

# Identification et localisation des défauts dans les ponts à l'aide de l'apprentissage profond

Douaa BENHADDOUCHE<sup>1</sup>, Alaa CHATEAUNEUF<sup>2</sup>, Vincent BARRA<sup>3</sup>

<sup>1</sup> Université Clermont-Auvergne, Clermont-Auvergne-INP, Institut Pascal, LIMOS, 63000 Clermont-Ferrand, CIDECO

<sup>2</sup> Université Clermont Auvergne, Clermont-Auvergne-INP, Institut Pascal, 63000 Clermont-Ferrand, CIDECO

<sup>3</sup> Université Clermont-Auvergne, CNRS, Mines de Saint-Étienne, Clermont-Auvergne-INP, LIMOS, 63000 Clermont-Ferrand

## RESUME

Avec l'évolution de la technologie des réseaux de capteurs et l'émergence des méthodes de l'intelligence artificielle pour l'analyse des grandes masses de données, la surveillance de la santé structurale est devenue un outil pratique pour évaluer la sécurité et la performance des structures. Les variations dans les conditions environnementales et opérationnelles sont les facteurs principaux qui causent l'apparition des défauts structuraux. Un effort considérable a été investi dans les approches basées sur les vibrations et l'apprentissage profond. Selon le type de données utilisées pour alimenter le modèle d'apprentissage profond, les approches de détection proposées sont regroupées en deux familles : les approches non paramétriques, et les approches paramétriques. L'approche paramétrique emploie les accélérations pour déterminer les paramètres inconnus de la structure, comme les fréquences propres et les courbures modales. Dans ce cadre, nous avons développé une méthode qui utilise les courbures modales pour entraîner un auto-encodeur profond ; les erreurs de reconstruction du modèle sont exploitées pour identifier et localiser les défauts. La méthode a été validée sur le modèle numérique d'un pont réel. Plusieurs scénarios de défauts avec différents niveaux de gravité ont été testés. Les résultats de détection ont montré que l'auto-encodeur profond entraîné sur les courbures modales de l'état intact, est capable d'identifier et de localiser les désordres lorsque le bruit de mesure est maîtrisé.

**Mots-clés :** surveillance, santé structurale, détection de défauts structuraux, auto-encodeur, apprentissage profond.

## I. INTRODUCTION

Au cours des deux dernières décennies, de nombreux systèmes de surveillance de la santé structurale (Structural Health Monitoring) ont été mis en œuvre dans des applications mécaniques, aérospatiales et en génie civil. La surveillance de la santé structurale est définie comme un processus d'évaluation non destructive in-situ, qui utilise plusieurs types de capteurs tels que les capteurs acoustiques, de pression, et des accéléromètres, fixés sur une structure ou qui y sont intégrés (Bisby, 2004). Ces capteurs obtiennent des données, qui sont ensuite collectées, stockées, et analysées pour évaluer la sûreté et le rendement de la structure par la détection précoce des défauts structuraux. Dans la surveillance de la santé structurale, la détection des défauts consiste à identifier tout changement dans le comportement dynamique d'une structure. Ce changement résulte de l'évolution des défauts causés par les conditions environnementales (température, vent

