

Post-doctoral position

Online/Incremental Learning for spatial applications

Contexte et objectifs

Exécuter des algorithmes d'apprentissage de manière automatique à bord d'un satellite pourrait offrir de nombreux avantages tels que la réduction de la bande passante, du stockage de données, et du temps de réponse. De nombreuses applications telles que la réponse aux catastrophes naturelles pourraient bénéficier d'un tel système. Or, en général, l'algorithme de Machine Learning est entraîné au sol avant d'être intégré au satellite. Néanmoins, une fois embarqué dans le satellite, cet algorithme est confronté à plusieurs problématiques: i) la différence de type de données en entrée par rapport à celui sur lequel il a été entraîné ; ii) la multitude de types d'environnement, en tenant en compte également des changements saisonniers et des différences de conditions d'éclairage ; iii) le vieillissement des capteurs qui induit un drift dans les données.

Ces problématiques, liées à la variabilité des données, posent plusieurs défis concernant la mise à jour du modèle. Les modèles exécutés dans un satellite sont généralement entraînés et réajustés au sol à partir de données transmises par le satellite. Pour préserver la capacité de stockage et la bande passante du satellite, il serait intéressant de pouvoir déterminer les données utiles à transmettre au segment sol afin de réentraîner efficacement le modèle, tout en évitant le problème de « l'oubli catastrophique » [GoodFellow 2015] dont souffrent les systèmes d'IA actuels. En effet, des changements mineurs dans les poids synaptiques de quelques neurones, peuvent entraîner une défaillance de tout le réseau. Il s'agit donc ici de **remettre en cause le paradigme de l'apprentissage off-line supervisé** afin de permettre une adaptation dynamique du système à son environnement. Lors d'un apprentissage dynamique le réseau doit ainsi être en mesure d'absorber de nouvelles informations, en modifiant partiellement ses poids synaptiques, ceci sans perdre les connaissances acquises précédemment. Il y a donc un compromis entre, d'une part la plasticité qui permet d'intégrer de nouvelles informations au réseau et d'autre part la stabilité du réseau qui maintient les connaissances acquises précédemment.

Dans un second temps, il est envisagé de mettre à jour les poids d'un modèle déjà pré-entraîné directement à bord du satellite avant de communiquer avec le segment au sol. On pourra aussi considérer un entraînement fédéré au sol dans le cas d'une constellation de satellites. **Le Federated Learning** [Skatchkovsky 2020] est un paradigme d'apprentissage automatique qui permet de former des modèles de manière distribuée tout en préservant la confidentialité des données. Contrairement à l'apprentissage centralisé, où les données sont collectées sur un serveur central pour former un modèle, le Federated Learning permet à des appareils périphériques, ici des satellites, de collaborer à la formation d'un modèle commun sans avoir à partager leurs données sensibles. Le modèle est ainsi envoyé à chaque appareil périphérique où il est **entraîné localement sur les données de l'appareil**. Les **misés à jour de modèle sont ensuite envoyées au serveur central** (ici le segment au sol) où elles sont agrégées pour former un modèle global mis à jour. Le processus est répété plusieurs fois jusqu'à ce que le modèle converge.

Plusieurs approches peuvent être envisagées pour traiter les sujets mentionnés ci-dessus. Tout d'abord, **l'apprentissage en ligne** (*online learning*) qui permet de mettre à jour le modèle à chaque fois que de nouveaux échantillons sont disponibles. Il est particulièrement utile lorsque le modèle doit s'adapter rapidement à des conditions changeantes [Wang2021], ce qui est le cas dans le domaine spatial. Ensuite, **les points d'influence** (*influence functions*) qui sont utilisés pour comprendre l'importance d'une donnée d'entraînement sur les prédictions du modèle [Basu2020]. Cette technique pourrait être utile pour déterminer les échantillons problématiques et nettoyer la base de données d'entraînement [Picard2022]. De plus, les nouvelles **méthodes basées sur le data pruning** permettent de réduire considérablement la taille de la base de données tout en améliorant la performance [Sorscher2022]. Enfin, une autre direction prometteuse est **l'apprentissage continu** (*continual learning*), qui permet de faire apprendre à un modèle pré-entraîné une nouvelle tâche sans oublier l'exécution des tâches précédemment apprises [Berjaoui 2020] [De Lange 2022] [Mainsant 2021] [Ravaglia 2021].

