ j=1\dots S}} = (a_{i,j})_{\substack{i=1\dots S, \\ j=1\dots N-\tau}} \times \left((a_{i,j})_{\substack{i=1\dots S, \\ j=\tau\dots N}} \right)^T \quad (3)$$

Grâce au modèle EF, nous pouvons simuler la réponse vibratoire de la structure soumise à l'excitation ambiante. La réponse vibratoire simulée sera exprimée par :

$$\mathbf{A}_{sim} = M_{ef}(\mathbf{E}, \mathbf{L}_{sim}(t)) \quad (4)$$

où \mathbf{A}_{sim} est la matrice accélération simulée, M_{ef} est le modèle éléments finis de la structure et \mathbf{L}_{sim} est l'excitation ambiante simulée. Les matrices de covariance décalées seront alors exprimées par :

$$(c_{i,j}^{sim}(\tau))_{\substack{i=1\dots S, \\ j=1\dots S}} = (a_{i,j}^{sim})_{\substack{i=1\dots S, \\ j=1\dots N-\tau}} \times \left((a_{i,j}^{sim})_{\substack{i=1\dots S, \\ j=\tau\dots N}} \right)^T \quad (5)$$

Notre objectif est de construire un ensemble d'apprentissage artificiel où chaque point de données (attributs) sera représenté par un ensemble de matrices de covariance pour un intervalle de valeurs de τ . Les étiquettes correspondantes seront les vecteurs représentant les rigidités des éléments de la structure.

Les matrices de covariance décalées sont retenues comme attributs pour l'analyse dynamique opérationnelle des structures soumises à une excitation ambiante stochastique, car elles contiennent l'essentiel de l'information modale et permettent ainsi de réduire l'impact du bruit de mesure. En effet, en calculant la corrélation entre les sorties des différents capteurs, il est possible de moyennner le bruit et d'obtenir un signal plus clair représentant la véritable réponse structurale. Ainsi, ces matrices garantissent la robustesse face aux données non stationnaires, qui sont souvent présentes dans les scénarii réels, puisqu'elles se focalisent sur les relations entre les capteurs plutôt que sur la réponse directe des capteurs individuels. De plus, leur calcul est rendu efficace grâce à l'utilisation de la transformée de Fourier rapide (FFT), ce qui réduit la charge computationnelle et permet une analyse plus réalisable pour des applications à grande échelle en temps réel.

A. Construction d'un ensemble de données d'apprentissage

Dans notre méthodologie, le jeu de données d'apprentissage est composé de paires de configurations de rigidité et de signaux temporels d'accélération aux points prédéfinis de la structure (i.e. positions des capteurs). Pour ce faire, nous faisons appel à un modèle éléments finis

qui prend, en entrée, une combinaison spécifique des rigidités des éléments, et produit, en sortie, les accélérations aux emplacements des capteurs, aux pas de temps discrétisés.

Pour réaliser le calcul dynamique, un chargement stochastique est appliqué au modèle éléments finis, afin de simuler l'excitation ambiante à laquelle la structure est soumise. Bien que notre approche ne calcule pas explicitement les paramètres modaux de la structure et que nous opérons dans le domaine temporel, nous émettons l'hypothèse que la majorité des informations utiles du signal est constituée par les données modales. Par conséquent, les valeurs spécifiques des différents paramètres de simulation doivent être déterminées de manière à collecter le maximum d'informations modales contenues dans le signal initial.

Afin d'éviter l'*aliasing* (i.e. répliques du spectre), le taux d'échantillonnage, conformément au théorème de Nyquist, doit être le double de la plus grande fréquence propre mesurable de la structure. De plus, une durée de simulation suffisante doit être choisie pour garantir une résolution adéquate du contenu fréquentiel. De façon similaire, il convient d'ajuster l'incrément du décalage temporel τ de manière à ce qu'il soit aussi fin que possible, en cohérence avec les considérations relatives au taux d'échantillonnage. Par ailleurs, il est important de choisir une étendue de τ suffisamment longue, en accord avec les raisons évoquées pour la durée de simulation.