et humidité, précipitations et neige) et opérationnelles (charges ambiantes, charges massiques, vitesse opérationnelle) appliquées sur cette structure. Une hiérarchie verticale de détection a été proposée par (Rytter, 1993) qui comprend quatre niveaux : 1- L'identification du défaut ; 2- La localisation du défaut ; 3- La quantification du défaut ; et 4- La prédiction du défaut. Les méthodes traditionnelles de détection des défauts structuraux, comme les essais non destructifs et les inspections visuelles présentent des limites (Avci et al., 2021). Par conséquent, le développement des méthodes de détection automatique pour réduire le coût et le temps de réparation est devenu indispensable. Grâce à leur capacité d'identifier les défauts invisibles dans les sections internes d'une structure, les méthodes basées sur les vibrations sont très répandues. La raison derrière l'efficacité de ces méthodes est que les défauts structuraux se traduisent par la variation des caractéristiques structurales comme la rigidité et se manifestent dans la réponse vibratoire de la structure (Zhang et al., 2022). Avec l'émergence des algorithmes d'intelligence artificielle et leurs succès dans diverses applications (reconnaissance de modèles, classification d'images, traitement du langage naturel, etc.). Le domaine de la surveillance de la santé structurale s'est emparé de ces méthodes pour analyser les données de vibrations issues d'un réseau de capteurs installé sur la structure. Les méthodes basées sur les vibrations et l'apprentissage automatique sont regroupées en deux catégories : la première concerne les approches non paramétriques, qui emploient des techniques statistiques de modélisation des séries temporelles (ARIMA, ARX, et ARMAX par exemple). La seconde catégorie concerne les approches paramétriques, qui utilisent les propriétés dynamiques de la structure telles que les fréquences et les modes propres, les courbures modales, et les taux d'amortissement. Les résultats de détection des approches paramétriques et non paramétriques basées sur la classification supervisée et non supervisée reposent sur la technique d'extraction de caractéristiques utilisées. Il s'avère que les techniques utilisées dans la littérature sont gourmandes en ressources et en temps de calcul. De plus, aucune combinaison d'une méthode d'extraction et d'un classificateur est le choix optimal pour détecter tout type de défauts (Avci et al., 2021). Pour surmonter ces limites, les réseaux de neurones profonds ont été largement utilisés. Ces derniers sont connus pour leur efficacité dans l'extraction automatique des caractéristiques, et de leur robustesse face aux données bruitées, imprécises ou mal définies. De nombreuses études sur la détection des défauts ont utilisé les séries temporelles d'accélération et les propriétés modales pour entraîner les modèles d'apprentissage profond. (Rastin et al., 2021) ont proposé une méthode non supervisée, basée sur un auto-encodeur à convolution pour l'identification des dommages et l'évaluation de l'état global de la structure. Deux modèles numériques, et le pont de Tianjin, ont été utilisés pour évaluer les performances de cette méthode. (Dhiraj et al., 2021) ont développé une méthode composée d'un réseau de convolution profond et d'un modèle de régression linéaire multivariée qui utilise les fonctions de transmissibilité pour détecter, localiser et quantifier les défauts. La méthode a été testée sur les modèles éléments finis de deux structures. La plupart des approches reposent sur un mode supervisé, qui nécessite des données étiquetées de l'état sain et endommagé de la structure surveillée. Ce qui les rend peu pratiques pour les infrastructures de génie civil (Avci et al., 2021), parce que les données provenant de différents états endommagés de ces structures ne sont pas accessibles. De plus, la détection de défauts se limite aux types de défauts considérés dans la phase d'entraînement. Ainsi le mode non supervisé semble plus approprié puisqu'il permet de détecter tout type de défaut, du fait qu'il n'utilise que les données de la structure saine pour entraîner le réseau de neurones. Néanmoins, les travaux sur l'apprentissage profond non supervisé restent limités, et sont souvent capables d'identifier l'existence du défaut, et dans certains cas, de fournir l'information sur l'emplacement (Jiang et al., 2021) ou l'amplitude de défaut lorsqu'il est important. Compte tenu de ces défis, l'objectif de notre travail est de proposer une méthode paramétrique d'apprentissage non supervisé pour identifier et

localiser les défauts structuraux via un auto-encodeur profond pour apprendre la distribution des états structuraux, et les erreurs de reconstruction du modèle pour identifier et localiser les défauts. Cet article est organisé comme suit. La section 2 présente la méthode proposée, elle se concentre sur la compréhension de l'architecture et les hyperparamètres du modèle utilisé, ainsi que sa phase d'entraînement. La section 3 est consacrée à la validation expérimentale de la méthode à l'aide du modèle numérique d'un pont, suivie d'une discussion sur les résultats, les performances et les limites de la méthode. La section 4 conclut l'étude présentée et propose quelques suggestions de travaux futurs.

## II. MÉTHODOLOGIE

Les paramètres dynamiques de structures tels que les fréquences et les modes propres ou les coefficients d'amortissement, ont été beaucoup utilisés comme indicateurs de l'existence de défauts structuraux dans les méthodes basées sur les vibrations. La raison pour laquelle ces paramètres ont été largement exploités est la facilité de les mesurer sur les structures réelles (Ma et al., 2020). De plus, il a été reporté plusieurs fois que ces propriétés sont sensibles aux défauts mais également aux variations des conditions environnementales (Niyirora et al., 2022). Les fréquences et les modes propres sont directement reliés à la rigidité de la structure. De ce fait, une modification des fréquences propres ou un changement dans les modes indiquent facilement la présence de défauts et leur sévérité. Pour une meilleure localisation des défauts, d'autres paramètres dynamiques ont été proposés, parmi lesquels : la densité spectrale de puissance (Yu et al., 2019) et les courbures modales (Hou and Xia, 2021) qui ont montré plus de sensibilité aux défauts que les modes (Pandey et al., 1991). Dans le travail présenté ici, nous avons utilisé les courbures modales de l'état sain de la structure pour entraîner un auto-encodeur profond. Le modèle apprend à reconstruire les courbures modales de la structure sur les points de mesure. Les erreurs de reconstruction du modèle dans l'étape de test sont utilisées pour identifier et localiser les défauts. La figure 1 compare les courbures de l'état sain et celles des cinq scénarios de défauts. Dans cette étude, neuf points de mesure sont considérés. Les pics sur les courbes apparaissent aux points de mesure proches du défaut. Par exemple, sur la figure 1, le scénario 1 correspond au défaut **se trouvant** dans la zone couverte par les points de mesure C4, C5, et C6. La méthode proposée est composée de deux phases : l'apprentissage de l'état de référence (ou initial) de la structure, et l'identification et la localisation des désordres par les erreurs de reconstruction. Durant la première phase, l'auto-encodeur profond apprend la distribution des courbures modales dans l'état intact afin de les reproduire. Et dans la deuxième phase, les erreurs de reconstruction dans l'état endommagé sont utilisées comme indicateurs de l'existence de défauts sur la structure et pour les localiser.

