

A satellite image of the tropical Atlantic Ocean. The left side shows the brownish, textured landmass of Africa. The right side shows the ocean with a large, complex cyclone system, characterized by swirling patterns of light blue and white, indicating high cloud density and storm activity.

# CNN pour la prévision saisonnière des nutriments dans l'Atlantique tropical

Gabriela Martinez Balbontin (MOi; encadrée par Jean-Michel Lellouche), Rachid Benshila (LEGOS) et Julien Jouanno (LEGOS)


# Contexte

Des prévisions biogéochimiques précises sont essentielles pour mieux comprendre les phénomènes écologiques, ainsi que pour élaborer des stratégies d'adaptation efficaces...



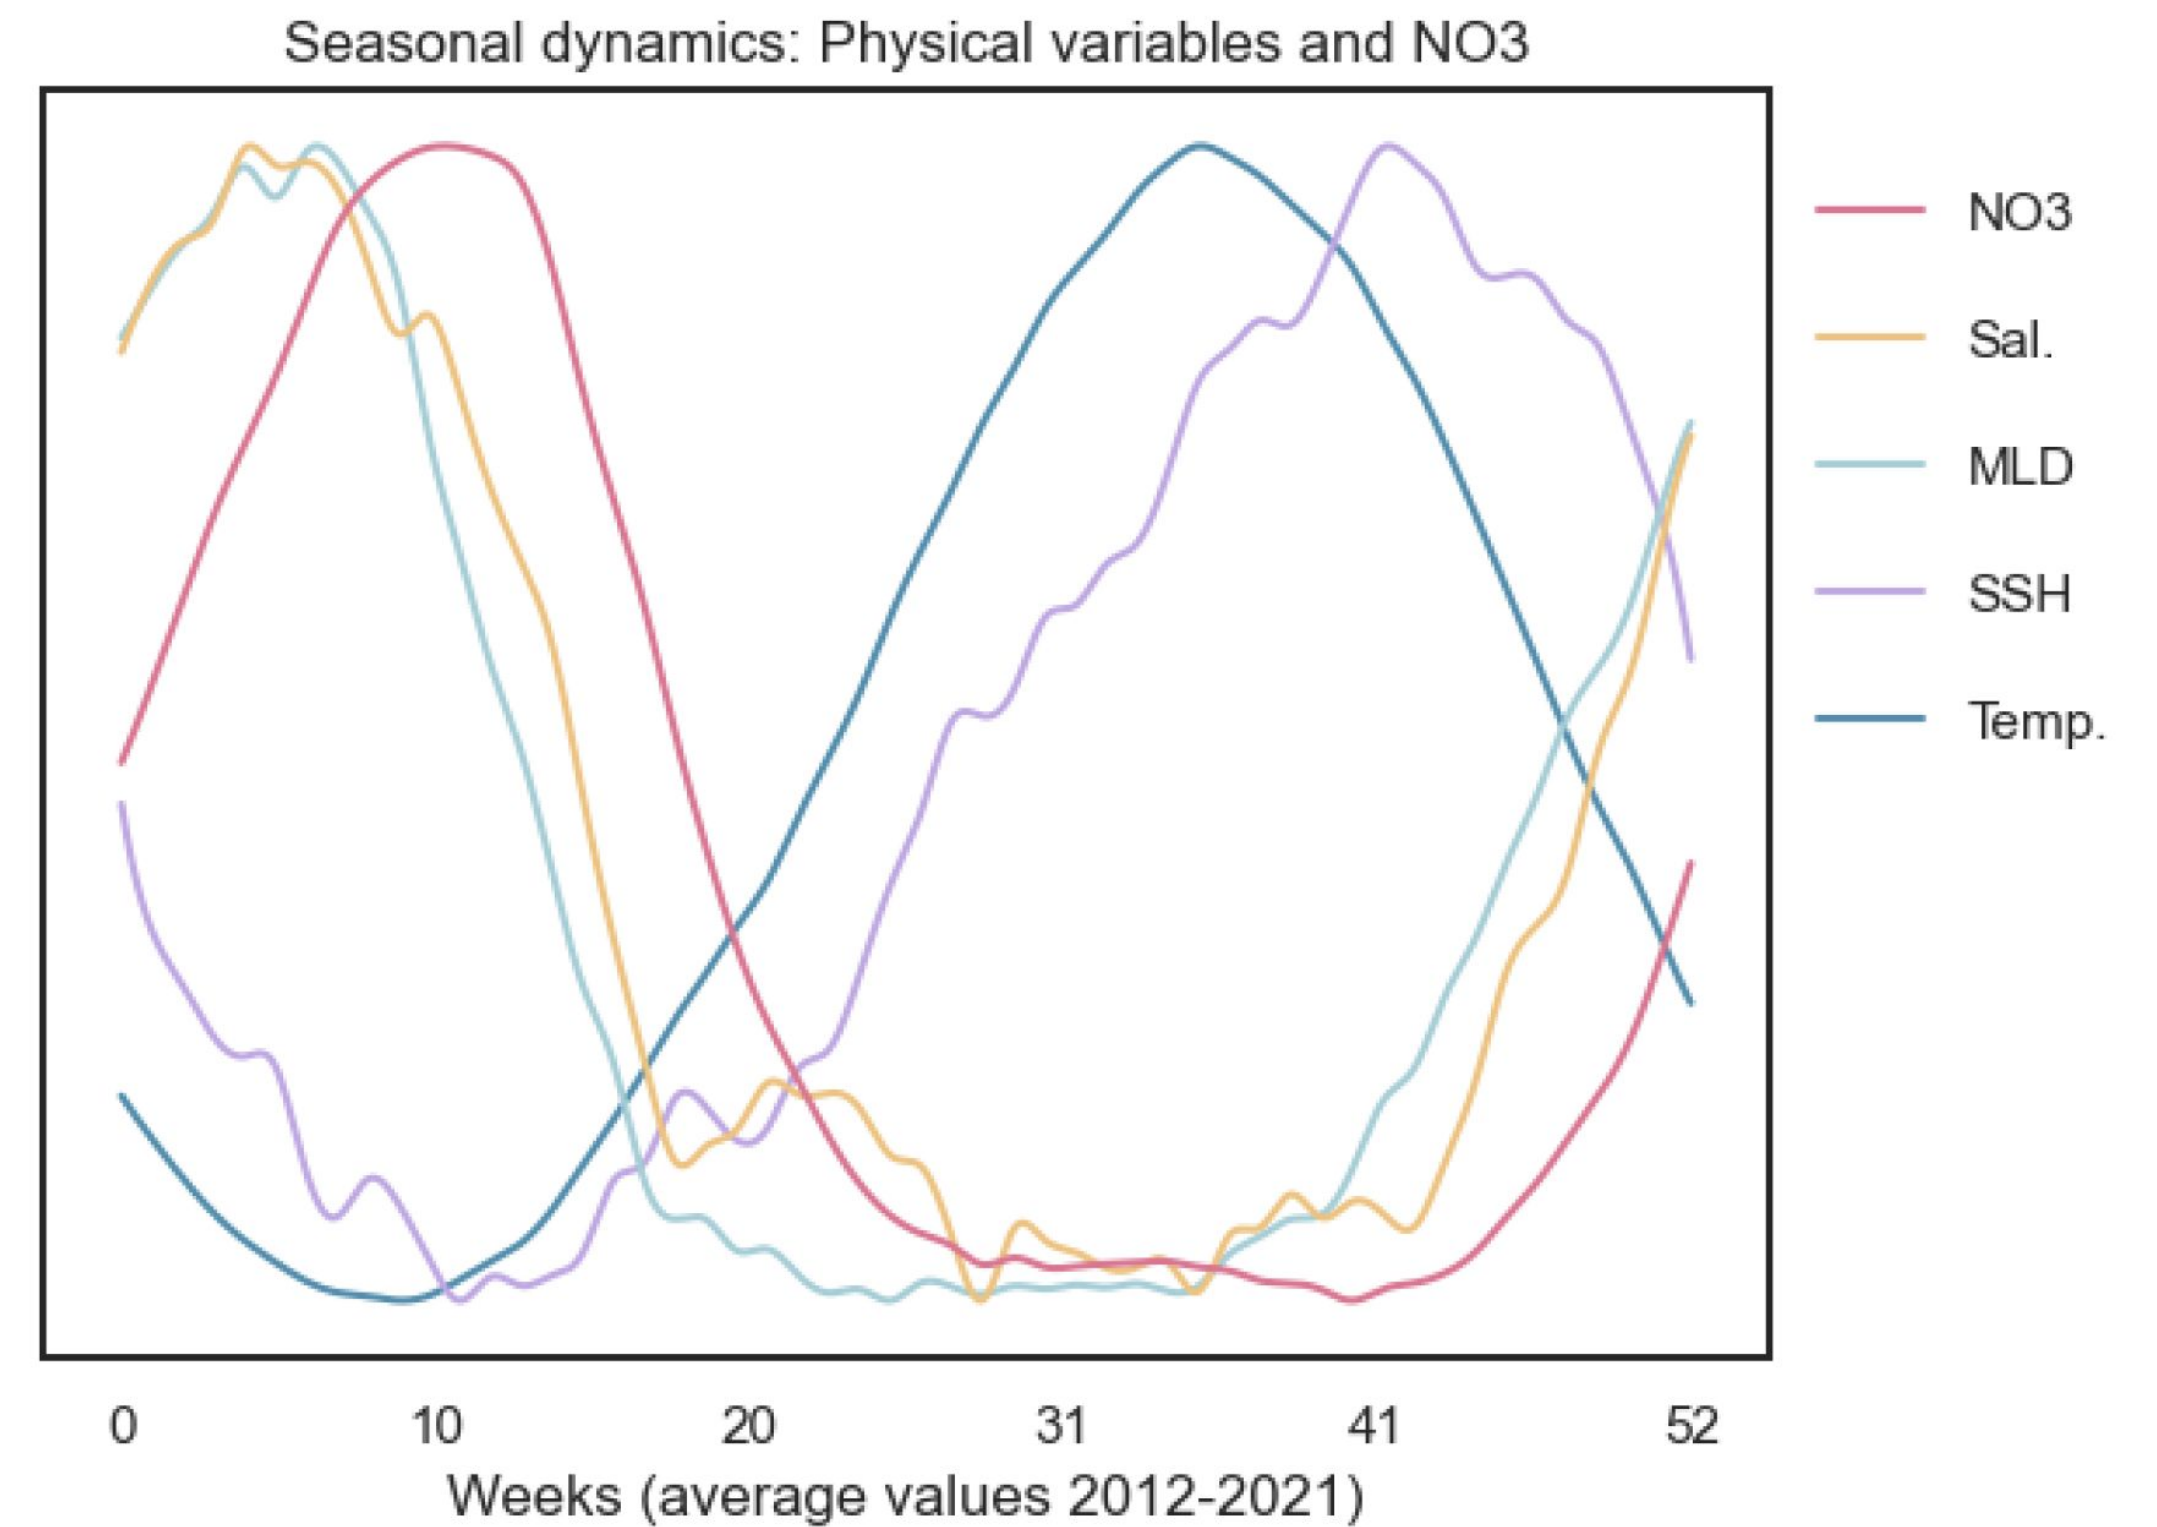
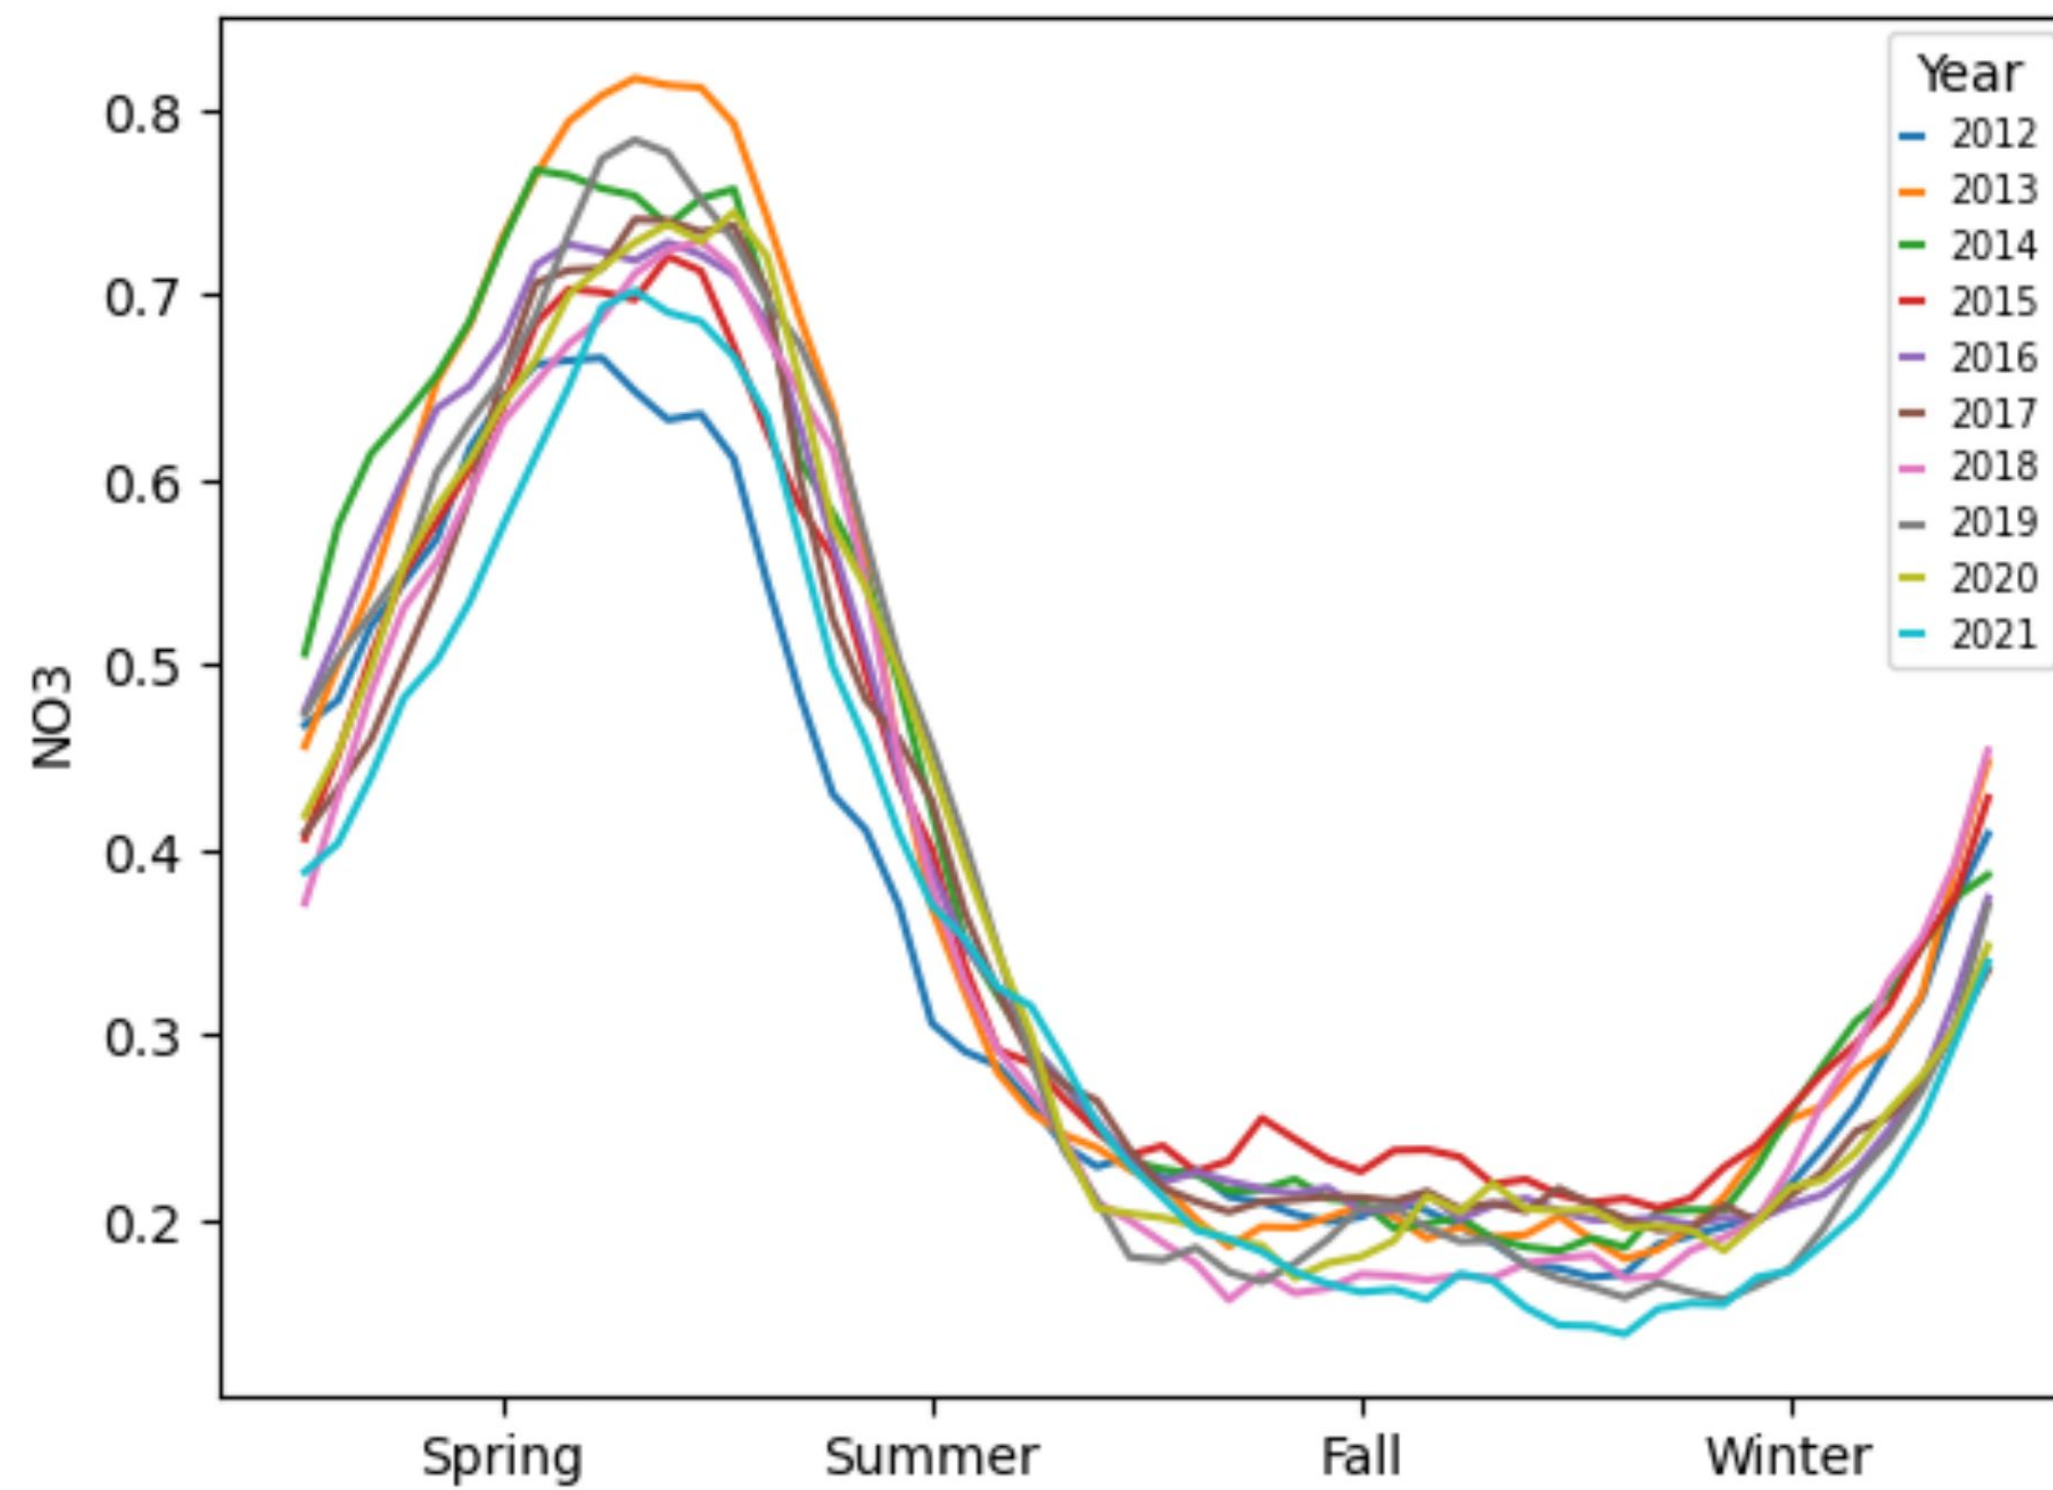
# Contexte

