

# Approche basée sur l'apprentissage automatique pour la détection d'anomalies lors de la surveillance d'ouvrages

Nicolas Manzini\*<sup>1</sup>, Franziska Schmidt<sup>2</sup>, Jean-François Bercher<sup>3</sup>, André Orcesi<sup>4</sup>, Pierre Marchand<sup>5</sup>, Julien Gazeaux<sup>6</sup>

<sup>1</sup> SITES, 1 Avenue Edouard Belin, Rueil-Malmaison, France – [nicolas.manzini@sites.fr](mailto:nicolas.manzini@sites.fr)

<sup>2</sup> Univ Gustave Eiffel, MAST-EMGCU, F-77454 Marne-la-Vallée, France

<sup>3</sup> Univ Gustave Eiffel, ESIEE Paris, LIGM, CNRS, F-77454 Marne-la-Vallée, France

<sup>4</sup> Cerema, Research team ENDSUM, DTecITM/DTOA, Champs-sur-Marne, France

<sup>5</sup> Cerema, DTecITM/DTOA/GITEX, Champs-sur-Marne, France

<sup>6</sup> Univ Gustave Eiffel, IGN, SGM, 73 avenue de Paris, Saint-Mandé, France

**RÉSUMÉ** L'un des principaux objectifs de la surveillance de santé structurale (SHM) est de détecter, et éventuellement localiser, quantifier ou prédire les dommages sur les structures. Sans connaissances détaillées du comportement mécanique structural, l'analyse des données est une tâche complexe, et la surveillance opérationnelle est souvent limitée à l'utilisation de seuils plus ou moins arbitraires. Les approches *data-driven* qui reposent sur une analyse statistique des données, ont suscité un intérêt croissant ces deux dernières décennies.

Cet article propose une approche basée sur plusieurs modèles automatisés construits par apprentissage automatique, pour la détection et la localisation des anomalies dans les données de surveillance d'un grand pont en béton. Pour chaque capteur, plusieurs modèles de régression sont générés à l'aide de réseaux de neurones récurrents en utilisant les données d'autres capteurs déployés sur la structure. Les anomalies sont ensuite identifiées dans le jeu de données en fonction des résidus entre les sorties des modèles et les données mesurées in situ. Pour un capteur donné, les résidus de tous les modèles sont ensuite compilés pour produire un indicateur d'anomalie.

**Mots-clefs** Détection d'anomalies, Réseaux de neurones, Surveillance de santé structurale, apprentissage statistique, automatisation.

**Keywords** Novelty detection, Neural networks, Structural health monitoring, Machine learning, Automation.

## I. INTRODUCTION

Dans un contexte global de vieillissement des infrastructures et d'une exploitation croissante des réseaux, de plus en plus d'ouvrages d'art sont équipés de systèmes de surveillance structurale (*Structural Health Monitoring*, SHM) afin d'en optimiser la maintenance et d'en assurer la sécurité.

L'objectif de ces systèmes est la détection d'endommagement structurel, qui peut aller de la simple identification de l'anomalie à sa localisation, sa quantification et sa prédiction [Rytter, 1993].

L'une des approches de détection les plus courantes consiste à comparer les données acquises à un état de référence. Comme le comportement d'une grande structure est largement influencé par les conditions environnementales (température, vent, humidité) et les charges, un modèle mécanique peut être développé pour prédire sa réponse structurelle et la comparer aux observations.

Les récents développements techniques dans l'analyse de grands volumes de données (*big data*) et de relations complexes (apprentissage profond, intelligence artificielle) ont fourni de nouveaux outils pour le SHM. L'analyse *data-driven*, qui ne prend en compte que les distributions statistiques des ensembles de données sans faire d'hypothèses sur la structure, regroupe une grande variété d'outils tels que la classification [Santos, 2016] [Concepcion et al., 2019], la reconnaissance des formes [Cury et al., 2012] [Entezami et al., 2020], la fusion des données [Santos et al., 2017] et la régression des séries temporelles.

