

Offre de stage :

Hybridation de réseaux de neurones profonds et de modèles physiques pour la modélisation de phénomènes dynamiques en environnement

Niveau : M2

Cadre :

- encadrant principal : Patrick Gallinari (patrick.gallinari@lip6.fr)
- co-encadrant(s) : Vivien Mallet (Vivien.Mallet@inria.fr) Ibrahim Ayed (Ibrahim.Ayed@lip6.fr), Emmanuel de Bezenac (Emmanuel.De-Bezenac@lip6.fr)
- Laboratoire(s) : LIP6, LOCEAN
- Équipe(s) : MLIA

Lieu : 4 place Jussieu, Paris, France

Contexte scientifique :

L'observation de phénomènes physiques génère des quantités gigantesques de données spatio-temporelles complexes. L'analyse et la modélisation de ces données présentent plusieurs sources de difficultés. Les observations donnent une information incomplète et imparfaite du phénomène qui les a générées, la dynamique sous-jacente est complexe et mal connue, etc. Une direction de recherche récente vise à combiner des connaissances a priori provenant de la physique et des approches traitement de données basées sur les réseaux de neurones profonds (Deep Learning) pour modéliser ces phénomènes. Par exemple, l'utilisation de connaissances physiques a été récemment utilisée pour apprendre la dynamique de processus physiques complexes pour la modélisation d'observations satellitaires (de Bezenac 2018). L'apprentissage de dynamiques à partir d'observations incomplètes est abordé dans (Ayed 2019). De nombreux travaux commencent à explorer cette problématique comme par exemple (Chang 2018, Haber 2018, Long 2018, Lu 2018, Raissi 2018). Une publication récente de la revue Nature dresse les perspectives de cette approche pour le domaine de la géophysique (Reichstein 2019)

Objectifs :

Nous proposons d'explorer l'incorporation de connaissances physiques dans des modèles neuronaux. Nous considérons des données issues de l'observation de systèmes dynamiques. Nous supposons que les connaissances physiques sont fournies sous la forme d'équations différentielles (advection, réaction-diffusion, etc..) qui donnent des informations sur l'évolution temporelle ou spatio-temporelle des phénomènes étudiés. L'objectif est d'utiliser cette information au sein de modèles neuronaux. Une première approche consiste à contraindre la solution par des lois exprimées par les équations aux dérivées partielles décrivant le phénomène. Dans (de Bezenac 2018) la solution d'une équation d'advection diffusion est intégrée comme module dans un réseau de neurone qui apprendra à estimer à partir des données, le vecteur transport associé à cette

équation. L'objectif de ce stage est 1) de généraliser cette démarche à d'autres familles d'équations, 2) de proposer une intégration des contraintes physiques directement sous la forme d'équations différentielles. Les domaines d'application sont en environnement avec en particulier l'observation de données satellitaires et la modélisation de données caractérisant la qualité de l'air issues de capteurs couvrant une large partie de la terre.

Références bibliographiques :

Ayed, I., de Bézenac, E., Pajot, A., Brajard, J. and Gallinari, P. 2019. Learning Dynamical Systems from Partial Observations. ArXiv (2019).

Chang, B., Meng, L., Haber, E., Ruthotto, L., Begert, D. and Holtham, E. 2018. Reversible Architectures for Arbitrarily Deep Residual Neural Networks. AAI (2018), 2811–2818.

de Bezenac, E., Pajot, A. and Gallinari, P. 2018. Deep Learning For Physical Processes: Incorporating Prior Scientific Knowledge. ICLR (2018).

Haber, E., Lensink, K., Triester, E. and Ruthotto, L. 2019. IMEXnet: A Forward Stable Deep Neural Network. ICML (2019).

Long, Z., Lu, Y. and Dong, B. 2018. PDE-Net 2.0: Learning PDEs from Data with A Numeric-Symbolic Hybrid Deep Network. (2018).

Lu, Y., Zhong, A., Li, Q. and Dong, B. 2018. Beyond Finite Layer Neural Networks: Bridging Deep Architectures and Numerical Differential Equations. ICML (2018), 3282–3291.

Raissi, M. 2018. Deep Hidden Physics Models: Deep Learning of Nonlinear Partial Differential Equations. Journal of Machine Learning Research. 19, (2018), 1–24.

Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N. and Prabhat, & 2019. Deep learning and process understanding for data-driven Earth system

Compétences souhaitées :

- Apprentissage statistique
- Réseaux de neurones
- Intérêt pour les applications ciblant l'environnement