... mais elles sont difficiles à mesurer et à prévoir à l'échelle nécessaire pour effectuer des prévisions saisonnières.




# Contexte

Leur concentrations varient en fonction des facteurs biologiques, de la localisation et saisonnalité, mais aussi en fonction des **facteurs physiques**




# L'objectif:


Reconstruire les **concentrations saisonnières de nutriments en surface** à partir de ces **paramètres physiques** dans le but de générer des **prévisions**




Température



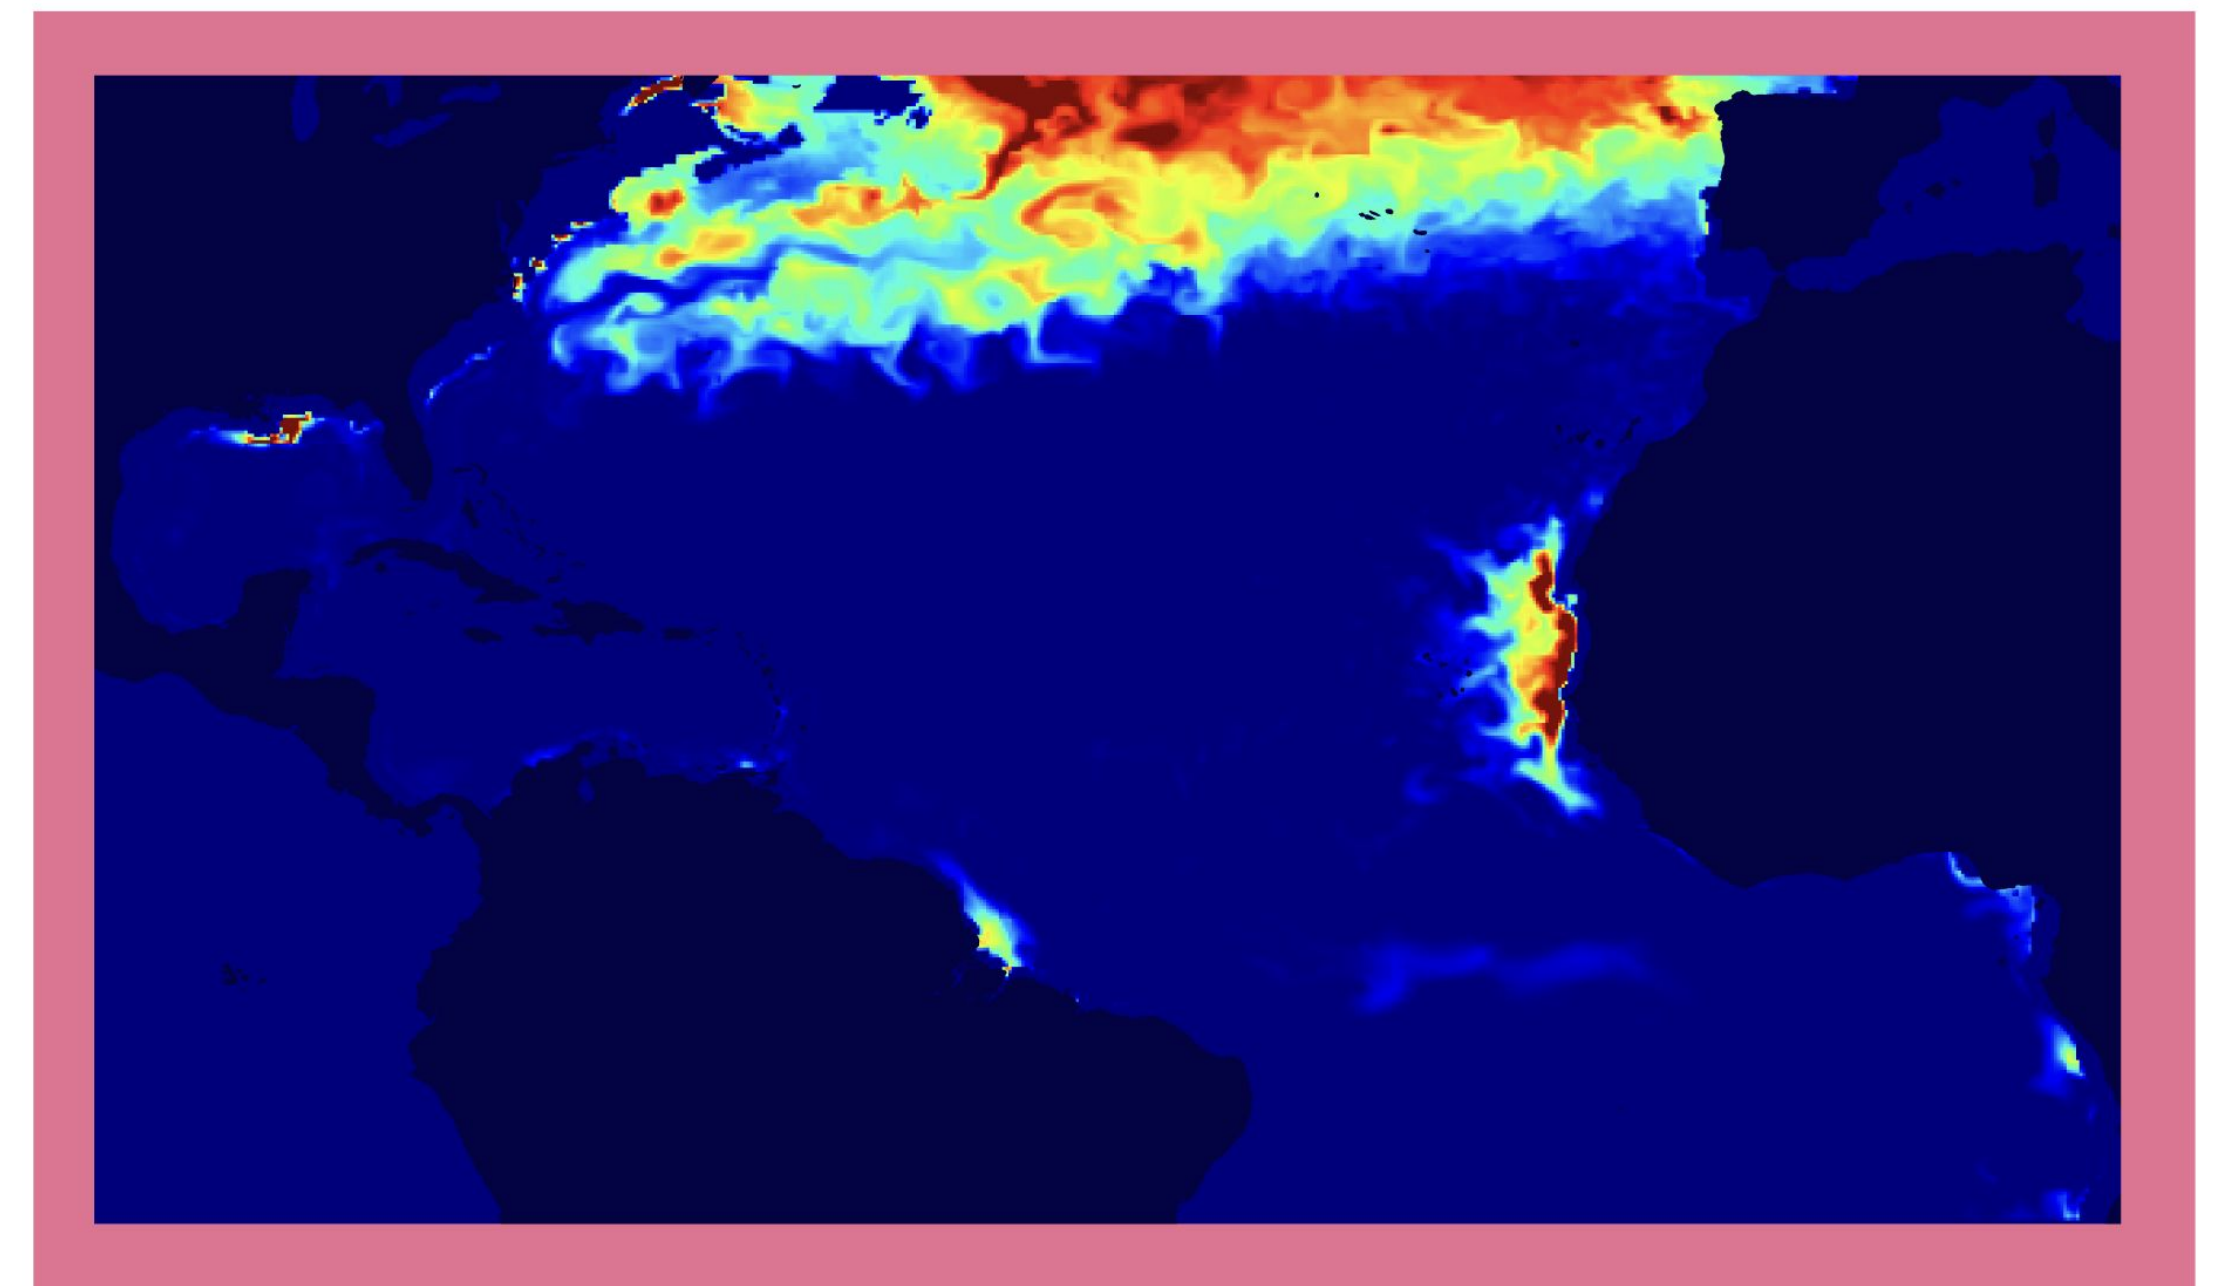

SSH



MLD



Salinité




Champs biogéochimiques

# La méthode:


## Original data

Trained using 1998-2017 data,  
30 days x 6 months batches  
1/4° grid resolution