Les réseaux de neurones ont suscité un intérêt croissant au cours de la dernière décennie, notamment en tant qu'outil de régression pour modéliser des séries temporelles complexes : [Kaloop et al., 2014] ont souligné que les réseaux de neurones autorégressifs peuvent être utilisés pour prédire les déplacements au sommet d'un pylône de pont sur la base de données de température et de charge, tandis que [Manzini, 2020] a observé que les réseaux de neurones peuvent être utilisés pour relier les déplacements observés sur différentes parties d'un pont bétonné en utilisant un réseau de capteurs GPS [Manzini et al., 2020].

Dans ce contexte, cet article étudie le potentiel d'un algorithme d'apprentissage automatique combinant plusieurs modèles générés avec des réseaux de neurones appliqués sur les données des capteurs d'un grand pont en béton.

## II. DONNÉES UTILISÉES

Les données utilisées dans cette étude ont été acquises sur un pont extradossé en béton pendant deux années de surveillance continue (2019-2020). Le pont comporte 2 pylônes d'approximativement 50m et est divisé en trois travées pour une longueur totale d'environ 250m. Le pont est entouré de deux viaducs d'accès, qui ne sont pas étudiés dans ce document. Le pont a été instrumenté par SITES d'un système de surveillance comportant des capteurs variés (Fig. 1) acquérant des données à un rythme fixe d'une heure :

- 2 inclinomètres 2D au sommet de chaque pylône, dans les directions longitudinale et transversale,
- 3 capteurs de déplacement à chaque extrémité du pont,
- 7 extensomètres à corde vibrante pour le suivi des déformations du voussoir de clavage,
- 2 accéléromètres : un accéléromètre à 3 axes installé au centre de la travée principale et un accéléromètre à 2 axes installé au centre de la travée Sud,
- 16 capteurs de tension situés à la base des câbles, environ un tous les deux câbles,
- 18 sondes de température réparties sur différentes parties de la structure, à côté des extensomètres, des capteurs de déplacement et des inclinomètres,

- Une station météorologique recueillant la température de l'air ainsi que la vitesse et la direction moyennes du vent.




FIGURE 1. Système de surveillance du pont

Note : en raison de dysfonctionnements de certains systèmes d'acquisition, les données de 3 extensomètres à cordes vibrantes ont été retirées de l'étude.

### III. UTILISATION DE RÉSEAUX DE NEURONES RÉCURRENTS

Les modèles linéaires sont souvent les premiers outils considérés pour la régression de séries temporelles, en particulier pour les effets induits par la température. Toutefois, dans un contexte où des données environnementales ou d'exploitation sont incomplètes, il a été démontré que les réseaux de neurones artificiels [Connor et al., 1994] peuvent constituer un outil de régression pertinent même avec des réseaux de petite taille et peu coûteux en temps de calcul [Manzini, 2020].

Les réseaux de neurones artificiels regroupent une grande famille d'outils d'apprentissage utilisés pour la régression, la prédiction ou la classification de séries chronologiques. Un réseau de neurone artificiel consiste en un assemblage de couches de cellules de traitement appelées perceptrons, qui effectuent une combinaison simple à partir de plusieurs entrées. Les réseaux de neurones récurrents (RNN) sont une variante des réseaux de neurones où une récurrence est introduite entre les itérations du modèle. La capacité de RNN à faible nombre de couches à générer des modèles plus stable et plus précis que des modèles linéaires pour un surcoût faible en ressources a été observée par [Manzini, 2020] dans le cadre de la surveillance statique d'ouvrages d'art.

Des RNN ont été utilisés pour modéliser les séries temporelles de chaque capteur (sauf température et vent) en fonction des données des autres capteurs. L'objectif est d'apprendre les différentes configurations structurelles que peut prendre l'ouvrage. Comme cette approche utilise les données des capteurs à la fois comme entrée et comme sortie des modèles, la détection des anomalies basée sur l'étude d'un seul modèle ne peut pas être utilisée pour localiser une anomalie, qui peut se trouver soit dans la série temporelle modélisée, soit dans l'une des entrées. Il est donc proposé de générer plusieurs modèles pour chaque capteur afin de renforcer la localisation des anomalies dans l'ensemble des données. Pour chaque capteur, cinq ensembles d'entrées sont considérés. Les ensembles ont été formés en répartissant les capteurs du même type dans différents groupes (par

exemple, tous les ensembles comprennent au moins un capteur de déplacement, trois capteurs de tension, trois sondes de température, etc.)