B. Réseaux de neurones convolutifs :

Lorsque les matrices de corrélation sont utilisées comme caractéristiques d'apprentissage, notamment lorsque l'étendue de τ est longue, l'application d'un réseau de neurones entièrement connecté (FCN) peut soulever des problèmes de mémoire et de complexité de calcul. En effet, dans les FCN, chaque neurone doit être connecté à tous les autres neurones des couches adjacentes, ce qui engendre un nombre considérable de paramètres à apprendre et à stocker en mémoire.

Dans notre cas, la taille des données d'entrée est de $S \times S \times N$, S étant le nombre de capteurs utilisés et N le nombre de décalages temporels retenus. En considérant une seule couche cachée de taille H , le nombre total de paramètres serait de $S \times S \times N \times H$, sans inclure les biais. Ceci équivaut à plusieurs millions de paramètres. Par contre, les réseaux de neurones convolutifs (CNN) permettent de réduire considérablement le nombre de paramètres à apprendre par rapport aux FCN, grâce à l'utilisation de filtres (ou noyaux) pour réaliser des convolutions locales sur les données d'entrée.

Dans un CNN, pour chaque couche convolutive, sont associés K filtres de taille $F \times F$; F étant le paramètre de filtrage des données, choisi généralement entre 1 et 5. Ces filtres balayent les cartes d'activations qui sont un espace tridimensionnel de hauteur H , longueur L et de profondeur K . F est généralement beaucoup plus petite que H et L . Ainsi, pour chaque couche convolutive le nombre total de paramètres est égal à $F \times F \times K$, sans inclure les biais. Par conséquent, le nombre de paramètres à apprendre est indépendant de la taille des données d'entrée et dépend uniquement de la taille du filtre et du nombre de filtres.

Les matrices de covariance décalées dans le temps représentent les dépendances temporelles entre différentes mesures des capteurs. Un CNN permet de caractériser ces dépendances aux différents niveaux de complexité et d'abstraction, de manière hiérarchique. Dans les couches inférieures du CNN, les filtres convolutifs apprennent à reconnaître des motifs simples et locaux dans les matrices de covariance. Ces motifs peuvent correspondre à des dépendances à court terme

entre les mesures des capteurs, identifiant les structures temporelles de base. Au fur et à mesure que l'information se propage à travers les couches supérieures du CNN, ces caractéristiques simples sont combinées et agrégées pour représenter des structures temporelles plus complexes et globales. Les couches supérieures sont capables de représenter les dépendances à long terme et les relations complexes entre les mesures des capteurs.

La normalisation des entrées joue un rôle important dans la préparation des données pour l'entraînement des réseaux de neurones, en particulier lorsque les données d'entrée ont une structure complexe. Pour nos besoins, la forme des données d'entrée est similaire à celle d'une image ayant S canaux de couleur différents, une hauteur S et une largeur N . En mettant les données d'entrée à une échelle comparable, plusieurs avantages sont obtenus. Premièrement, cela permet une convergence plus rapide de l'algorithme d'optimisation en réduisant les oscillations et les mises à jour des pondérations pendant la rétropropagation. Deuxièmement, cela améliore la stabilité numérique du modèle en évitant des valeurs extrêmes d'activation et de gradient, susceptibles de provoquer des problèmes tels que la saturation des neurones et le phénomène de disparition ou d'explosion des gradients.

Nous effectuons aussi une normalisation par lots après chaque couche neuronale. Cette méthode normalise les activations des couches intermédiaires pendant l'entraînement, ce qui permet une meilleure propagation des gradients, une convergence plus rapide et une plus grande stabilité du modèle. Il convient de souligner que la normalisation des données d'entrée et la normalisation par lots ont des objectifs légèrement différents. Alors que la normalisation des données d'entrée vise à homogénéiser les différentes dimensions d'entrée (i.e. la normalisation est effectuée entre les colonnes des données), la normalisation par lots, quant à elle, s'effectue sur les lignes d'un lot.