**GLORYS12:** Physical ocean ref. data

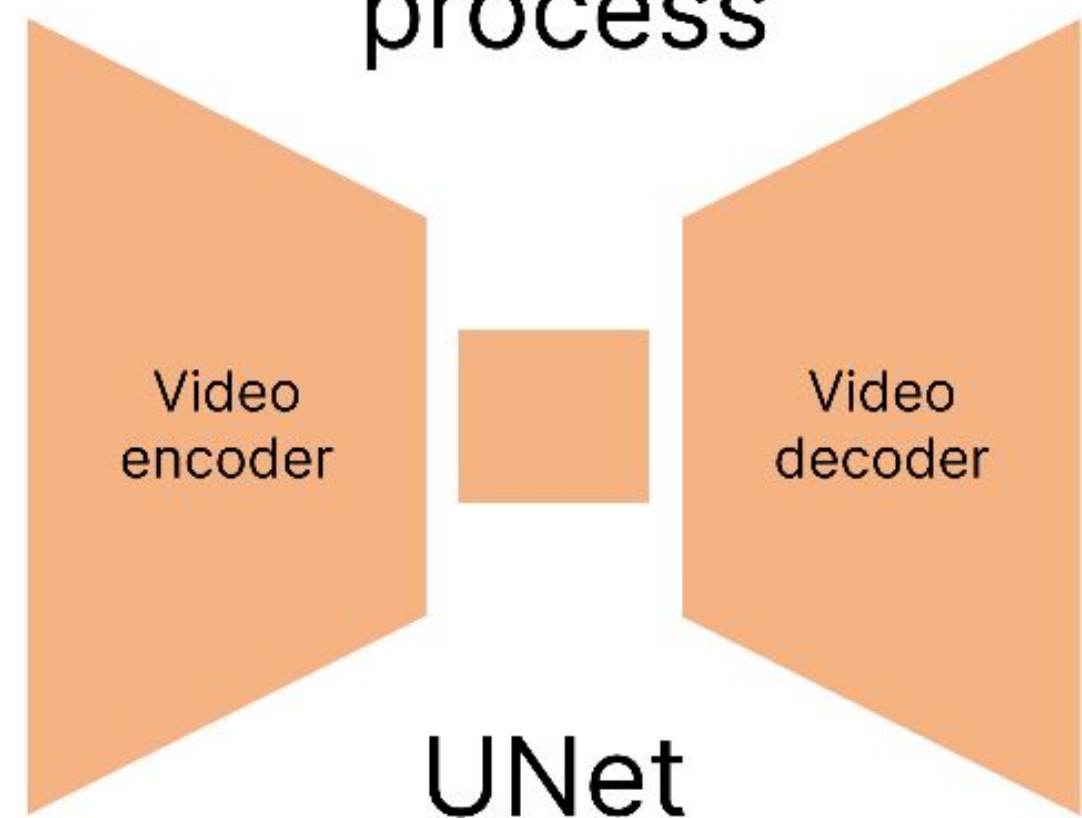


+



**GlobColor:** Chlorophyll ref. data  
**BIOMER4V2R1:** Nutrients ref. data

## Training process




UNet

# La méthode:


## Original data

Trained using 1998-2017 data,  
30 days x 6 months batches  
1/4° grid resolution

**GLORYS12:** Physical ocean ref.data




+




**GlobColor:** Chlorophyll ref. data  
**BIOMER4V2R1:** Nutrients ref. data


## Training process



## Deployable model



Input physical  
ocean data




**SEAS5:** Physical ocean long-range forecast  
(30 days x 6 months batches)

# La méthode:


## Original data

Trained using 1998-2017 data,  
30 days x 6 months batches  
1/4° grid resolution

**GLORYS12:** Physical ocean ref.data

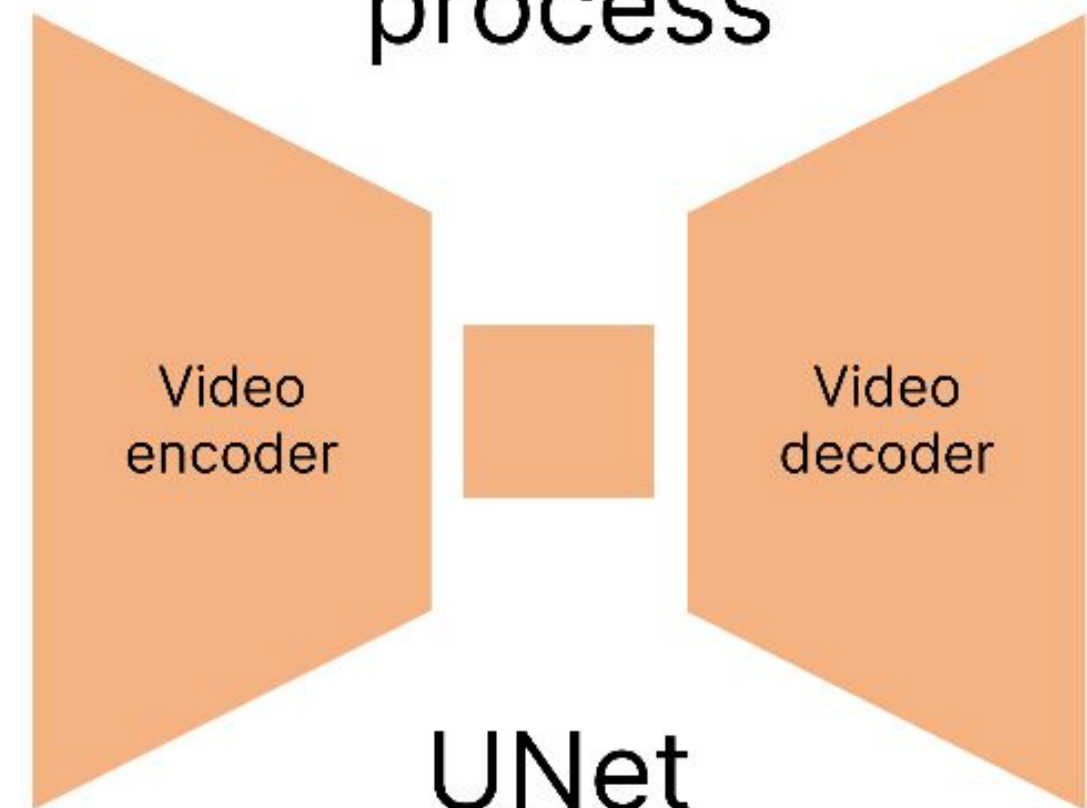


+




**GlobColor:** Chlorophyll ref. data  
**BIOMER4V2R1:** Nutrients ref. data

## Training process

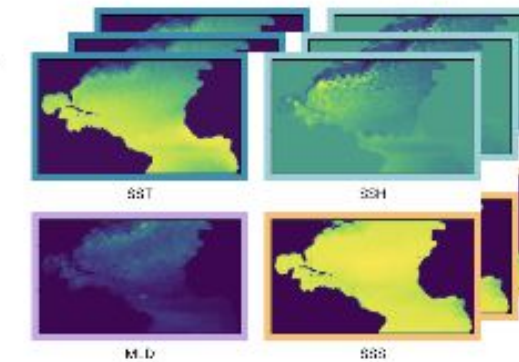


UNet

## Deployable model




Input physical  
ocean data



**SEAS5:** Physical ocean long-range forecast  
(30 days x 6 months batches)

## Generated data

**BGC forecast or estimation**  
30 days x 6 months  
1/4° grid resolution





Validated for chlorophyll and nitrate  
(2018-2022)