Missions du post-doc

Les missions du post-doctorants seront organisées en plusieurs périodes:

- Etude de l'état de l'art sur les techniques suivantes
 - Apprentissage en ligne (online learning), apprentissage continu (continual learning),
 - Points d'influence (influence functions) et data pruning,
 - Federated learning.
- Proposer des approches visant à optimiser la quantité de données transmises au sol par le satellite pour effectuer un apprentissage on-line sur de nouvelles données.
- Proposer des méthodes d'apprentissage en ligne (dans le satellite) optimisant les performances vis-à-vis des différentes variabilités et limitant l'impact en termes de consommation (temps de calcul) et empreinte mémoire. Il s'agira aussi de tenir compte du problème de l'oubli catastrophique.
- Explorer des approches permettant un apprentissage continu du satellite sur de nouvelles données.
- Ces travaux seront effectués selon 2 cas de figure : i) un satellite relié à une station au sol, ii) une constellation de satellites sera considérée avec l'utilisation de techniques de type Federated Learning.

Ce post-doc se fera dans le cadre du projet IRMA¹ de l'IRT St-Exupéry.

Informations pratiques

Lieu : IRT St Exupéry et Laboratoire LEAT, Sophia Antipolis – France.

Durée : 18 mois avec un démarrage entre Octobre 2023 et Octobre 2024.

Salaire : 42500€ brut annuel (sortie de thèse).

Profil : Machine learning, neural networks, artificial intelligence, Python, Pytorch.

Contacts

Adrien Girard

IRT St-Exupéry, Chef de projet IRMA.

adrien.girard@irt-saintexupery.com

Pr. Alain Pegatoquet, Pr. Benoît Miramond

EDGE Team

LEAT Laboratory – University Cote d'Azur / CNRS

alain.pegatoquet@univ-cotedazur.fr

benoit.miramond@univ-cotedazur.fr

Références

[Wang2021] Wang, Chen, et al. "Unsupervised online learning for robotic interestingness with visual memory." IEEE Transactions on Robotics 38.4 (2021): 2446-2461.

[Basu2020] Basu et al. "Influence functions in deep learning are fragile." arXiv preprint arXiv:2006.14651 (2020).

[Picard2022] Picard, Agustin Martin, et al. "Leveraging Influence Functions for Dataset Exploration and Cleaning." 11th European Congress Embedded Real Time Systems (ERTS 2022). 2022.

[Berjaoui 2020] Berjaoui, Ahmad. "Continual learning using hash-routed convolutional neural networks." arXiv preprint arXiv:2010.05880 (2020).

[GoodFellow 2015] I. J. Goodfellow, M. Mirza, D. Xiao, A. Courville, and Y. Bengio, "An Empirical Investigation of Catastrophic Forgetting in Gradient-Based Neural Networks," arXiv :1312.6211 [cs, stat], Mar. 2015. arXiv : 1312.6211.

[Skatchkovsky 2020] Skatchkovsky et al., "Federated Neuromorphic Learning of Spiking Neural Networks for Low-Power Edge Intelligence," IEEE ICASSP, Barcelona, Spain, 2020

[De Lange 2022] M. De Lange et al., "A Continual Learning Survey: Defying Forgetting in Classification Tasks," in IEEE Trans. on Pattern Analysis and Machine Intelligence, July 2022, doi: 10.1109/TPAMI.2021.3057446.

[Mainsant 2021] M. Mainsant et al. "Dream Net: a privacy preserving continual learning model for face emotion recognition", 2021 ACIIW conference.

[Ravaglia 2021] L. Ravaglia et al., "A TinyML Platform for On-Device Continual Learning with Quantized Latent Replays", IEEE Journal on Emerging and Selected Topics in Circuits and Systems 11.4 (2021), 789-802

¹ Image analysis for a Responsive Mission with AI