### **Apprentissage de la distribution de l'état structural**

Dans cette phase, un auto-encodeur profond a été utilisé pour apprendre la distribution des courbures modales dans l'état intact de la structure. Nous supposons que la distribution des courbures modales dans un état d'endommagement dévie de la distribution des courbures apprise par le modèle, ce qui nous permettra de détecter les désordres. Un auto-encodeur est un réseau de neurones de type propagation en avant, son apprentissage se fait en utilisant la rétropropagation basée sur les algorithmes d'optimisation. Un auto-encodeur est entraîné d'une manière non supervisée à reproduire son entrée, il ne nécessite donc pas d'échantillons de l'état endommagé dans la phase d'apprentissage. Un auto-encodeur est composé de deux réseaux : l'encodeur et le décodeur. L'encodeur plonge les données d'entrée  $\mathbf{x}$  dans un espace latent de petite dimension  $\mathbf{h}$  alors que le décodeur tente de reconstruire les données originales à partir de  $\mathbf{h}$  pour obtenir  $\hat{\mathbf{x}}$ .

La fonction de transfert de chaque partie est exprimée comme suit :

$$\mathbf{h} = \mathbf{f}(\mathbf{x}) = \Phi(\mathbf{W}\mathbf{x} + \mathbf{b}) \quad (1)$$

$$\hat{\mathbf{x}} = \mathbf{g}(\mathbf{h}) = \Phi'(\mathbf{W}'\mathbf{x} + \mathbf{b}') \quad (2)$$

où  $\mathbf{W}, \mathbf{W}'$  et  $\mathbf{b}, \mathbf{b}'$  sont respectivement les matrices de pondérations et les vecteurs de biais de l'encodeur et du décodeur, tandis que  $\Phi$  et  $\Phi'$  sont respectivement les fonctions d'activations de l'encodeur et du décodeur. L'auto-encodeur optimise les paramètres d'apprentissage  $\mathbf{W}, \mathbf{W}'$  et  $\mathbf{b}, \mathbf{b}'$  en utilisant une fonction de coût  $L$  entre l'entrée  $\mathbf{x}$  et la sortie du décodeur  $\hat{\mathbf{x}}$ .

La dimension d'un auto-encodeur est le nombre de neurones dans la couche latente qui sépare ses deux parties. Il est dit auto-encodeur profond, lorsqu'il contient plus qu'une couche cachée.

L'auto-encodeur profond proposé dans cet article a pour dimension 3 (DAE-3D) et est composé de 5 couches cachées. Il a été entraîné sur 100 époques par lots de 256 données de courbures modales de l'état sain seulement. L'algorithme d'optimisation Adam a été utilisé pour mettre à jour les pondérations du réseau. L'objectif de l'actualisation des pondérations est de minimiser la perte entre les séries de courbures reconstruites et réelles. Nous avons utilisé l'erreur quadratique moyenne (MSE) comme fonction de coût pour calculer cette perte. La fonction MSE pour  $n$  entrées est donnée comme suit :

$$MSE = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \hat{\mathbf{x}}_i)^2 \quad (3)$$

La fonction d'activation de la couche de sortie de l'encodeur est linéaire, et comme les séries de courbures ont été normalisées à  $[-1,1]$  dans cette méthode, l'activation de la couche de sortie du décodeur est la tangente hyperbolique. La fonction d'activation *Leaky-ReLU* est utilisée sur les autres couches de l'encodeur et du décodeur. Le pas d'apprentissage est fixé à 0,01 et le reste des paramètres comme l'initialisation des pondérations et des biais a été effectuée par la méthode de Glorot (Glorot and Bengio, 2010). Les nombres de couches et de neurones dans chaque couche ont été choisis expérimentalement. Le réseau a été codé en Python en utilisant la librairie *Tensorflow* (<https://www.tensorflow.org>). La figure 2 montre l'architecture de l'auto-encodeur profond utilisé.

### Identification et localisation des défauts

Après l'étape d'apprentissage de la distribution des données de l'état intact, le modèle est utilisé pour identifier la présence des défauts dans la structure, puis pour déterminer leurs emplacements. Les courbures modales d'un état endommagé sont employées dans cette phase pour détecter les désordres. L'intuition sous-jacente de cette hypothèse, est que les défauts modifient les propriétés dynamiques de la structure par rapport à celles de l'état intact (ou initial). Cela se traduit par l'inefficacité de l'auto-encodeur profond à reproduire les courbures modales de l'état endommagé. En conséquence, les grandes valeurs de MSE résultent de l'écart entre les courbures de l'état endommagé et celles prédites par le modèle. Ces valeurs de MSE sont supérieures aux valeurs de MSE calculées pendant la phase d'apprentissage. Pour cela, nous avons déterminé un seuil d'erreur (SE), basé sur les erreurs en phase d'apprentissage, pour identifier la présence de défauts dans la structure. Le seuil est calculé comme suit :

$$SE = \text{Max} \left[ \frac{1}{m} \sum_{j=1}^m mse_{ij} \right] \quad (4)$$

où  $m$  est le nombre de modes et  $mse_{ij}$  est l'erreur quadratique moyenne de reconstruction sur le point de mesure  $i$  sur le mode  $j$ . Cette technique peut être utilisée sur n'importe quel mode afin d'identifier la présence de défauts ; le type de défaut reste néanmoins inconnu. Pour la localisation, le maximum des valeurs MSE calculées pour chaque point de mesure, est supposé être la valeur du

capteur proche de l'emplacement du défaut. Dans cette étape, chaque mode est traité séparément. Après les phases d'entraînement, d'identification et de localisation, les résultats de détection des 10 modes sont agrégés et le résultat final est obtenu par consensus. L'occurrence de chaque capteur détecté proche d'un défaut sur les 10 modes est utilisée comme critère du consensus.

