

Apprendre avec peu d'exemples : Une approche auto-supervisée basée sur les segments avec application à la télédétection

Antoine Saget*, Baptiste Lafabregue*
Antoine Cornuéjols**, Pierre Gançarski*

*ICube, Université de Strasbourg, France
prenom.nom@unistra.fr

**UMR MIA-Paris, AgroParisTech, INRAE - Université Paris-Saclay
antoine.cornuejols@agroparistech.fr

1 Introduction

Cet article est une traduction raccourcie de Saget et al. (2024). De vastes quantités d'images satellites sont capturées chaque jour, mais leur exploitation par apprentissage supervisé classique nécessite un étiquetage préalable coûteux et difficile à obtenir, laissant la majorité des données disponibles inexploitées. L'apprentissage auto-supervisé (Self-Supervised Learning, SSL) utilise les données non étiquetées pour apprendre de nouvelles représentations nécessitant moins de données étiquetées que les méthodes supervisées standard pour atteindre une même performance. En apprentissage SSL contrastif, les exemples positifs sont des points de données similaires, généralement créés par augmentation. Cependant, les augmentations couramment utilisées en traitement d'images ne peuvent pas être directement appliquées aux séries temporelles. Nous proposons donc d'utiliser des groupements préexistants de données (segments) comme exemples positifs pour se passer d'augmentations et adapter le SSL contrastif aux SITS.

2 Données et Méthode

Données. Notre jeu de données, inspiré par Rußwurm et al. (2020), comprend plus de 5,8 millions de parcelles agricoles étiquetées en France métropolitaine. Les labels proviennent du Registre Parcellaire Graphique 2022 (232 classes). Pour chaque parcelle, 100 séries temporelles Sentinel-2 sont extraites, chacune comportant 12 bandes radiométriques sur 60 pas de temps (du 1er février au 30 novembre 2022).

Méthode. Notre approche "Groups as Positive Pairs" (GaPP) définit comme exemples positifs toutes paires de séries temporelles de pixels provenant d'une même parcelle agricole. Aussi, plutôt que de soumettre des paires de séries temporelles individuelles à l'encodeur, nous lui soumettons des n -uplets de séries temporelles d'une même parcelle, puis les agrégeons avec une couche de moyennage ("Average Pooling", AvgP).

3 Expériences et Résultats

Nous comparons dans le Tableau 1 notre approche avec une régression logistique (point de référence), Rocket et InceptionTime (méthodes supervisées performantes en classification de séries temporelles) et TimeMAE (méthode SSL pour séries temporelles). Nous utilisons la méthode de SSL contrastif SimCLR avec un encodeur ResNet adapté aux séries temporelles. Notre méthode avec 50 exemples par classe égale la précision d’InceptionTime avec 100.

Méthode	N exemples/classe dans train			
	5	10	50	100
Régression Logistique	42	49	68	74
MiniRocket (Dempster et al., 2021)	47	58	75	79
InceptionTime (Ismail Fawaz et al., 2020)	56	65	77	80
TimeMAE (Cheng et al., 2023)	53	61	75	79
SimCLR (Chen et al., 2020) + AvgP + GaPP	62	70	80	82

TAB. 1 – Accuracy sur un jeu de validation de 20 classes selon le nombre de parcelles étiquetées par classe dans le jeu d’entraînement.

Les travaux futurs exploreront : la généralisation à d’autres tâches, l’application à d’autres groupements et l’exploration des méthodes SSL génératives.

Nous remercions l’ANR (projets ArtIC et HERELLES) pour le financement de ce travail et le programme Copernicus de l’ESA pour l’accès gratuit et public aux données Sentinel-2.

Références

- Chen, T., S. Kornblith, M. Norouzi, et G. Hinton (2020). A simple framework for contrastive learning of visual representations. In *International conference on machine learning*, pp. 1597–1607.
- Cheng, M., Q. Liu, Z. Liu, H. Zhang, R. Zhang, et E. Chen (2023). Timemae : Self-supervised representations of time series with decoupled masked autoencoders. *arXiv :2303.00320*.
- Dempster, A., D. F. Schmidt, et G. I. Webb (2021). MiniRocket : A very fast (almost) deterministic transform for time series classification. In *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pp. 248–257.
- Ismail Fawaz, H., B. Lucas, G. Forestier, C. Pelletier, D. F. Schmidt, J. Weber, G. I. Webb, L. Idoumghar, P.-A. Muller, et F. Petitjean (2020). Inceptiontime : Finding alexnet for time series classification. *Data Mining and Knowledge Discovery* 34(6), 1936–1962.
- Rußwurm, M., C. Pelletier, M. Zollner, S. Lefèvre, et M. Körner (2020). Breizhcrops : A time series dataset for crop type mapping. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLIII-B2*, 1545–1551.
- Saget, A., B. Lafabregue, A. Cornuéjols, et P. Gançarski (2024). Learning from few labeled time series with segment-based self-supervised learning : application to remote-sensing. In *Proceedings of SPAICE2024 : The First Joint European Space Agency / IAA Conference on AI in and for Space*, pp. 275–279.