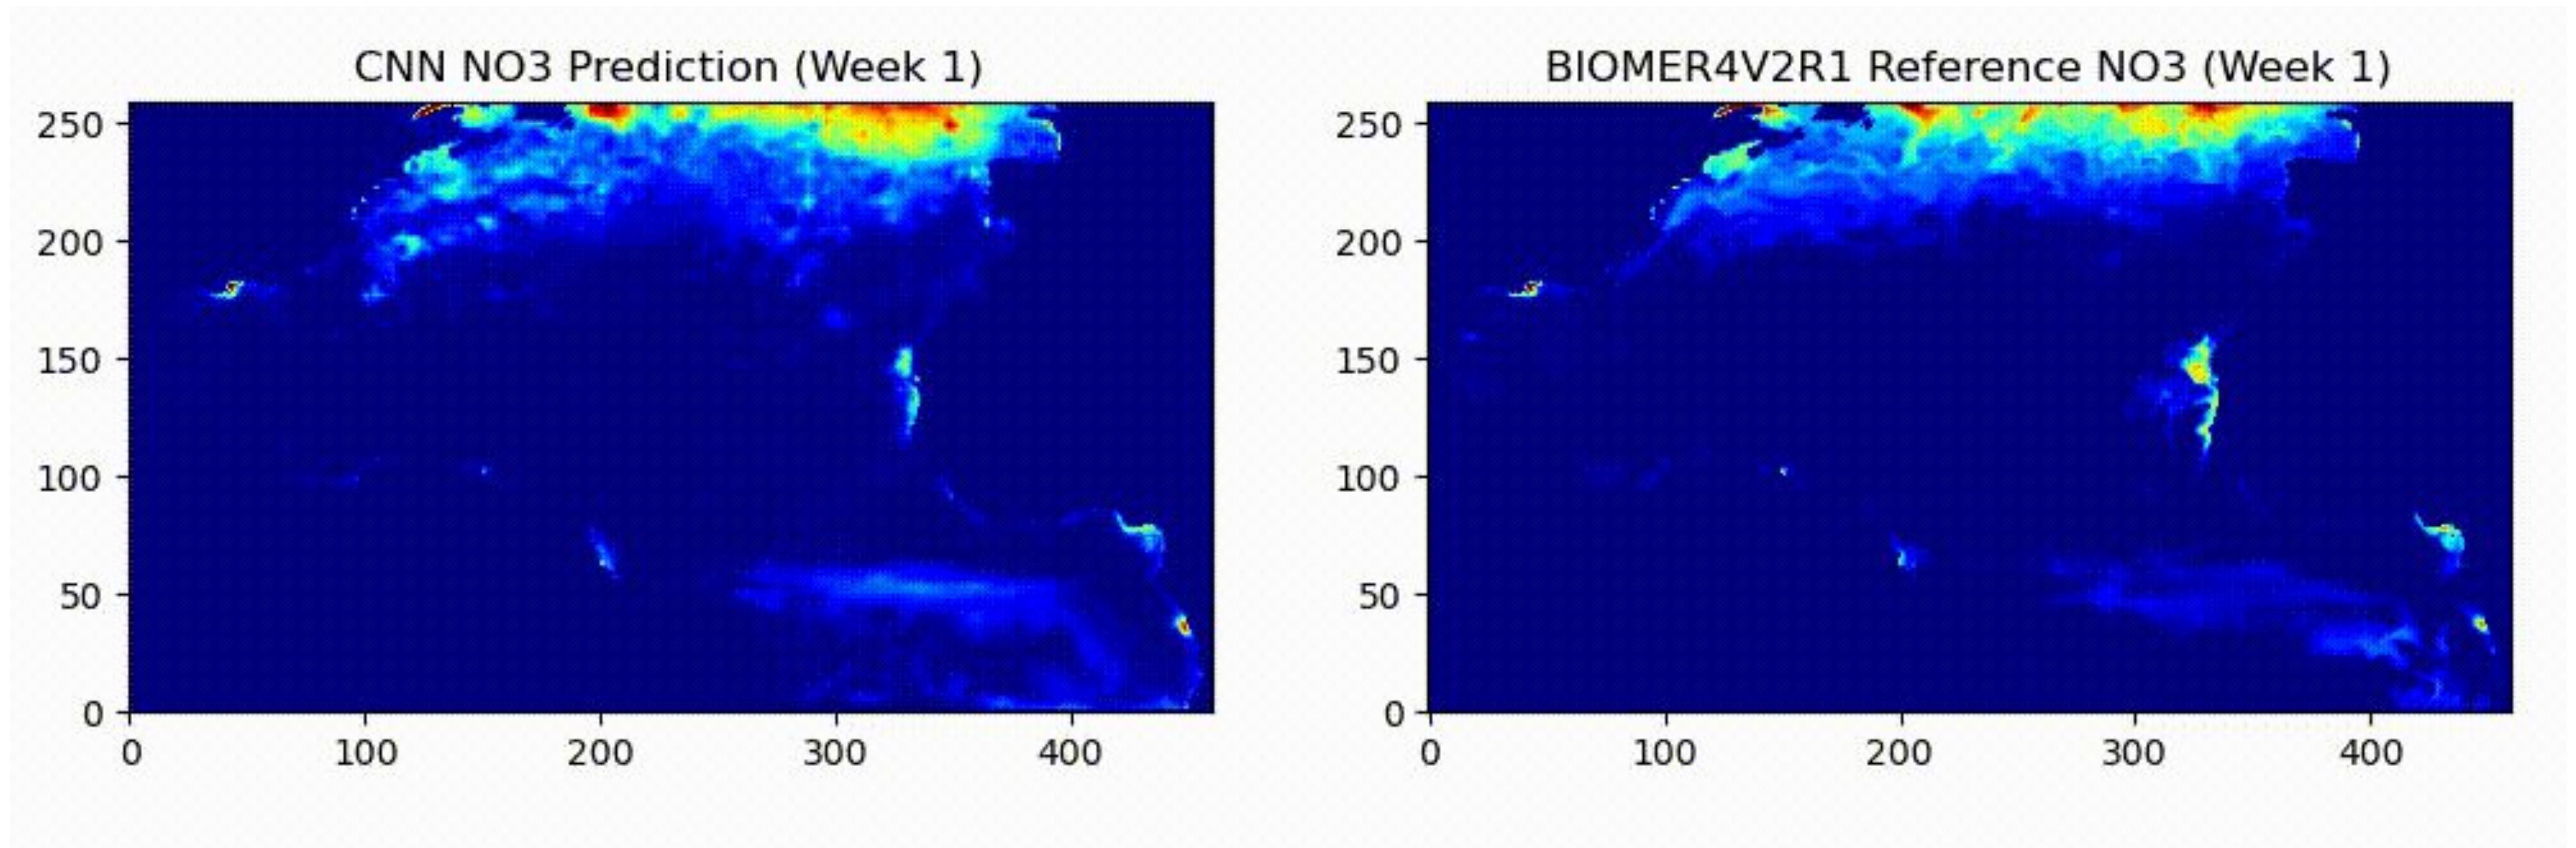
# Résultats: Nitrate

Comparaison entre estimation (UNet) et données de référence BIOMER4V2R1 pour 2021 (moyennes hebdomadaires et spatiales)




# Résultats: Nitrate

Comparaison entre estimation (UNet) et données de référence BIOMER4V2R1 pour 2021 (moyennes hebdomadaires)


