



**Le laboratoire de Mathématiques et Informatique pour la Complexité et les Systèmes
présente**

L'AVIS DE SOUTENANCE

De Monsieur Marien Chenaud

à l'école doctorale INTERFACES, CentraleSupélec, Université Paris-Saclay, qui
soutiendra publiquement ses travaux de thèse de doctorat intitulés :

**“Hybrid Scientific Machine Learning Methods for Surrogate Modeling of Physical
Systems”**

Sous la direction de Monsieur Frédéric Magoulès et la co-supervision de Monsieur José Alves.

Le vendredi 25 septembre 2026 à 14h30

À l'école CentraleSupélec, en **Amphi II** - Bâtiment Eiffel.

Lien public de visio-conférence : à venir

Membres du jury :

Mme Jian CAO, Professeure des Universités, Northwestern University, Rapporteuse & Examinatrice

M. Francisco PERIAGO, Professeur des universités, Universidad Politécnica de Cartagena, Rapporteur
& Examineur

M. Guillaume CHARPIAT, Chargé de Recherche, Inria, Université Paris Saclay, Examineur

Mme Mathilde MOUGEOT, Professeure des universités, ENS Paris Saclay, Examinatrice

M. David RYCKELYNCK, Professeur des Universités, Mines Paris PSL, Examineur

Résumé :

Le développement de jumeaux numériques efficaces, robustes et fiables est essentiel
pour la modélisation des systèmes mécaniques, des lois constitutives des matériaux à

la déformation élastique et plastique des structures industrielles. Dans cette thèse, nous traitons des méthodes d'apprentissage profond pour le développement de ces modèles. Nous nous concentrons sur les méthodes hybrides intégrant méthodes numériques et modèles d'apprentissage profond, dans l'objectif de combiner l'expressivité des réseaux de neurones avec la robustesse et les garanties de convergence des schémas numériques classiques. Dans une première partie, nous démontrons que la différentiation numérique, issue de la formulation éléments finis du problème physique, améliore l'apprentissage informé par la physique. Les modèles hybrides résultants montrent une capacité accrue pour les problèmes non-analytiques avec des conditions aux bords plus générales. Ensuite, nous traitons des réseaux de neurones sur graphes dans des domaines irréguliers, et nous prouvons une amélioration des capacités de généralisation. Nous proposons une stratégie d'augmentation de la connectivité pour améliorer la diffusion d'informations dans ces domaines complexes. Dans une troisième partie, nous développons un couplage hybride entre les modèles d'apprentissage profond étudiés et un solveur numérique, conduisant à une convergence et un temps de calcul améliorés en comparaison avec des modèles numériques ou d'apprentissage purs.

Abstract:

Efficient, robust, and reliable surrogate models are crucial for modeling mechanical systems, ranging from constitutive material laws to the elastic and plastic deformation of industrial structures. In this thesis, we explore deep learning approaches for the development of such surrogate models. This thesis focuses on hybrid approaches that integrate numerical methods and deep learning models, aiming to combine the expressive power of neural networks with the robustness and theoretical convergence guarantees of classical numerical schemes. First, we demonstrate that the use of numerical differentiation, based on the finite element formulation of the physical problem, improves data-free physics-informed training. The resulting hybrid models have the ability to address complex, non-analytic problems with general boundary conditions. Next, we investigate graph neural network architectures on irregular domains and demonstrate improved generalization performance. We further propose an edge-augmentation strategy to enhance information flow across such complex domains. Finally, we develop a hybrid coupling between the proposed deep learning models and numerical solvers, demonstrating improved convergence and computational efficiency compared to purely numerical or purely machine learning methods.