

Avis de Soutenance

Monsieur Valentin MOUTON

Génie mécanique

Soutiendra publiquement ses travaux de thèse intitulés

Apprentissage profond réductionniste pour l'ingénierie mécanique

Travaux dirigés par Monsieur Joël PERRET-LIAUDET et Monsieur Emmanuel RIGAUD

Soutenance prévue le **lundi 07 septembre 2026** à 9h00

Lieu : École centrale de Lyon, bâtiment W1, 36 avenue Guy de Collongue, 69130 Écully, FRANCE

Salle : Amphi 203

Composition du jury proposé

M. Joël PERRET-LIAUDET	Maître de conférences HDR	École centrale de Lyon	Directeur de thèse
M. Germain FORESTIER	Professeur des universités	ENSISA / Université de Haute-Alsace	Rapporteur
M. Édouard OYALLON	Chargé de recherche HDR	CNRS, Sorbonne Université	Rapporteur
Mme Céline HUDELOT	Professeure des universités	CentraleSupélec	Examinatrice
M. Benjamin GUEDJ	Directeur de recherche	Inria / University College London	Examineur
M. Loïc SALLES	Associate professor	Université de Liège	Examineur
M. Adrien MELOT	Inria Rennes	Invité	

Mots-clés : apprentissage profond, régression scientifique, données tabulaires, lois d'échelle, modèles de substitution, ingénierie mécanique

Résumé :

L'ingénierie mécanique contemporaine est confrontée à un paradoxe croissant : l'augmentation de la complexité des systèmes, qui impose le traitement de phénomènes nouveaux (non-linéarités, interactions multi-physique), se heurte à l'explosion du coût computationnel des méthodes de simulation numérique. Si le paradigme de la science pilotée par les données est perçu depuis le début du XXI^e siècle comme une voie prometteuse, notamment grâce à l'essor de l'apprentissage profond, son application aux sciences de l'ingénieur reste entravée par la rareté des données, rendant difficile l'extraction de représentations robustes des physiques sous-jacentes. Ce travail de thèse est en rupture avec les approches existantes qui tentent majoritairement d'appliquer les paradigmes du traitement automatique des langues ou de la vision par ordinateur sans tenir pleinement compte des spécificités des sciences de l'ingénieur. À ce titre, nous développons une méthodologie qualifiée de « réductionniste ». Contrairement aux modèles de fondation supposés généralistes, cette approche repose sur l'utilisation de solveurs physiques rapides pour générer des datasets synthétiques massifs. En exploitant la structure des données pour s'affranchir du mécanisme d'attention, cette stratégie permet d'obtenir la diversité et le volume de données nécessaires à l'entraînement de réseaux de neurones profonds, le tout sur du matériel grand public d'entrée de gamme. La thèse s'articule autour de trois contributions majeures, composées de deux études de cas. Premièrement, un problème de régression directe appliqué à la conception des transmissions par engrenages montre la viabilité de l'entraînement de perceptrons multicouches sur un dataset de trente et un millions d'échantillons, une échelle inédite en sciences de l'ingénieur. Deuxièmement, ce travail est étendu à la régression inverse, avec la conception de méta-interfaces frictionnelles à loi de frottement pilotée. En exploitant un dataset de deux cents millions d'échantillons, ces travaux mettent en lumière le compromis entre inférence amortie et fidélité fonctionnelle, tout en illustrant la capacité des auto-encodeurs variationnels, avec ou sans conditionnement, à capturer la multimodalité de l'espace des solutions. Enfin, une étude empirique permet de caractériser les conditions menant à l'apparition de lois d'échelle en régression scientifique. En comparant nos résultats à des corpus de référence allant de la finance décentralisée à l'astrophysique, cette thèse montre qu'un régime d'approximation optimal peut être atteint en traitant des phénomènes déterministes, le tout couplé un échantillonnage dense et uniforme de l'espace des solutions. Ce travail expose enfin les limites liées à l'arithmétique flottante induites par l'entraînement de modèles de grande taille sur des données tabulaires scientifiques.

Summary:

A growing paradox defines modern mechanical engineering: as system complexity increases, the computational cost of numerical simulations rises exponentially due to the need to model novel phenomena (e.g., non-linearities and multi-physics interactions). Although data-driven science has emerged as a powerful alternative---driven by the rise of deep learning---its utility in engineering remains constrained by the scarcity of high-fidelity datasets capable of capturing underlying physics. This thesis challenges the prevailing trend of adopting paradigms from Natural Language Processing (NLP) and Computer Vision without fully accounting for the unique constraints of the engineering sciences. We therefore propose a methodology termed "Reductionist Deep Learning." In contrast to general-purpose foundation models, this approach leverages fast physical solvers to generate massive synthetic datasets. By employing dense and uniform sampling of the design space, we demonstrate that deep neural networks---without relying on attention mechanisms---can be effectively trained on consumer-grade hardware. Our contributions are threefold: first, we implement direct regression for gear transmission design using a dataset of 31 million samples, representing an unprecedented scale in the field; second, we address inverse regression for friction interfaces with controlled friction behavior using 200 million samples, analyzing the trade-off between computational efficiency and functional fidelity while demonstrating how Variational Autoencoders (both conditional and unconditional) capture the multimodality of the solution space. Finally, through an empirical comparison across diverse corpora---ranging from decentralized finance to astrophysics---we identify the conditions for the emergence of scaling laws in scientific regression, proving that an optimal approximation regime can be achieved through efficient modeling and dense sampling of deterministic phenomena. Lastly, we characterize the computational bottlenecks introduced by floating-point arithmetic when training large-scale models on scientific tabular data.