IV. APPLICATION NUMERIQUE

Le pont de Longues (Fig 2) se trouve au niveau de la route départementale D225 en sortie de Vic-Le-Comte. Il s'agit d'un pont à caisson en béton précontraint inauguré en 1971, d'une longueur totale de 160 m entre les culées.




FIGURE 2. Pont de Longues : profil de l'ouvrage et emplacement des capteurs.

Un total de 24 capteurs sont installés sur le pont de Longues, sur la partie basse du caisson, au niveau de l'âme centrale des deux alvéoles. Les capteurs C1 à C6 sont situés sur la travée rive gauche du pont avec un espacement de 6,24 m. Le capteur C7 se trouve au droit de la pile P1. Les capteurs C8 à C20 sont situés sur la travée centrale du pont avec un espacement de 6,64 m. Le capteur C21 se trouve au droit de la pile P2. Les capteurs C22 à C24 sont situés sur la travée rive droite du pont avec un espacement de 6,24 m. Ces capteurs sont capables de mesurer les accélérations et les inclinaisons des éléments, dans les trois dimensions, ainsi que la température ambiante et l'orientation du capteur par rapport au nord magnétique.

Pour l'application numérique dans cette étude, nous utilisons seulement 5 capteurs pour valider les algorithmes, à savoir les capteurs C3, C5, C12, C17 et C24. Ces capteurs ont été choisis de manière arbitraire, sans recourir à une procédure d'optimisation qui aurait été appropriée si le maître d'ouvrage avait décidé d'installer uniquement 5 capteurs. De plus, nous utilisons uniquement la composante verticale des mesures obtenues à partir de ces capteurs, sans tenir compte de la température ambiante. La performance du modèle peut être considérablement améliorée lorsque ces informations sont prises en compte, mais nous nous limitons, dans cette étude, à l'évaluation de la capacité discriminatoire des vibrations verticales pour l'identification, la localisation et l'évaluation des désordres structuraux.

Dans cette application, les fréquences propres pertinentes de la structure sont inférieures à 25 Hz. Selon le théorème de Nyquist, le taux d'échantillonnage doit être au moins deux fois supérieur à la plus grande fréquence dans le signal, pour éviter l'aliasing. Pour cela, nous avons adopté un taux d'échantillonnage de 50 Hz lors de la création de l'ensemble d'apprentissage.

La figure 3 montre un échantillon d'accélérations obtenues lors du passage des véhicules. La base de données d'apprentissage est réalisée avec des vitesses moyennes de trafic allant de 50 à 150 km/h ; la vitesse réglementaire sur la route nationale étant égale à 80 km/h. Le pourcentage de poids lourds a été fixé à 15% par rapport au nombre total de véhicules. Des tests numériques préliminaires ont montré que l'efficacité du réseau était significativement compromise si les signaux utilisés lors de la validation étaient dus à des véhicules roulant à des vitesses en dehors de la plage considérée pour l'ensemble d'apprentissage. Selon ces tests, le réseau était relativement robuste aux variations du pourcentage des poids lourds.




FIGURE 3. Accélérations obtenues à différents capteurs.

Le taux d'incrément du décalage temporel τ a été aussi choisi à 50 Hz. La longueur du signal est fixée à 2000 secondes (soit 33 minutes) qui donne une résolution de fréquence égale à :

$$\Delta f = \frac{1}{T} = \frac{Fs}{N} = 0,025 \text{ Hz} \quad (6)$$

Bien que l'on puisse croire qu'une telle résolution en fréquence paraît excessivement précise, nous avons eu besoin de 2000 secondes comme durée du signal, car nous estimons les matrices de corrélation en supposant l'ergodicité du signal, c'est-à-dire que nous effectuons une moyenne temporelle plutôt qu'une moyenne d'un ensemble de signaux. En conséquence, plus la durée du signal est longue, plus notre estimation sera précise.