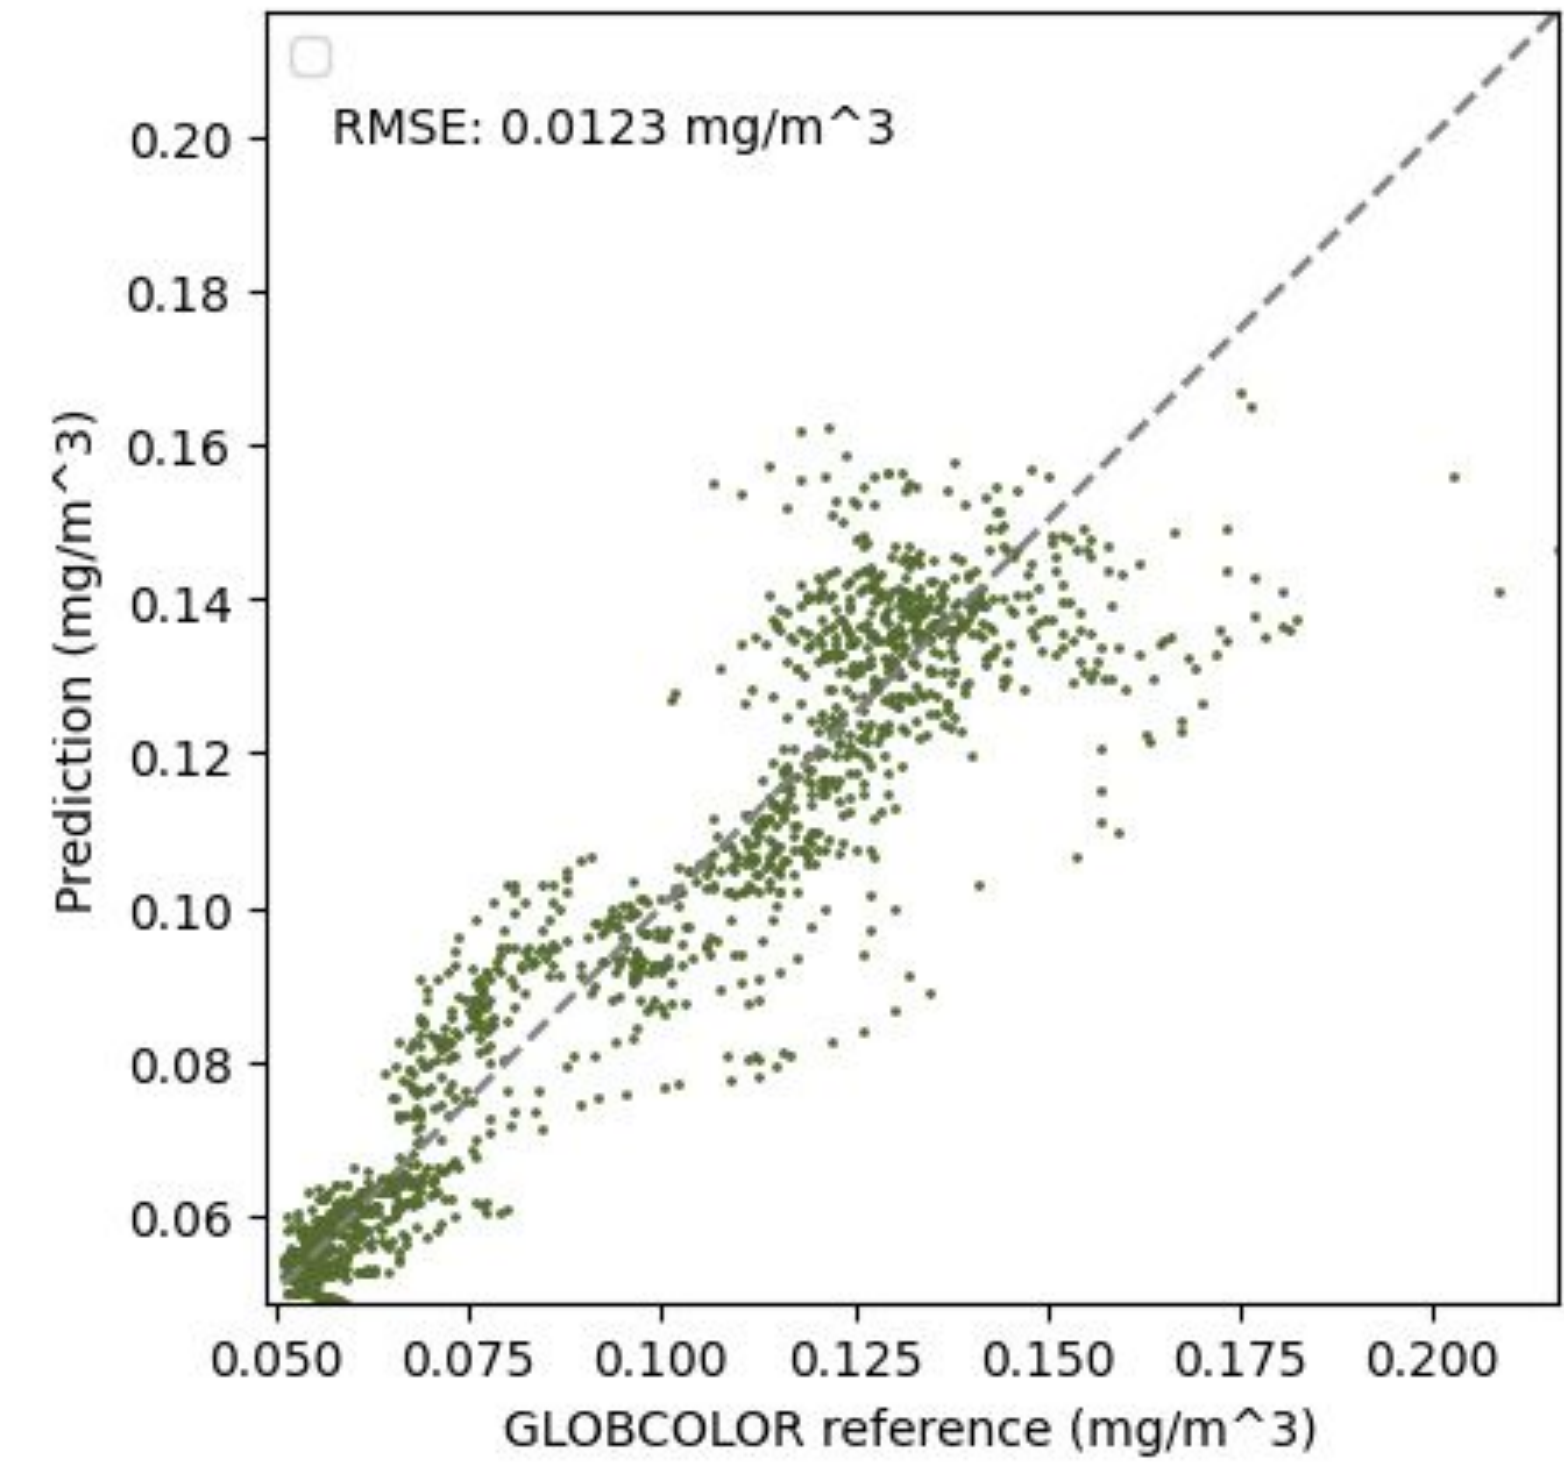