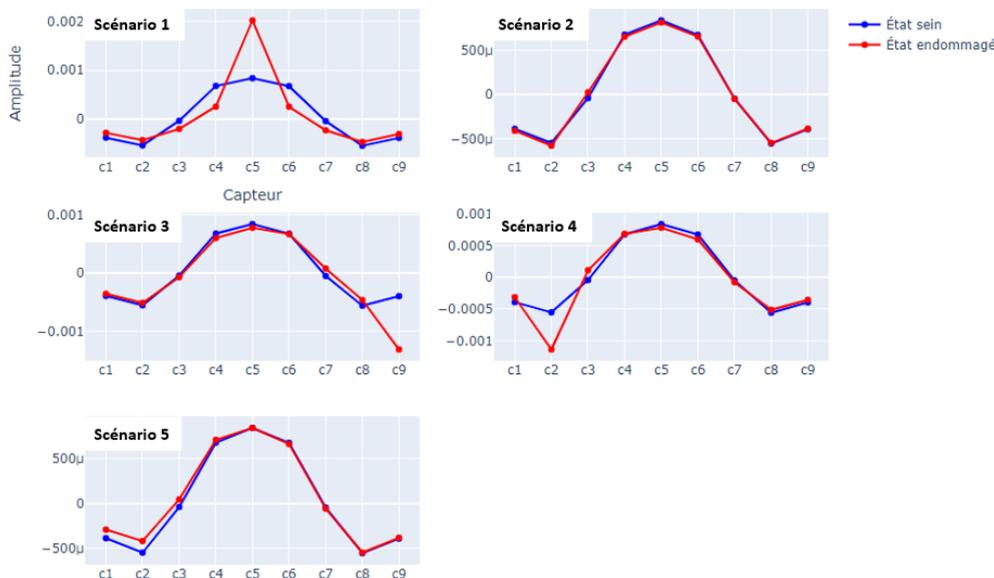


FIGURE 1. Comparaison entre les courbures modales de l'état sain et de l'état endommagé.

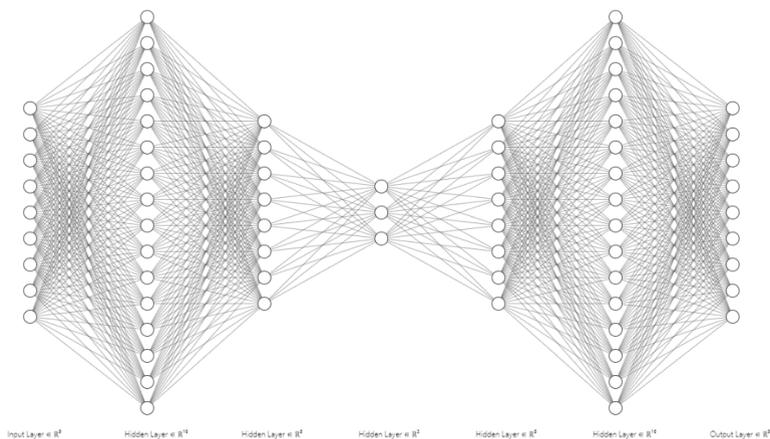


FIGURE 2. Architecture du DAE-3D utilisé.

### III. RÉSULTATS ET DISCUSSION

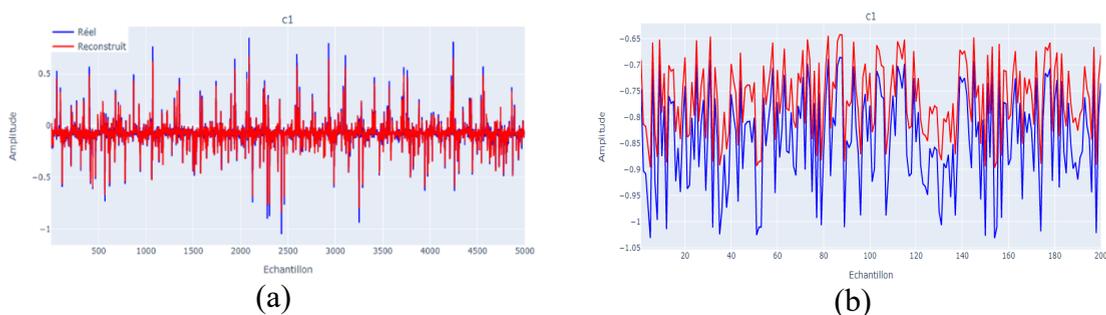
Pour étudier l'efficacité de la méthode proposée, nous l'avons appliquée sur un modèle numérique du pont de Longues au Puy-de-Dôme (63). La structure de test employée est un modèle éléments finis composé de 28 éléments et 29 nœuds, neuf points de mesure ont été définis sur différents éléments du modèle pour enregistrer sa réponse dynamique dans l'état sain et l'état d'endommagement par des essais de tirer-lâcher. Cinq scénarios de défauts ont été simulés pour vérifier l'efficacité de la méthode. Ces défauts correspondent à la réduction de rigidité des éléments sur lesquels ils ont été déterminés. La figure 3 illustre le modèle numérique du pont, ainsi que les emplacements des défauts. Les  $C_i$  sont les points de mesure, et les éléments endommagés sont