De nombreuses itérations ont été effectuées pour définir les valeurs appropriées des méta-paramètres, permettant d'aboutir à l'architecture décrite dans le Tableau 1. Le réseau de neurones convolutif a été implémenté à l'aide de la bibliothèque PyTorch. L'optimiseur utilisé est ADAM, avec un taux d'apprentissage fixé à 0,001. La fonction de coût employée est l'Erreur Quadratique Moyenne (EQM). La taille du lot d'apprentissage est de 100. Une normalisation par lot est réalisée après chaque couche du réseau afin d'améliorer la convergence du modèle. Cette technique consiste à standardiser les activations des neurones pour chaque lot d'apprentissage, réduisant ainsi les écarts entre les différentes distributions des données. Le nombre d'époques maximal, au-delà duquel on observe une stabilisation de la fonction de coût, est de 40 époques.

TABLEAU 1. Architecture du réseau convolutif

Couche	Nombre de filtres (K)	Taille du filtre (FxF)	Pas	Remplissage	Fonction d'activation
Entrée	-	-	-	-	-
Conv1 / Conv2	5 / 32	3x3	1	même	Relu
MaxPool1	-	1x2	2	-	-
Conv3 / Conv4	32 / 64	3x3	1	même	Relu
MaxPool2	-	1x2	2	-	-
Conv5	32	3x3	1	même	Relu
MaxPool3	-	1x2	2	-	-
Conv6	32	3x3	1	même	Relu
MaxPool4	-	2x2	2	-	-
Aplatir	-	-	-	-	-
Comple1/Comple2	1024 /248	-	-	-	Relu
Sortie	28	-	-	-	Linéaire

Un ensemble d'apprentissage constitué de 28000 réalisations a été simulé en accord avec les descriptions présentées dans les sections précédentes. Cet ensemble a par la suite été séparé en deux sous-ensembles distincts afin de permettre l'apprentissage et la validation du modèle. Le premier sous-ensemble, appelé ensemble d'entraînement, correspond à 90% des données (soit 25 200 réalisations) et sert à entraîner le modèle. Le second sous-ensemble, nommé ensemble de test, représente 10% des données (c'est-à-dire 2 800 réalisations) et est utilisé pour évaluer la performance du modèle entraîné.

Les courbes d'apprentissage et de validation montrent que le réseau de neurones est très performant pour détecter les défauts, les localiser et évaluer leur amplitude. En effet, l'Erreur Quadratique Moyenne (EQM) obtenue sur l'ensemble de validation est de l'ordre de 0,0008, soit une erreur-type d'environ 2%. Toutefois, un phénomène de fuite (leakage) est souvent observé entre l'élément défectueux et les éléments directement adjacents. Par exemple, si un élément défectueux présente une diminution de rigidité de 80%, il arrive que l'un des éléments adjacents présente un faux positif avec une indication de défaut de 30% par le modèle.

Il est également intéressant de constater que le réseau ne souffre pas de surapprentissage (overfitting), quel que soit le nombre d'époques. En effet, d'après la Figure 4 on remarque que la courbe de coût pour l'ensemble de validation suit de près celle de l'ensemble d'apprentissage. Une explication possible de ce phénomène est que les attributs d'entrée (dans notre cas, les matrices de covariance) sont suffisamment lisses par rapport à la configuration des défauts. Cette explication est également soutenue par le phénomène de fuite mentionné précédemment.




FIGURE 4. Courbes d'apprentissage et de validation du modèle.

Dans la figure 5, nous présentons les prévisions obtenues pour différents niveaux de dégradation dans l'élément 5, sous différents scénarii de trafic. Il est à noter que les trafics simulés ne sont pas ceux de l'ouvrage réel, qui se trouve sur une route nationale. Toutefois, ce trafic nous permet de confirmer la validité du modèle d'apprentissage pour une large plage de conditions d'exploitation. De même, les niveaux de dégradation sont obtenus par simulations éléments finis, dans le but confirmer les performances du modèle d'apprentissage.

Quels que soient le type de trafic et l'ampleur des désordres simulés dans les ensembles d'apprentissage et de validation, nous observons que la capacité de prévision du modèle est très bonne, en termes de localisation et de quantification de la perte de rigidité, i.e. du désordre.




