

Machine learning et respect des lois de la physique : application à l'imagerie sismique

Léo DE SOUZA

En 2019, Raissi et al. ont montré comment il est possible de coupler des approches de *machine learning* avec le respect des lois de la physique, sous la dénomination de Physics-Informed Neural Networks (PINN) [1]. Les applications concernent la résolution d'équations différentielles (i.e. le problème direct) et la résolution de problèmes inverses (retrouver les paramètres qui contrôlent le phénomène physique, par exemple la propagation des ondes, à partir d'observations). C'est cette deuxième approche qui sera développée dans ma thèse.

D'un côté, les réseaux de neurones profonds permettent en théorie de représenter toute fonction. L'apprentissage est souvent compliqué et dans les problèmes physiques les observables sont peu nombreuses et coûteuses à acquérir. D'un autre côté, les équations de la physique représentent une information cruciale que les approches de *machine learning* traditionnelles ne prennent pas en compte. L'approche de Raissi et al., 2019, comble cette lacune. La fonction objective (*loss function*) dans les réseaux de neurones comprend plusieurs termes pour s'assurer que les données prédisent bien les observables disponibles et que les lois de la physique sont également respectées [1]. Ce second terme peut être vu comme une régularisation, indispensable pour éviter de sur-exploiter des données bruitées (*overfitting*). Les algorithmes d'auto-différentiation, au sein des réseaux de neurones, permettent d'estimer les meilleurs paramètres qui minimisent la fonction objective.

Cette approche est très attractive et sera étendue et modifiée pour être applicable au domaine de l'imagerie sismique. Dans le cadre de l'acquisition sismique, une source active provoque des ondes acoustiques / élastiques qui se propagent dans le sous-sol (Figure 1). Des capteurs, souvent en surface, enregistrent la pression ou le déplacement des particules en fonction du temps. L'objectif est de déterminer des champs de vitesses de propagation des ondes (et tout autre champ qui contrôle la propagation des ondes comme la densité, l'anisotropie...).

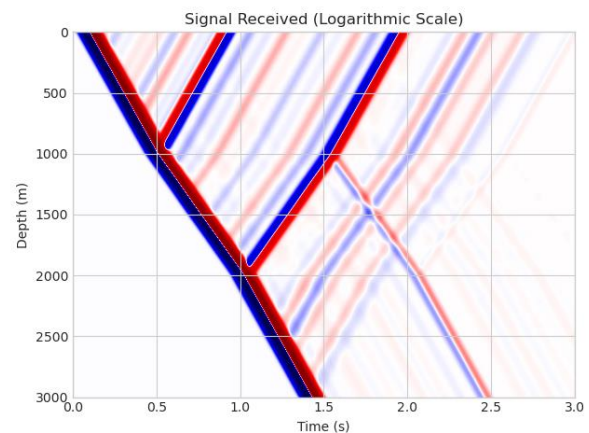


Figure 1: Propagation d'une onde sismique.

Par rapport aux premiers cas illustrés dans la littérature autour du couplage entre *machine learning* et respect de la physique, l'imagerie sismique offre des particularités à prendre en compte :

- L'aspect propagatif des ondes fait que les champs d'onde ne sont pas lisses et que contrôler qu'un champ d'onde vérifie bien l'équation des ondes doit se faire a priori en un très grand nombre de points ;
- La fonction coût traditionnelle en imagerie sismique contient des minima secondaires. Comment l'approche PINN peut-elle gérer cette difficulté ? Comment tirer avantage du contenu fréquentiel des données ?
- Enfin, le nombre de paramètres à estimer est potentiellement très grand. Comment aborder cette thématique et jouer avec l'architecture des réseaux de neurones ?

L'objectif de la thèse est donc de développer une approche de *machine learning* couplée aux lois de la physique, dans le cadre de l'imagerie sismique.

Références bibliographiques

- [1] Chauris, H., 2019, Full waveform inversion, Seismic Imaging: a practical approach, J.-L. Mari and M. Mendes (Eds.), EDP Sciences, 123–145.
[2] Raissi, M., Perdikaris, P., Karniadakis G.E., 2019, Physics-informed neural networks, J. Comput. Phys. 378, 686–707.