entourés par des cercles rouges. Après avoir calculé les dix premiers modes de la structure, un jeu de données de taille (20000,9) a été généré pour chaque mode à l'état intact, et cinq jeux de données de taille (200,9) ont été créés pour chaque scénario de défaut. Tous ces jeux de données ont été normalisés entre  $[-1,1]$  en utilisant la formule  $\frac{x-x_{min}}{x_{max}-x_{min}}$  avant d'être présentés à notre auto-encodeur profond pour la phase d'entraînement et de test.



**FIGURE 3.** Pont de Longues : ouvrage, modèle numérique et localisation des capteurs et des défauts.

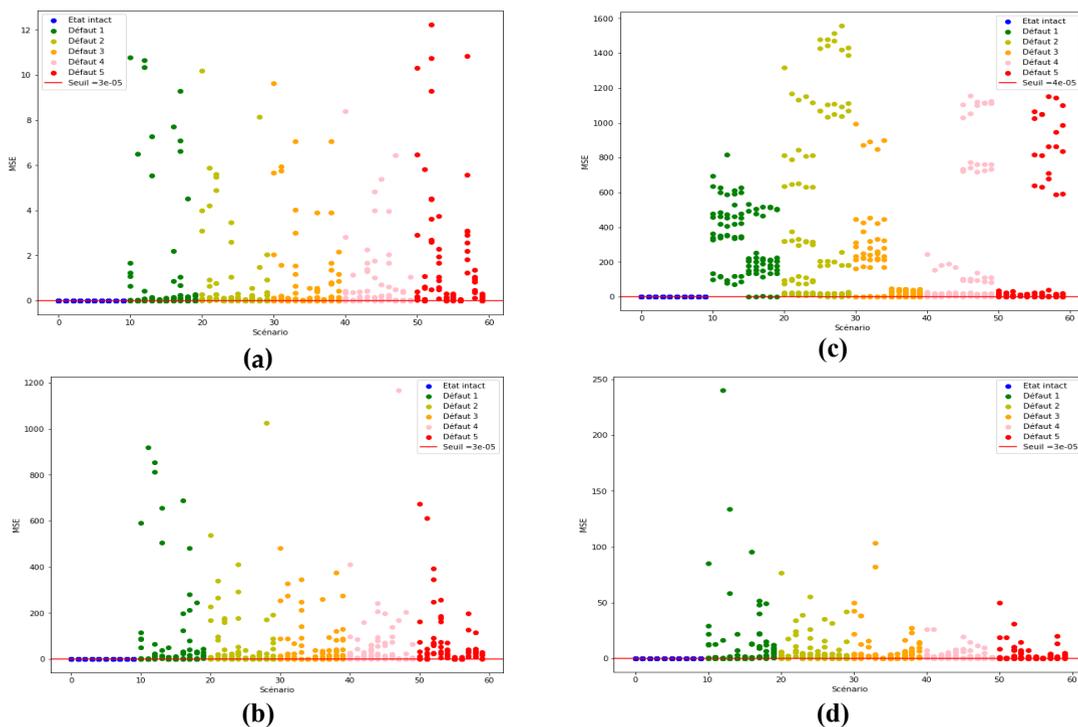
Deux jeux de données ont été créés, avec faible bruit et bruit important ; le bruit est modélisé par des variables aléatoires gaussiennes indépendantes qui affectent les rigidités des éléments. De plus, deux niveaux de gravité de défauts ont été définis pour les scénarios d'endommagement : 20% défauts faibles et 80% défauts sévères, afin de tester la capacité de détection de la méthode vis-à-vis du niveau de bruit et de la sévérité des désordres. Dans la phase d'entraînement, 25% du jeu de données a été utilisé pour valider l'apprentissage du modèle. La figure 4 illustre les résultats d'entraînement sur le mode 6 dans l'état intact et le scénario du défaut 2 sur le point de mesure C1. Dans cet exemple, nous remarquons que l'auto-encodeur profond est capable de reconstruire les courbures de l'état intact avec une bonne précision, alors que dans le cas endommagé, la différence entre les courbures mesurées et prédites est assez conséquente.



**FIGURE 4.** Comparaison des courbures originales et reconstruites du point C1 pour : (a) état intact, (b) état endommagé.