Les modèles ont été entraînés à l'aide des données acquises en 2019 (8760 échantillons), en utilisant la fonction de performance MSE et en appliquant la régularisation bayésienne [Burden et al., 2008] [Doan et al., 2004] comme algorithme d'apprentissage. Pour chaque combinaison entrée/cible, plusieurs tailles de RNN ont été testées, allant de 1 à 3 couches cachées, chacune d'entre elles étant constituée d'un maximum de 15 perceptrons utilisant la fonction ReLU (définie comme la partie positive de son argument). Trois critères d'arrêts sont possibles : le gradient de performance (valeur seuil normalisée à  $10^{-7}$ ), le coefficient d'amélioration  $\mu$  (valeur seuil normalisée à  $10^{10}$ ) [Manzini, 2020] et le nombre d'itérations maximum fixé à 1000.

#### IV. APPLICATION SUR LES DONNÉES

Pour chaque capteur modélisé, les prédictions faites par les différents RNN sont comparées. Leurs performances sont évaluées en calculant l'erreur quadratique moyenne (RMSE) entre les prédictions et les observations dans un intervalle de vérification (Fig. 2). Cet intervalle de vérification est choisi parce qu'il a été démontré que la performance sur l'ensemble de la formation peut ne pas être pertinente pour la performance globale du modèle en raison des risques de surajustement (overfitting) [Manzini, 2020].





FIGURE 2. Illustration de l'intervalle d'entraînement (1), de vérification (2) et d'application (2) et (3)

Le meilleur modèle pour chaque capteur a été sélectionné, ses performances sont évaluées sur l'intervalle d'application en comparant le RMSE  $r$  à l'écart-type  $\sigma$  du capteur cible. Comme les variations saisonnières peuvent être dominantes, les mêmes valeurs  $r'$  et  $\sigma'$  sont calculées après avoir supprimé la moyenne mobile sur 7 jours des observations et des prédictions. Les performances obtenues pour différents capteurs sont résumées dans le Tableau 1. Comme les résultats sont similaires pour la plupart des capteurs du même type, et pour des raisons de commodité, un seul capteur de chaque type est présenté. Un exemple est présenté dans la Fig. 3.

Ces résultats mettent en évidence le potentiel des RNN pour modéliser la plupart des capteurs dans le système de surveillance étudié. Lorsque l'on considère chaque combinaison entrée/cible indépendamment, on observe que, même si pour certaines combinaisons,  $r$  peut varier du simple au double, les conclusions restent similaires dans la plupart des cas :  $r$  est toujours significativement plus petit que  $\sigma$  pour chaque combinaison d'entrées étudiée.



**FIGURE 3.** Illustration d'un modèle RNN d'un inclinomètre

**TABLEAU 1.** Comparaison des performances des modèles par type de capteur

Capteur	Unités	$r$	$\sigma$	$r'$	$\sigma'$
Déplacement	mm	0.35	8.21	0.24	1.76
Inclinomètre transversal	mrad	0.04	0.22	0.03	0.17
Inclinomètre longitudinal	mrad	0.04	0.09	0.03	0.04
Accéléromètre	mm/s <sup>2</sup>	1.44	3.15	1.39	2.71
Tension	kN	0.13	1.55	0.12	1.24
Corde vibrante	μm/m	6.75	27.23	4.18	6.16

## V. STRATÉGIE DE DÉTECTION PROPOSÉE

La stratégie de détection présentée dans cette étude consiste à (a) trouver des changements dans n'importe quel signal caractéristique des résidus des modèles, et (b) évaluer la significativité des changements potentiels par des tests statistiques.

