

Stage M1

Estimation de mod les spatio-temporels par deep learning

Laboratoire d'accueil : Equipe G ostatistique, Centre de G osciences, Mines Paris PSL, Fontainebleau et MIA Paris Saclay

Encadrants : Lucia Clarotto (AgroParisTech), Mike Pereira et Thomas Romary (Mines Paris)

Dur e : 3 mois (  partir de Mai 2024)

Comp tences recherch es : Statistiques, statistiques spatiales, deep learning, programmation informatique (Python et/ou Julia)

Gratification : Selon les conditions actuelles de r mun ration l gale des stagiaires (environ 600 euros/mois)

Contexte

En g ostatistique, les processus gaussiens sont couramment utilis s pour mod liser les donn es spatiales et spatio-temporelles, car ils permettent de pr dire simplement la variable d'int r t en des sites non mesur s tout en quantifiant l'incertitude de pr diction. Dans ce cadre, les donn es sont consid r es  tant issues d'une r alisation particuli re d'un champ al atoire gaussien dont la fonction de covariance doit  tre estim e   partir des donn es. Une approche classique pour l'estimation des param tres consiste   choisir une famille param tr e de fonctions de covariance, puis   choisir les param tres qui maximisent la vraisemblance associ e aux donn es. Dans la pratique, cette approche repr sente souvent un goulot d' tranglement, car la seule  valuation de la fonction de vraisemblance peut rapidement devenir co teuse d'un point de vue informatique quand la quantit  de donn es devient importante, notamment en spatio-temporel. Il est donc souhaitable de disposer de m thodes permettant de d duire les param tres d'un mod le de covariance sans passer par la fonction de vraisemblance.

R cemment, plusieurs m thodes utilisant des r seaux de neurones (notamment CNN et GNN) ont  t  propos es pour r pondre   ce probl me. Deux principales approches peuvent  tre mentionn es. La premi re vise   former un r seau neuronal capable d'identifier les param tres d'une fonction de covariance,   partir d'une r alisation d'un champ al atoire gaussien avec cette covariance [2, 3, 6, 4]. La seconde vise plut t   obtenir une approximation de la vraisemblance en fonction des param tres et des observations, ce qui permet d'obtenir un proxy facile   calculer [5]. La surface de vraisemblance neuronale peut alors  tre maximis e pour un ensemble fixe d'observations afin d'obtenir un estimateur des param tres du mod le associ    ces observations.

Objectifs

Ce stage vise   d velopper et valider des architectures adapt es au contexte spatio-temporel. Un enjeu de cette g n ralisation est l'estimation d'un plus grand nombre de param tres, qui n'a jamais  t  mise en  uvre pour l'instant. Une premi re  tape consistera   identifier et comparer les diff rentes strat gies mises en avant dans la litt rature, dans un premier temps sur des jeux de donn es simul es.

Dans un second temps, on cherchera à adapter une ou plusieurs de ces approches au cas spatio-temporel, notamment dans les modèles issus des équations aux dérivées partielles stochastiques [1]. L'approche retenue sera validée sur un jeu de données réelles de mesures du rayonnement solaire.

Comment postuler ?

Pour postuler ou si vous avez des questions, veuillez contacter Lucia Clarotto (lucia.clarotto@agroparistech.fr), Mike Pereira (mike.pereira@minesparis.psl.eu) et Thomas Romary (thomas.romary@minesparis.psl.eu). Merci de nous envoyer un CV ainsi qu'une lettre de motivation.

References

- [1] Lucia Clarotto, Denis Allard, Thomas Romary, and Nicolas Desassis. The spde approach for spatio-temporal datasets with advection and diffusion. *arXiv preprint arXiv:2208.14015*, 2022.
- [2] Florian Gerber and Douglas Nychka. Fast covariance parameter estimation of spatial gaussian process models using neural networks. *Stat*, 10(1):e382, 2021.
- [3] Amanda Lenzi, Julie Bessac, Johann Rudi, and Michael L Stein. Neural networks for parameter estimation in intractable models. *Computational Statistics & Data Analysis*, 185:107762, 2023.
- [4] Matthew Sainsbury-Dale, Jordan Richards, Andrew Zammit-Mangion, and Raphaël Huser. Neural bayes estimators for irregular spatial data using graph neural networks. *arXiv preprint arXiv:2310.02600*, 2023.
- [5] Julia Walchessen, Amanda Lenzi, and Mikael Kuusela. Neural likelihood surfaces for spatial processes with computationally intensive or intractable likelihoods. *arXiv preprint arXiv:2305.04634*, 2023.
- [6] Christopher K Wikle and Andrew Zammit-Mangion. Statistical deep learning for spatial and spatio-temporal data. *arXiv preprint arXiv:2206.02218*, 2022.