La méthode proposée exploite cette différence pour identifier puis localiser les défauts. L'identification des cas endommagé se fait à l'aide d'un seuil d'erreur défini en phase d'entraînement. Les cas dont les MSE sont supérieures à ce seuil sont considérés comme cas endommagés. La raison pour laquelle ces erreurs dépassent le seuil, est à la présence de défauts dans la structure. Dès lors, son comportement dynamique a changé, et le modèle est incapable de

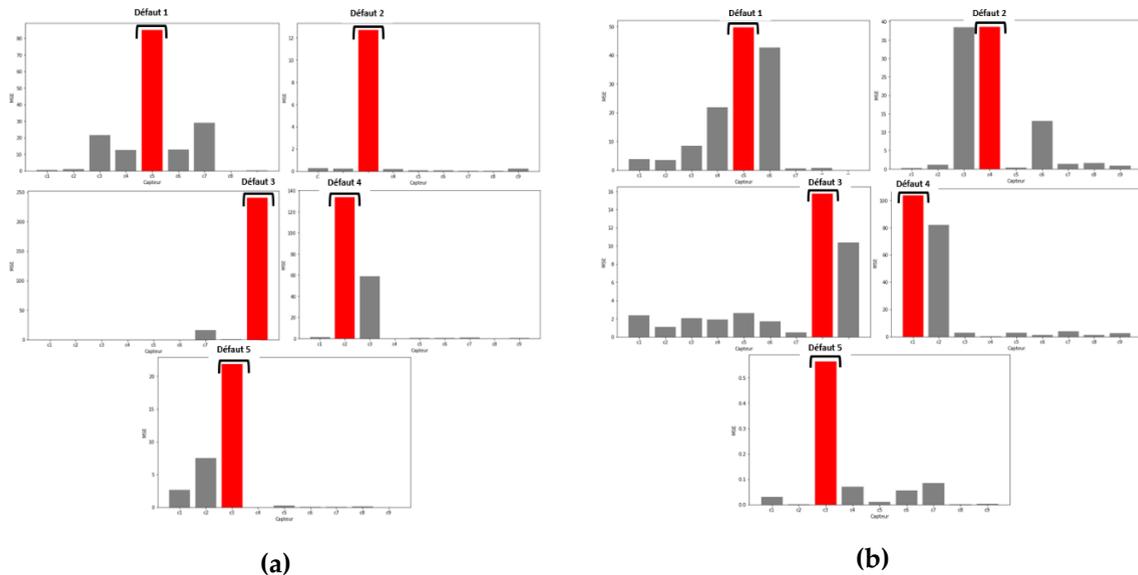
reconstruire les courbures modales précisément dans l'état endommagé. La figure 5 montre les résultats d'identification des défauts en utilisant les deux jeux de données avec des niveaux de bruit faible et élevé. Les figures 5.a et 5.b présentent les erreurs de reconstruction sur les dix modes à tous les points de mesure dans l'état intact (en bleu) et dans l'état endommagé (5 scénarios de défauts : scénario 1 en verre, scénario 2 en jaune, scénario 3 en orange, scénario 4 en rose, et scénario 5 en rouge, avec les 2 pourcentages de sévérité) des données avec un bruit faible, et les figures 5.c et 5.d montrent les erreurs de reconstruction des 9 points de mesure dans l'état intact et l'état endommagé avec un bruit important. La ligne rouge sur les quatre figures représente le seuil d'identification. Nous remarquons que la valeur de ce seuil est quasiment la même pour chaque jeu de données, ce qui est évident parce que l'entraînement se fait avec le même ensemble de données. La valeur du seuil dans ce cas est très faible, et égale à  $3 \times 10^{-5}$ . Ce qui montre que notre modèle a bien appris la distribution des données dans l'état intact. Nous observons que sur les deux ensembles de données et avec les différents pourcentages de gravité des défauts, il existe une variation significative des valeurs d'erreurs dans l'état endommagé (les cinq scénarios de défauts) comparée aux valeurs d'erreurs à l'état sain, qui sont approximativement constantes. En outre, la plupart de ces erreurs se trouvent en dessus du seuil, d'où l'identification des désordres dans la structure. Notre méthode est donc apte à identifier les défauts même à faible degré de gravité. Quant à la localisation, nous avons remarqué que certains modes donnent de grandes erreurs sur les points de mesure voisins de l'élément endommagé, ou n'arrivent pas à localiser correctement quelques défauts. Pour cela, nous avons utilisé un consensus de localisation entre les modes basé sur le nombre de fois qu'un capteur i a eu la plus grande valeur d'erreur sur les dix modes.



**FIGURE 5.** Comparaison des erreurs de reconstruction dans l'état intact et dans les cinq états endommagés en utilisant les deux jeux de données simulés : (a) données avec bruit faible et défauts de 20%, (b) données avec bruit faible et défauts de 80%, (c) données avec bruit important et défauts de 20%, (d) données avec bruit important et défauts de 80%.

La figure 6 montre les résultats de localisation sur le mode 1 et 5. Nous remarquons sur la figure 6.a que tous les défauts, illustrés sur la figure 3, ont été correctement localisés par le mode 1.

Cependant, pour le mode 5 seulement 2 défauts sur 5 (défaut 1 sur C5 et défaut 5 sur C3) ont été précisément localisés. Pour les trois autres défauts, ce sont les points de mesure voisins qui ont été détectés proches des emplacements des défauts. Par exemple, le défaut 3 est détecté sur C8 alors qu'il se trouve sur C9.