À partir des résidus, de nouvelles séries sont générées en calculant le RMSE quotidien. Un algorithme de détection des points de changement est alors appliqué sur chacune de ces séries RMSE obtenues. Cet algorithme peut être représenté comme un problème d'estimation basé sur l'approche suivante. La série étudiée est segmentée en  $K$  intervalles temporels aux caractéristiques stables, avec  $K+1$  limites notées  $\tau_0, \tau_1, \dots, \tau_k$  ( $\tau_0$  et  $\tau_k$  étant respectivement le premier et le dernier élément de la série temporelle et  $\tau_1, \dots, \tau_{k-1}$  les points de changement). On note  $y(t)$  une série temporelle notée  $y=y(t_i)$ , avec  $\mu_k$  et  $\sigma_k$  respectivement sa moyenne locale et son écart type local sur l'intervalle  $[\tau_{k-1}, \tau_k]$ .

Le maximum de vraisemblance pour un tel modèle conduit à minimiser l'erreur quadratique moyenne pondérée sur chaque intervalle, ce qui conduit à la fonction de coût  $U_k$  (Eq. 1), où  $\mu'_k$  et  $\sigma'_k$  sont les estimations de la moyenne et de l'écart type sur le  $k$ -ième segment.

$$U_K(\tau_1, \dots, \tau_{k-1}) = \sum_{k=1}^K \frac{1}{\sigma'_k} \sum_{i=\tau_{k-1}+1}^{\tau_k} (y_i - \mu'_k)^2 \quad (1)$$

Lorsque le nombre total de points de changement  $K$  est inconnu, il peut être estimé en fixant une valeur maximale de points de changement  $K_{max}$  et en minimisant une fonction de coût pénalisée (Lavielle, 2005).

Une fois que le RMSE du modèle a été divisé en  $K$  segments, le type et l'importance des changements sont évalués à l'aide de tests multiples :

- Test de normalité (Kolmogorov-Smirnov),
- Test de tendance stationnaire (test de Kwiatkowski-Phillips-Schmidt-Shin et test de Dickey-Fuller augmenté) pour vérifier si la moyenne est une séquence constante par morceaux avant et après les points de changement,
- Test de Student pour vérifier si les moyennes locales avant et après les points de changement sont significativement différentes.

Tous les intervalles sont comparés à un (ou plusieurs) intervalle(s) de référence, qui peut être soit le premier intervalle généré, soit tous les intervalles chevauchant une période de référence. Lorsqu'un intervalle est détecté comme étant significativement différent de la référence, il est qualifié d'anormal pour le modèle étudié.


## VI. APPLICATION SUR LES DONNÉES DE SURVEILLANCE

Pour appliquer cette stratégie de détection aux données de surveillance, un capteur cible a été sélectionné : un capteur de déplacement situé à l'extrémité Nord du pont. Cinq RNN ont été entraînés en utilisant différentes entrées et un intervalle d'apprentissage d'un an. Trois scénarios ont été testés :


- Scénario n°1 : les données sont inchangées,
- Scénario n°2 : un décalage de 3 mm a été appliqué aux données du capteur cible (qui observe des variations annuelles d'environ 35 mm) pendant le mois d'août 2020. Ce décalage a été appliqué dans la direction opposée aux variations saisonnières (Fig. 4), de sorte que les valeurs de déplacement maximales ne dépassent pas celles observées l'année précédente et ne déclenchent pas une approche de détection à seuil simple,
- Scénario n°3 : un décalage similaire d'une amplitude de 6 mm a été appliqué à un capteur de déplacement situé à l'extrémité Sud du pont, et utilisé comme entrée dans un des cinq modèles (Fig. 5).

