

Titre du projet

Physical models recognition, inversion and explainability by AI: application to structures and monitoring data

Laboratoire, institution

Université Gustave Eiffel – Laboratoires EMGCU et LIGM

Équipe ou projet dans le laboratoire

Laboratoires EMGCU (Franziska Schmidt) et LIGM (Jean-François Bercher)

Partenaire international envisagé pour la poursuite en stage (mai-août)

Politecnico de Milano / TU München

Nom et adresse e-mail des tuteurs

Franziska.schmidt@univ-eiffel.fr

jf.bercher@esiee.fr

Filière visée (Informatique, Cybersécurité, Datascience et intelligence artificielle, Systèmes embarqués, Systèmes électroniques intelligents, Génie industriel, Biotechnologie et e-santé, Énergie)



Datascience, Informatique, ...

Présentation générale du sujet (environ 5 à 10 lignes)

L'objectif général est de développer des techniques d'analyse du signal, d'intelligence artificielle (IA) et d'apprentissage machine (ML) pour la modélisation, la prise de décision et la résolution de problèmes tels qu'ils se présentent dans les applications physiques, et en particulier dans le contexte du pesage par ponts instrumentés. Les travaux se dérouleront dans un contexte multidisciplinaire et bénéficieront de l'expertise conjointe de chercheurs en IA – informatique - traitement du signal, ainsi qu'en génie civil. Des problèmes réels et des données réelles (mesurées sur ouvrages d'art) sont disponibles qui permettront de nourrir et confronter les méthodes à la réalité terrain. Les applications visées sont la caractérisation du trafic et la surveillance de l'état des structures.

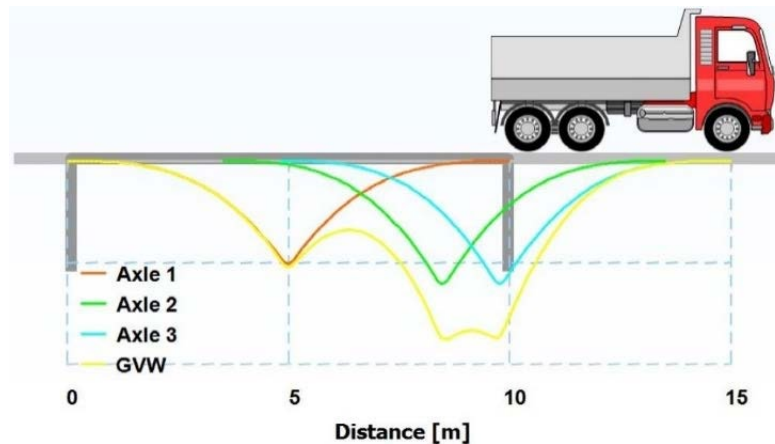
Objectif du projet (environ 10 à 20 lignes)

Le pesage en marche par ponts instrumentés consiste à enregistrer des signaux de déformation ou de contraintes lors du passage de poids lourds sur un ouvrage. Ces mesures permettent d'accéder à des informations à la fois sur les poids-lourds (dimension, nombre d'essieux, poids sur chaque essieu), et en principe sur l'ouvrage lui-même.

Par calcul inverse, il est alors possible de remonter jusqu'aux poids et dimensions de ces poids lourds, pourvu que la ligne d'influence (réponse de l'ouvrage) soit connue.

Ce calcul inverse est "mal posé" et sujet à incertitudes. Divers paramètres interviennent, liés à l'ouvrage (défauts structurels de la structure, chaussée avec uni médiocre induisant des effets dynamiques), au poids lourd (position transversale dans la voie, type d'amortisseur, présence ou non de déflecteur d'air, ...) ou externe (conditions météorologiques, présence multiple, ...).

Diverses campagnes de mesure de pesage par ponts instrumentés ont été menées, avec enregistrement des signaux temporels et des valeurs de ces paramètres influant sur la précision de l'évaluation des poids et dimensions des poids lourds. Ces campagnes de pesage ont été menées sur des ponts cadres (Senlis, Saint-Avold) et métalliques (viaduc de Millau).



La première étape du travail consiste à collecter et explorer (EDA – *exploratory data analysis*) toutes les données des expérimentations, afin de constituer une base de données sur laquelle appuyer les analyses numériques à mener par la suite. La deuxième étape porte sur l'étalonnage d'un pont instrumenté, dont l'objectif est d'estimer la soi-disant "ligne d'influence du pont", soit par les approches classiques de calcul inverse, soit par des approches nouvelles de type *physics-based deep learning*. La troisième étape s'intéressera à la formulation du problème de pesage en marche, puis à sa résolution par des méthodes avancées d'optimisation. Des résultats sont d'ores et déjà disponibles dans l'équipe, qui pourront être complétés par des techniques de *machine learning* (*clustering* préalable), traitement correctif a posteriori par *machine learning*, afin d'accroître les performances. La quatrième étape se concentrera sur l'évaluation du système et sur l'analyse des paramètres susceptibles d'affecter la précision des pesées, qui permettra éventuellement de remettre en cause et de corriger les modèles développés aux étapes précédentes. Enfin, en fonction de l'avancée du projet, il pourra être intéressant d'investiguer quels sont les paramètres de structure et de santé de l'ouvrage qui peuvent être extraits de la ligne d'influence.

Le projet permettra à l'élève de développer ses compétences en *machine learning*, optimisation mathématique et du traitement du signal, et en développement en langage Python. Il appréhendera également le contexte de la recherche pluridisciplinaire et expérimentale.

Bibliographie

Y. Bar-Sinai, S. Hoyer, J. Hickey, and M. P. Brenner. "Learning data-driven discretizations for partial differential equations." *PNAS*, 116 (31), 15344-15349, 2019.

F. Doshi-Velez, and B. Kim. "Towards a rigorous science of interpretable machine learning," E-print arXiv:1702.08608, 2017.

I. Goodfellow, Y. Bengio, A. Courville, "Deep Learning." MIT Press, 2016. <http://www.deeplearningbook.org>

J. B. Harley and D. Sparkman, "Machine learning and Non Destructive Evaluation: Past, present, and

future”, AIP Conference Proceedings 2102, 090001 (2019)

Y. LeCun, Y. Bengio, and G. Hinton, “Deep Learning.” *Nature*, 521, 436-444, 2015.

Z. Long, Y. Lu, X. Ma, and B. Dong, “PDE-Net: Learning PDEs from Data,” *ICML 2018*.

M. Raissi, “Deep hidden physics models: Deep learning of nonlinear partial differential equations”, *J. Mach. Learn. Res.* 19 (1) (2018) 932–955.

M. Raissi, P. Perdikaris, G.E. Karniadakis, “Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations,” *Journal of Computational Physics*, Volume 378, Pages 686-707, 2019.

S. Shalev-Shwartz and S. Ben-David, “Understanding Machine Learning: From Theory to Algorithms”, Cambridge University Press (2014)