**FIGURE 6.** Localisation des défauts de 80% en cas de bruit élevé : (a) mode 1, (b) mode 5.

Les tableaux de la figure 7 présentent le résultat final de la localisation des cinq défauts par les dix modes sur les deux jeux de données. Sur la dernière colonne de chaque tableau sont précisés les capteurs situés sur les éléments endommagés des cinq scénarios de défaut comme défini sur la figure 3. Sur les autres colonnes, sont indiqués les capteurs ayant les valeurs maximales d'erreurs de reconstruction pour chaque scénario de défaut. La liste de capteurs au-dessus de chaque tableau correspond aux capteurs proches des défauts des 5 scénarios respectivement.

<p><b>(a) cas des données avec bruit faible et défauts de 20%</b></p>	Capteurs sur défauts: ['c5', 'c3', 'c9', 'c2', 'c3']											
		<b>Mode1</b>	<b>Mode2</b>	<b>Mode3</b>	<b>Mode4</b>	<b>Mode5</b>	<b>Mode6</b>	<b>Mode7</b>	<b>Mode8</b>	<b>Mode9</b>	<b>Mode10</b>	<b>Réel</b>
	<b>D1</b>	c5	c6	C5								
	<b>D2</b>	c3	c3	c3	c4	c4	c3	c5	c3	c3	c1	C3
	<b>D3</b>	c9	c8	c6	c8	c6	c7	c9	c9	c6	c8	C9
	<b>D4</b>	c2	c2	c1	c2	c2	c3	c3	c1	c2	c1	C2
<b>D5</b>	c3	c1	c6	c3	c1	c3	c3	c1	c3	c3	C3	
<p><b>(b) Cas des données avec bruit faible et défauts de 80%</b></p>	Capteurs sur défauts: ['c5', 'c3', 'c9', 'c2', 'c3']											
		<b>Mode1</b>	<b>Mode2</b>	<b>Mode3</b>	<b>Mode4</b>	<b>Mode5</b>	<b>Mode6</b>	<b>Mode7</b>	<b>Mode8</b>	<b>Mode9</b>	<b>Mode10</b>	<b>Réel</b>
	<b>D1</b>	c5	c6	C5								
	<b>D2</b>	c3	c3	c3	c3	c4	c3	c5	c3	c3	c3	C3
	<b>D3</b>	c9	c8	c6	c8	c9	c9	c9	c9	c7	c8	C9
	<b>D4</b>	c2	c2	c2	c2	c2	c3	c3	c2	c2	c1	C2
<b>D5</b>	c3	c1	c6	c3	c2	c3	c4	c1	c3	c6	C3	

<b>(c) Cas des données avec bruit important et défauts de 20%</b>	Capteurs sur défauts: ['c5', 'c5', 'c9', 'c5', 'c5']											
		Mode1	Mode2	Mode3	Mode4	Mode5	Mode6	Mode7	Mode8	Mode9	Mode10	Réel
	D1	c5	c4	c5	c9	c5	c9	c5	c4	c5	c1	C5
	D2	c5	c6	c5	c9	c5	c9	c5	c4	c5	c9	C3
	D3	c9	c4	c5	c9	c5	c9	c5	c4	c9	c1	C9
	D4	c5	c4	c5	c9	c5	c9	c5	c4	c1	c9	C2
D5	c5	c4	c5	c9	c5	c9	c5	c4	c1	c9	C3	
<b>(d) Cas des données avec bruit important et défauts de 80%</b>	Capteurs sur défauts: ['c5', 'c3', 'c9', 'c2', 'c3']											
		Mode1	Mode2	Mode3	Mode4	Mode5	Mode6	Mode7	Mode8	Mode9	Mode10	Réel
	D1	c5	c4	c5	c4	c5	c6	c5	c6	c5	c6	C5
	D2	c3	c3	c3	c3	c4	c3	c5	c3	c3	c8	C3
	D3	c9	c9	c7	c8	c8	c7	c8	c9	c9	c9	C9
	D4	c2	c2	c1	c2	c1	c3	c4	c2	c2	c1	C2
D5	c3	c4	c3	c1	c3	c4	c4	c3	c3	c6	C3	

**FIGURE 7. Résultat final de localisation des défauts**

Ces résultats montrent que la méthode a pu localiser correctement les défauts de 80% de gravité pour les données avec bruit faible (figure 7.b) et pour les données avec bruit important (figure 7.d). Les défauts de 20% de gravité ont été bien localisés sur les données de bruit faible (figure 7.a). Néanmoins, sur les données de bruit important (figure 7.c) seulement 2 défauts sur 5 ont été correctement localisés.