La stratégie de détection a été appliquée à tous les résidus pour chaque scénario, avec  $K_{max}=3$ . L'accent a été mis sur le test de Student (test à deux échantillons), car l'objectif est ici de détecter un changement de moyenne locale, en utilisant le premier intervalle comme référence. Le test considère comme hypothèse nulle que les données dans les intervalles comparés proviennent de distributions avec des moyennes égales et des variances égales mais inconnues. Le test ressort la valeur 1 s'il rejette l'hypothèse nulle (ce qui signifie que l'intervalle est considéré comme anormal) avec un niveau de significativité de 1%, et 0 dans le cas contraire. Ce seuil de significativité de 1 %

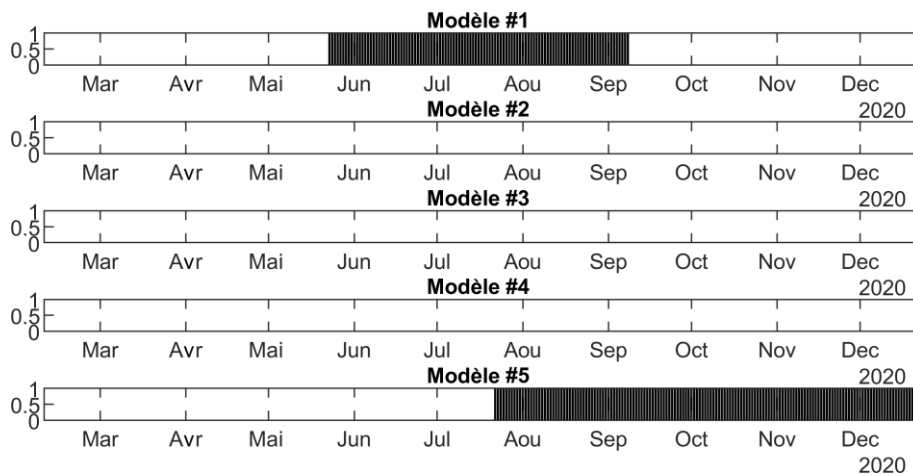
a été choisi sur la base des observations faites dans le cadre du scénario n°1. Les résultats obtenus pour tous les modèles dans le scénario n°1 sont présentés dans la Fig. 6.



**FIGURE 4.** Anomalie appliquée sur le capteur cible dans le scénario n°2



**FIGURE 5.** Anomalie appliquée sur un capteur d'entrée dans le scénario n°3



**FIGURE 6.** Résultats des tests pour tous les modèles du scénario n°1. Les barres noires correspondent à un échantillon identifié comme anormal.


Les résultats obtenus pour chaque scénario sont moyennés, ce qui permet d'obtenir un indicateur d'anormalité journalière (Fig. 7). Cet indicateur représente le pourcentage de modèles pour lesquels chaque jour a été identifié comme faisant partie d'un intervalle pour lequel le test a été rejeté.

Dans le scénario n°1, l'indicateur d'anomalie atteint la valeur maximale de 0.4. Bien que cette valeur ne suggère pas la présence d'une anomalie dans les données du capteur cible, elle met en avant des risques de faux-positif. Une alternative pourrait être de raccourcir les périodes de projection, ou

d'utiliser des intervalles de référence différents en été et en hiver, étant donné que le comportement du pont change de manière significative entre les saisons.

Dans le scénario n°2, la période anormale est clairement identifiée : du 31 juillet au 1er septembre, l'indicateur d'anomalie a une valeur de 1.0, ce qui signifie que cet intervalle de temps a été identifié comme anormal dans tous les modèles. Il convient également de noter qu'en raison des résidus plus élevés en août et de la valeur fixe de  $K_{max}$ , le premier modèle identifie en priorité l'intervalle du mois d'août grâce à la détection des points de changement, plutôt que l'ensemble de l'été comme dans le scénario n°1.

Enfin, dans le scénario n°3, en appliquant le décalage à l'une des entrées, seul un bref changement est observé sur un seul modèle, entre le 21 août et le 1er septembre. Cette période plus courte peut être due à l'utilisation de plusieurs capteurs en entrée, ce qui atténue les effets du décalage de l'un d'entre eux.



