

Computer Sciences
Apprentissage basé sur la physique
Physics-based learning

Mots-clés : processus physique, apprentissage profond, réseau de neurones

Project description:

Les modèles basés sur la physique sont de plus en plus souvent utilisés dans des domaines tels que hydrologie, science du climat, science des matériaux, agriculture et chimie computationnelle[1]. Ces modèles ont plusieurs limitations bien connues en raison des représentations simplifiées des processus physiques modélisés ou défis dans la sélection des paramètres appropriés. Il existe une formidable opportunité de systématiquement faire progresser la modélisation dans ces domaines en utilisant des méthodes d'apprentissage automatique. Nous proposons dans ce stage la mise en oeuvre d'une nouvelle méthodologie pour combiner des modèles basés sur la physique avec des méthodes d'apprentissage en profondeur de pointe pour tirer parti de leurs atouts complémentaires.

Même si les modèles basés sur la physique sont basés sur des lois physiques connues qui régissent les relations entre l'entrée et variables de sortie, la majorité des modèles basés sur la physique sont nécessairement des approximations de la réalité en raison de la connaissance de certains processus, ce qui introduit des biais. De plus, ils contiennent souvent un grand nombre de paramètres dont les valeurs doivent être estimées à l'aide de données observées limitées [2]. L'apprentissage qui permet de choisir les combinaisons de paramètres qui se traduisent par les meilleures performances sur les données d'entraînement est coûteuse et explore l'espace des combinaisons de paramètres de manière exhaustive.

Une Modélisation efficace des processus physiques (qui peuvent se dérouler et interagir à plusieurs échelles dans l'espace et dans le temps) dépend de la capacité des modèles ML à extraire des modèles complexes des données et à former des modèles d'apprentissage qui nécessitent beaucoup de données étiquetées, ce qui est rare dans la plupart des contextes pratiques[3].

Nous proposons de mettre en oeuvre un modèle de modélisation d'un processus physique et d'incorporer des lois physiques explicites telles que la conservation de l'énergie ou la conservation de la masse 1. Ceci est fait en introduisant des variables supplémentaires dans la structure récurrente pour garder une trace des états physiques qui peut être utilisé pour vérifier la cohérence avec les lois physiques.




Figure 1: Thèse de T. Ullman (2015) sur les théories de l'apprentissage intuitif de la physique. les jeunes enfants comprennent la mécanique très tôt, bien avant d'apprendre à marcher. Peut-on reproduire cette connaissance empirique intuitive. Se généralise à l'interaction sociale et à la psychologie.

Modèle de réseau neuronal récurrent guidé par la physique combinant RNN et basé sur la physique modèles pour exploiter leurs forces complémentaires et améliorer l'apprentissage de la tâche

En principe:

$$L = \text{Perte supervisée}(\hat{Y}_{\text{prédit}}, Y_{\text{true}}) + \lambda \text{Pénalité basée sur la physique} \quad (1)$$

(par exemple, RMSE en régression ou entropie croisée en classification). Le deuxième terme représente la pénalité basée sur la cohérence physique. Pour favoriser une cohérence physique solutions, un autre avantage secondaire majeur de l'inclusion d'une pénalité basée sur la physique dans la fonction de perte est qu'elle peut être appliquée même aux instances pour lesquelles les données de sortie (observées) ne sont pas disponibles car la pénalité basée sur la physique peut être calculée comme tant que les données d'entrée (pilote) sont disponibles.

Par exemple. Les pénalités basées sur la physique peuvent être des contraintes d'angle, de la vitesse, etc.

Les modèles basés sur la physique / mécaniste contiennent beaucoup de connaissances du domaine qui vont bien au-delà de ce qui peut être capturé comme contraintes de telles lois de conservation. Pour tirer parti de ces connaissances, nous générons une grande quantité d'observations "synthétiques" en exécutant des modèles basés sur la physique pour une variété d'entrées (qui sont facilement disponibles) et en utilisant les observations pour pré-entraîner le modèle [1].

Résultats attendus: programmer un modèle d'apprentissage basé sur la physique pour un problème jouet simple pour des données continues. Proposer des améliorations pour la convergence de ces données. Mettre en oeuvre un prototype de ce modèle pour l'analyse d'observations physiques Gains attendus:

- très peu de données d'entraînement
- robuste aux menaces de sécurité pour l'apprentissage en profondeur
- capacité à intégrer les connaissances encodées dans un modèle basé sur la physique
- garantissant une précision de prédiction élevée

Profil et compétences requises Capacité à comprendre et développer des algorithmes d'apprentissage adaptatif et à traiter les données médicales, les indexer et les utiliser dans un système opérationnel pour réaliser la mission décrite ci-dessus. Compétences en programmation: Python ou en C / C ++. Une pratique de Tensorflow et Pytorch serait un plus. La pratique du français n'est pas obligatoire.

Qualités professionnelles recherchées: autonomie, sens de la relation pour interagir avec les équipes de recherche et de société, motivation pour les nouvelles technologies, créativité pour mettre en place une solution innovante.

Contact: vincent Vigneron, Hichem Maaref, leonardo Duarte
(`{vincent.vigneron,hichem.maaref}@univ-evry.fr`, `leonardo.duarte@fca.unicamp.br`)
Phone: +33 6 635 687 60

References

- [1] Michael Kellman. *Physics-based Learning for Large-scale Computational Imaging*. PhD thesis, EECS Department, University of California, Berkeley, Aug 2020.
- [2] Michael Kellman, Michael Lustig, and Laura Waller. How to do physics-based learning, 2020.
- [3] Rui Wang, Karthik Kashinath, Mustafa Mustafa, Adrian Albert, and Rose Yu. *Towards Physics-Informed Deep Learning for Turbulent Flow Prediction*, page 1457–1466. Association for Computing Machinery, New York, NY, USA, 2020.