#### IV. CONCLUSION

Ce travail porte sur l'apprentissage profond non supervisée qui s'appuie sur un auto-encodeur profond pour assurer les deux premiers niveaux de détection, à savoir l'identification et la localisation des désordres dans une structure à partir des courbures modales. La méthode est composée de deux étapes : l'apprentissage de la distribution des courbures modales de l'état sain de la structure, et l'identification et la localisation des désordres. La première étape permet d'avoir une distribution de référence qui présente l'état intact de la structure, ce qui garantit la détection dans la deuxième étape de toute déviation de cette distribution. Cette déviation traduit le changement des propriétés dynamiques de la structure, engendrée par des désordres. Afin de valider les performances de cette méthode, nous l'avons appliquée au modèle éléments finis du pont de Longues au Puy-de-Dôme. Neuf points de mesure ont été définis le long de l'ouvrage et cinq scénarios de désordres ont été simulés. Deux ensembles de données ont été générés, pour représenter les niveaux de bruit faible et élevé. Les scénarios de défauts ont été simulés par la réduction de rigidité des éléments endommagés, avec deux pourcentages : 80% pour des défauts sévères, et 20% pour des défauts faibles. Un auto-encodeur profond à trois dimensions a été utilisé dans l'étape d'apprentissage. Il a été entraîné sur les courbures modales des dix premiers modes de la structure dans l'état intact. Puis les erreurs de reconstruction calculées par l'erreur quadratique moyennée (MSE) ont été exploitées pour identifier et localiser les défauts. Pour détecter les défauts, un seuil d'erreur de reconstruction a été déterminé en considérant la valeur maximale d'erreurs sur les points de mesure. Les résultats de cette technique ont montré l'efficacité de notre méthode pour l'identification des défauts à la présence d'un bruit important sur les données, et des défauts minimes. Afin de remédier à la fausse identification des emplacements de défauts, une

localisation par consensus a été employée. Cette méthode a été efficace pour localiser les défauts sévères sur les deux ensembles de données. Cependant, elle ne permet pas la localisation des faibles défauts lorsque le niveau de bruit devient important. La méthodologie présentée ici permet d'identifier et de localiser les défauts structuraux importants. Elle sera prochainement testée sur les données de la structure réelle. Dans les futurs travaux, nous travaillerons sur l'amélioration de la technique de localisation des faibles désordres lorsque les données sont fortement bruitées, et augmenter ainsi la capacité de détection de cette méthode, à l'aide d'outils statistiques appropriés pour mesurer le degré de gravité des défauts.

## REFERENCES

- Rytter A. *Vibrational Based Inspection of Civil Engineering Structures*. Aalborg: Dept. of Building Technology and Structural Engineering, Aalborg University, 1993. 193 p.
- Avci, O., Abdeljaber, O., Kiranyaz, S., Hussein, M., 2021. A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications. *Mechanical Systems and Signal Processing* 45.
- Bisby, L.A., 2004. *An Introduction to Structural Health Monitoring*.
- Dhiraj, Agarwal, A., Agrawal, A., Meruane, V., Sangwan, K.S., 2021. Development of a Machine Learning-based model for Damage Detection, Localization, and Quantification to Extend Structure Life. *Procedia CIRP* 98, 199–204. <https://doi.org/10.1016/j.procir.2021.01.030>
- Glorot, X., Bengio, Y., 2010. Understanding the difficulty of training deep feedforward neural networks.
- Hou, R., Xia, Y., 2021. Review on the new development of vibration-based damage identification for civil engineering structures: 2010–2019. *Journal of Sound and Vibration* 491, 115741. <https://doi.org/10.1016/j.jsv.2020.115741>
- Jiang, K., Han, Q., Du, X., Ni, P., 2021. A decentralized unsupervised structural condition diagnosis approach using deep auto-encoders. *Computer-Aided Civil and Infrastructure Engineering* 36, 711–732. <https://doi.org/10.1111/mice.12641>
- Ma, X., Lin, Y., Nie, Z., Ma, H., 2020. Structural damage identification based on unsupervised feature extraction via Variational Auto-encoder. *Measurement* 160, 107811. <https://doi.org/10.1016/j.measurement.2020.107811>
- Niyirora, R., Ji, W., Masengesho, E., Munyaneza, J., Niyonyungu, F., Nyirandayisabye, R., 2022. Intelligent damage diagnosis in bridges using vibration-based monitoring approaches and machine learning: A systematic review. *Results in Engineering* 16, 100761. <https://doi.org/10.1016/j.rineng.2022.100761>
- Pandey, A.K., Biswas, M., Samman, M.M., 1991. Damage detection from changes in curvature mode shapes. *Journal of Sound and Vibration* 145, 321–332. [https://doi.org/10.1016/0022-460X\(91\)90595-B](https://doi.org/10.1016/0022-460X(91)90595-B)
- Rastin, Z., Amiri, G.G., Darvishan, E., 2021. Unsupervised Structural Damage Detection Technique Based on a Deep Convolutional Autoencoder. *Shock and Vibration* 11.
- Yu, Y., Wang, C., Gu, X., Li, J., 2019. A novel deep learning-based method for damage identification of smart building structures. *Structural Health Monitoring* 18, 143–163. <https://doi.org/10.1177/1475921718804132>
- Zhang, C., Mousavi, A.A., Masri, S.F., Gholipour, G., Yan, K., Li, X., 2022. Vibration feature extraction using signal processing techniques for structural health monitoring: A review. *Mechanical Systems and Signal Processing* 177, 109175. <https://doi.org/10.1016/j.ymsp.2022.109175>