**FIGURE 7.** Indicateur d'anomalie quotidienne pour les trois scénarios considérés

Il ressort ainsi que, dans le contexte de l'application d'un type d'anomalie sur un seul capteur, les résultats obtenus montrent que l'indicateur proposé peut être utilisé pour détecter correctement l'anomalie dans la série temporelle. De plus, en comparant les scénarios #2 et #3, cet indicateur semble être capable de localiser l'anomalie dans l'ensemble de données, puisque la valeur maximale (1.0) n'est obtenue que lorsque le capteur cible est affecté.

## VII. CONCLUSIONS

La première partie de cet article a mis en évidence le potentiel des RNN pour l'analyse des données de surveillance. En utilisant des intervalles d'apprentissage et d'application d'un an, les prédictions faites par les modèles montrent une bonne concordance avec les observations pour la plupart des capteurs, tant pour les variations saisonnières que journalières. Les meilleurs résultats ont été obtenus pour les capteurs de déplacement, de tension et les inclinomètres : dans le contexte de ce cas d'étude, la méthodologie proposée apparaît comme plus adaptée à la surveillance statique, mais cette observation serait à confirmer dans un cas avec des données dynamiques plus variées.



Dans la deuxième partie de cet article, une approche de détection et de localisation des anomalies a été proposée. Cette approche est basée sur l'utilisation de modèles multiples utilisant des entrées différentes pour chaque capteur, en utilisant l'approche des points de changement sur les résidus pour l'étiquetage des intervalles de temps anormaux. Elle a été appliquée à un seul capteur et les résultats ont montré que l'indicateur calculé peut être utilisé pour détecter et localiser l'anomalie dans l'ensemble de données. D'autres travaux devront porter sur une approche plus généralisée, en prenant en compte plusieurs capteurs et plusieurs types d'anomalies pour en confirmer l'applicabilité.

## REFERENCES

1. Rytter, A. (1993). Vibrational based inspection of civil engineering structures.
2. Santos, J. P., Crémona, C., Calado, L., Silveira, P., & Orcesi, A. D. (2016) On-line unsupervised detection of early damage. *Structural Control Health Monitoring*, 23:1047-1069.
3. Concepcion, R. S., & Ilagan, L. C. (2019, March). Application of Hybrid Soft Computing for Classification of Reinforced Concrete Bridge Structural Health Based on Thermal-Vibration Intelligent System Parameters. In *2019 IEEE 15th International Colloquium on Signal Processing & Its Applications (CSPA)*, 207-212.
4. Cury, A., & Crémona, C. (2012). Pattern recognition of structural behaviors based on learning algorithms and symbolic data concepts. *Structural Control and Health Monitoring*, 19(2), 161-186.
5. Entezami, A., Sarmadi, H., Behkamal, B., & Mariani, S. (2020). Big data analytics and structural health monitoring: a statistical pattern recognition-based approach. *Sensors*, 20(8), 2328.
6. Santos, J. P., Cremona, C., Orcesi, A. D., & Silveira, P. (2017). Early damage detection based on pattern recognition and data fusion. *Journal of Structural Engineering*, 143(2), 04016162.
7. Kaloop, M. R., & Li, H. (2014). Multi input-single output models identification of tower bridge movements using GPS monitoring system. *Measurement*, 47, 531-539.
8. Manzini, N. (2020). Surveillance de santé structurale des ouvrages d'art incluant les systèmes de positionnement par satellites, Doctoral dissertation, Université Paris-Est.
9. Manzini, N., Orcesi, A. D., Thom, C., Brossault, M.-A., Botton, S., Ortiz, M. & Dumoulin, J. (2020): Performance analysis of low-cost GNSS stations for structural health monitoring of civil engineering structures, *Structure and Infrastructure Engineering*, DOI: 10.1080/15732479.2020.1849320
10. Burden, F., & Winkler, D. (2008a). Bayesian regularization of neural networks. In *Artificial neural networks*, Springer, 23-42.
11. Doan, C. D., & Liang, S. (2004). Generalization for multilayer neural network bayesian regularization or early stopping. *Proceedings of Asia Pacific Association of Hydrology and Water Resources 2nd Conference*, 5-8.
12. Lavielle, M. (2005). Using penalized contrasts for the change-point problem. *Signal processing*, 85(8), 1501-1510.