FIGURE 5. Comparaison des rigidités effectives et celles prévues par le modèle.

V. CONCLUSION

Ce travail porte sur l'apprentissage profond avec un réseau de neurones convolutif, dont les données sont constituées des matrices de covariance de la réponse temporelle sous les conditions normales de trafic. Le réseau de neurones a pour objectif d'identifier, de localiser et de quantifier les désordres dans l'ouvrage.

La construction de l'ensemble d'apprentissage est effectuée à l'aide d'un modèle éléments finis de l'ouvrage, où les rigidités des éléments sont aléatoirement injectées pour calculer les réponses dynamiques en fonction du trafic aléatoire. Les matrices de covariance sont ensuite calculées à partir de ces réponses temporelles. Le réseau de neurones est constitué de six couches convolutives suivies de deux couches totalement connectées.

La capacité prédictive du modèle est évaluée sur le modèle du pont de Longues au Puy-de-Dôme, où seulement cinq capteurs ont été considérés. Le modèle s'est avéré très performant dans la détection et la localisation des dégradations, quelles que soient les conditions de trafic et l'ampleur des désordres. L'application de la méthode sur des données réelles est en cours et confirme la robustesse de la méthode développée.

REFERENCES

- Balasubramaniam, K., Sikdar, S., Ziaja, D., Jurek, M., Soman, R., & Malinowski, P. (2023). A global-local damage localization and quantification approach in composite structures using ultrasonic guided waves and active infrared thermography. *Smart Materials and Structures*, 32(3), 035016.
- Brownjohn, J. M. W. (2007). Structural health monitoring of civil infrastructure. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 365(1851), 589-622.
- Carden, E. P., & Fanning, P. (2004). Vibration based condition monitoring: a review. *Structural health monitoring*, 3(4), 355-377.
- Doebling, S. W., Farrar, C. R., & Prime, M. B. (1998). A summary review of vibration-based damage identification methods. *The Shock and Vibration Digest*, 30(2), 91-105.
- Faddoul, R., Raphael, W., & Chateauneuf, A. (2011). A generalised partially observable Markov decision process updated by decision trees for maintenance optimisation. *Structure and infrastructure engineering*, 7(10), 783-796.
- Faddoul, R., Soubra, A. H., Raphael, W., & Chateauneuf, A. (2013). Extension of dynamic programming models for management optimisation from single structure to multi-structures level. *Structure and Infrastructure Engineering*, 9(5), 432-447.
- Faddoul, R., Raphael, W., Soubra, A. H., & Chateauneuf, A. (2013). Incorporating Bayesian networks in Markov decision processes. *Journal of infrastructure systems*, 19(4), 415-424.
- Faddoul, R., Raphael, W., Soubra, A. H., & Chateauneuf, A. (2015). Partially Observable Markov Decision Processes incorporating epistemic uncertainties. *European Journal of Operational Research*, 241(2), 391-401.
- Farrar, C. R., & Worden, K. (2007). An introduction to structural health monitoring. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 365(1851), 303-315.
- Geara, C., Faddoul, R., Chateauneuf, A., & Raphaël, W. (2020). Hybrid inspection-monitoring approach for optimal maintenance planning. *Structure and Infrastructure Engineering*, 16(11), 1551-1561.
- Kralovec, C., & Schagerl, M. (2020). Review of structural health monitoring methods regarding a multi-sensor approach for damage assessment of metal and composite structures. *Sensors*, 20(3), 826.
- Lynch, J. P., & Loh, K. J. (2006). A summary review of wireless sensors and sensor networks for structural health monitoring. *The Shock and Vibration Digest*, 38(2), 91-130.
- Sohn, H., Farrar, C. R., Hemez, F. M., Shunk, D. D., Stinemates, D. W., Nadler, B. R., & Czarnecki, J. J. (2003). A review of structural health monitoring literature: 1996–2001. Los Alamos National Laboratory Report, LA-13976-MS.