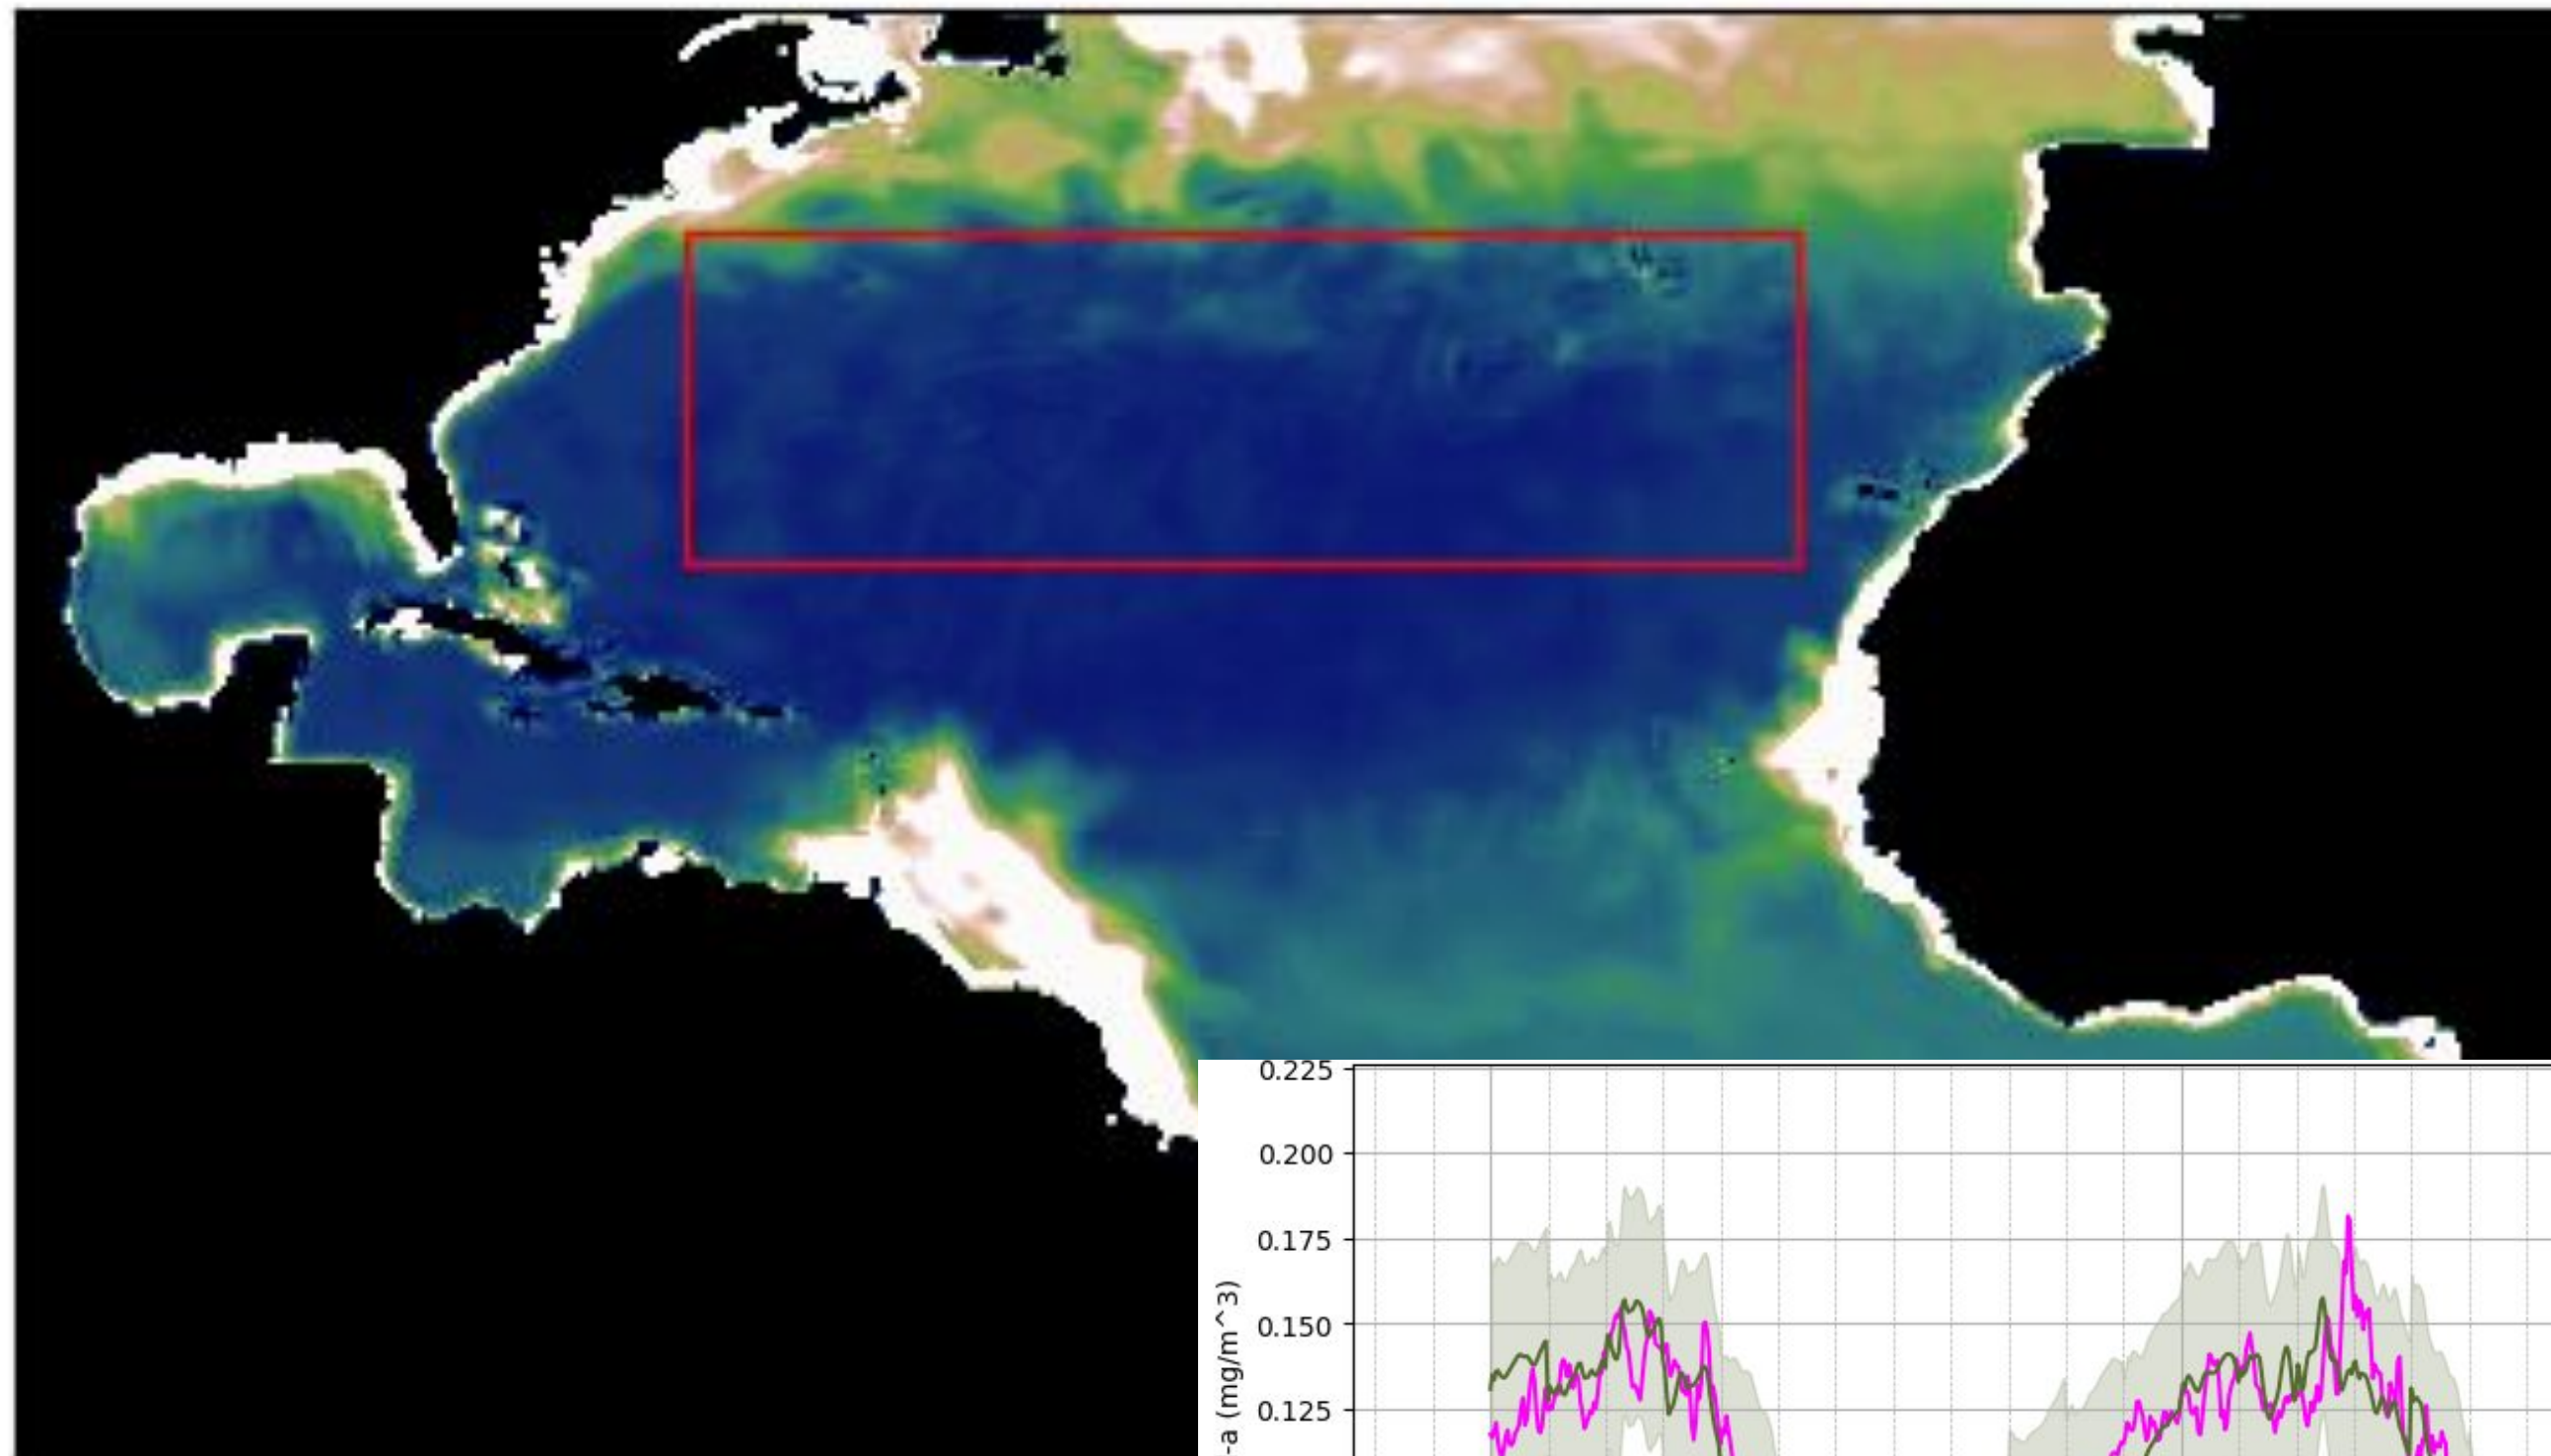


# Résultats: Chlorophyll-a

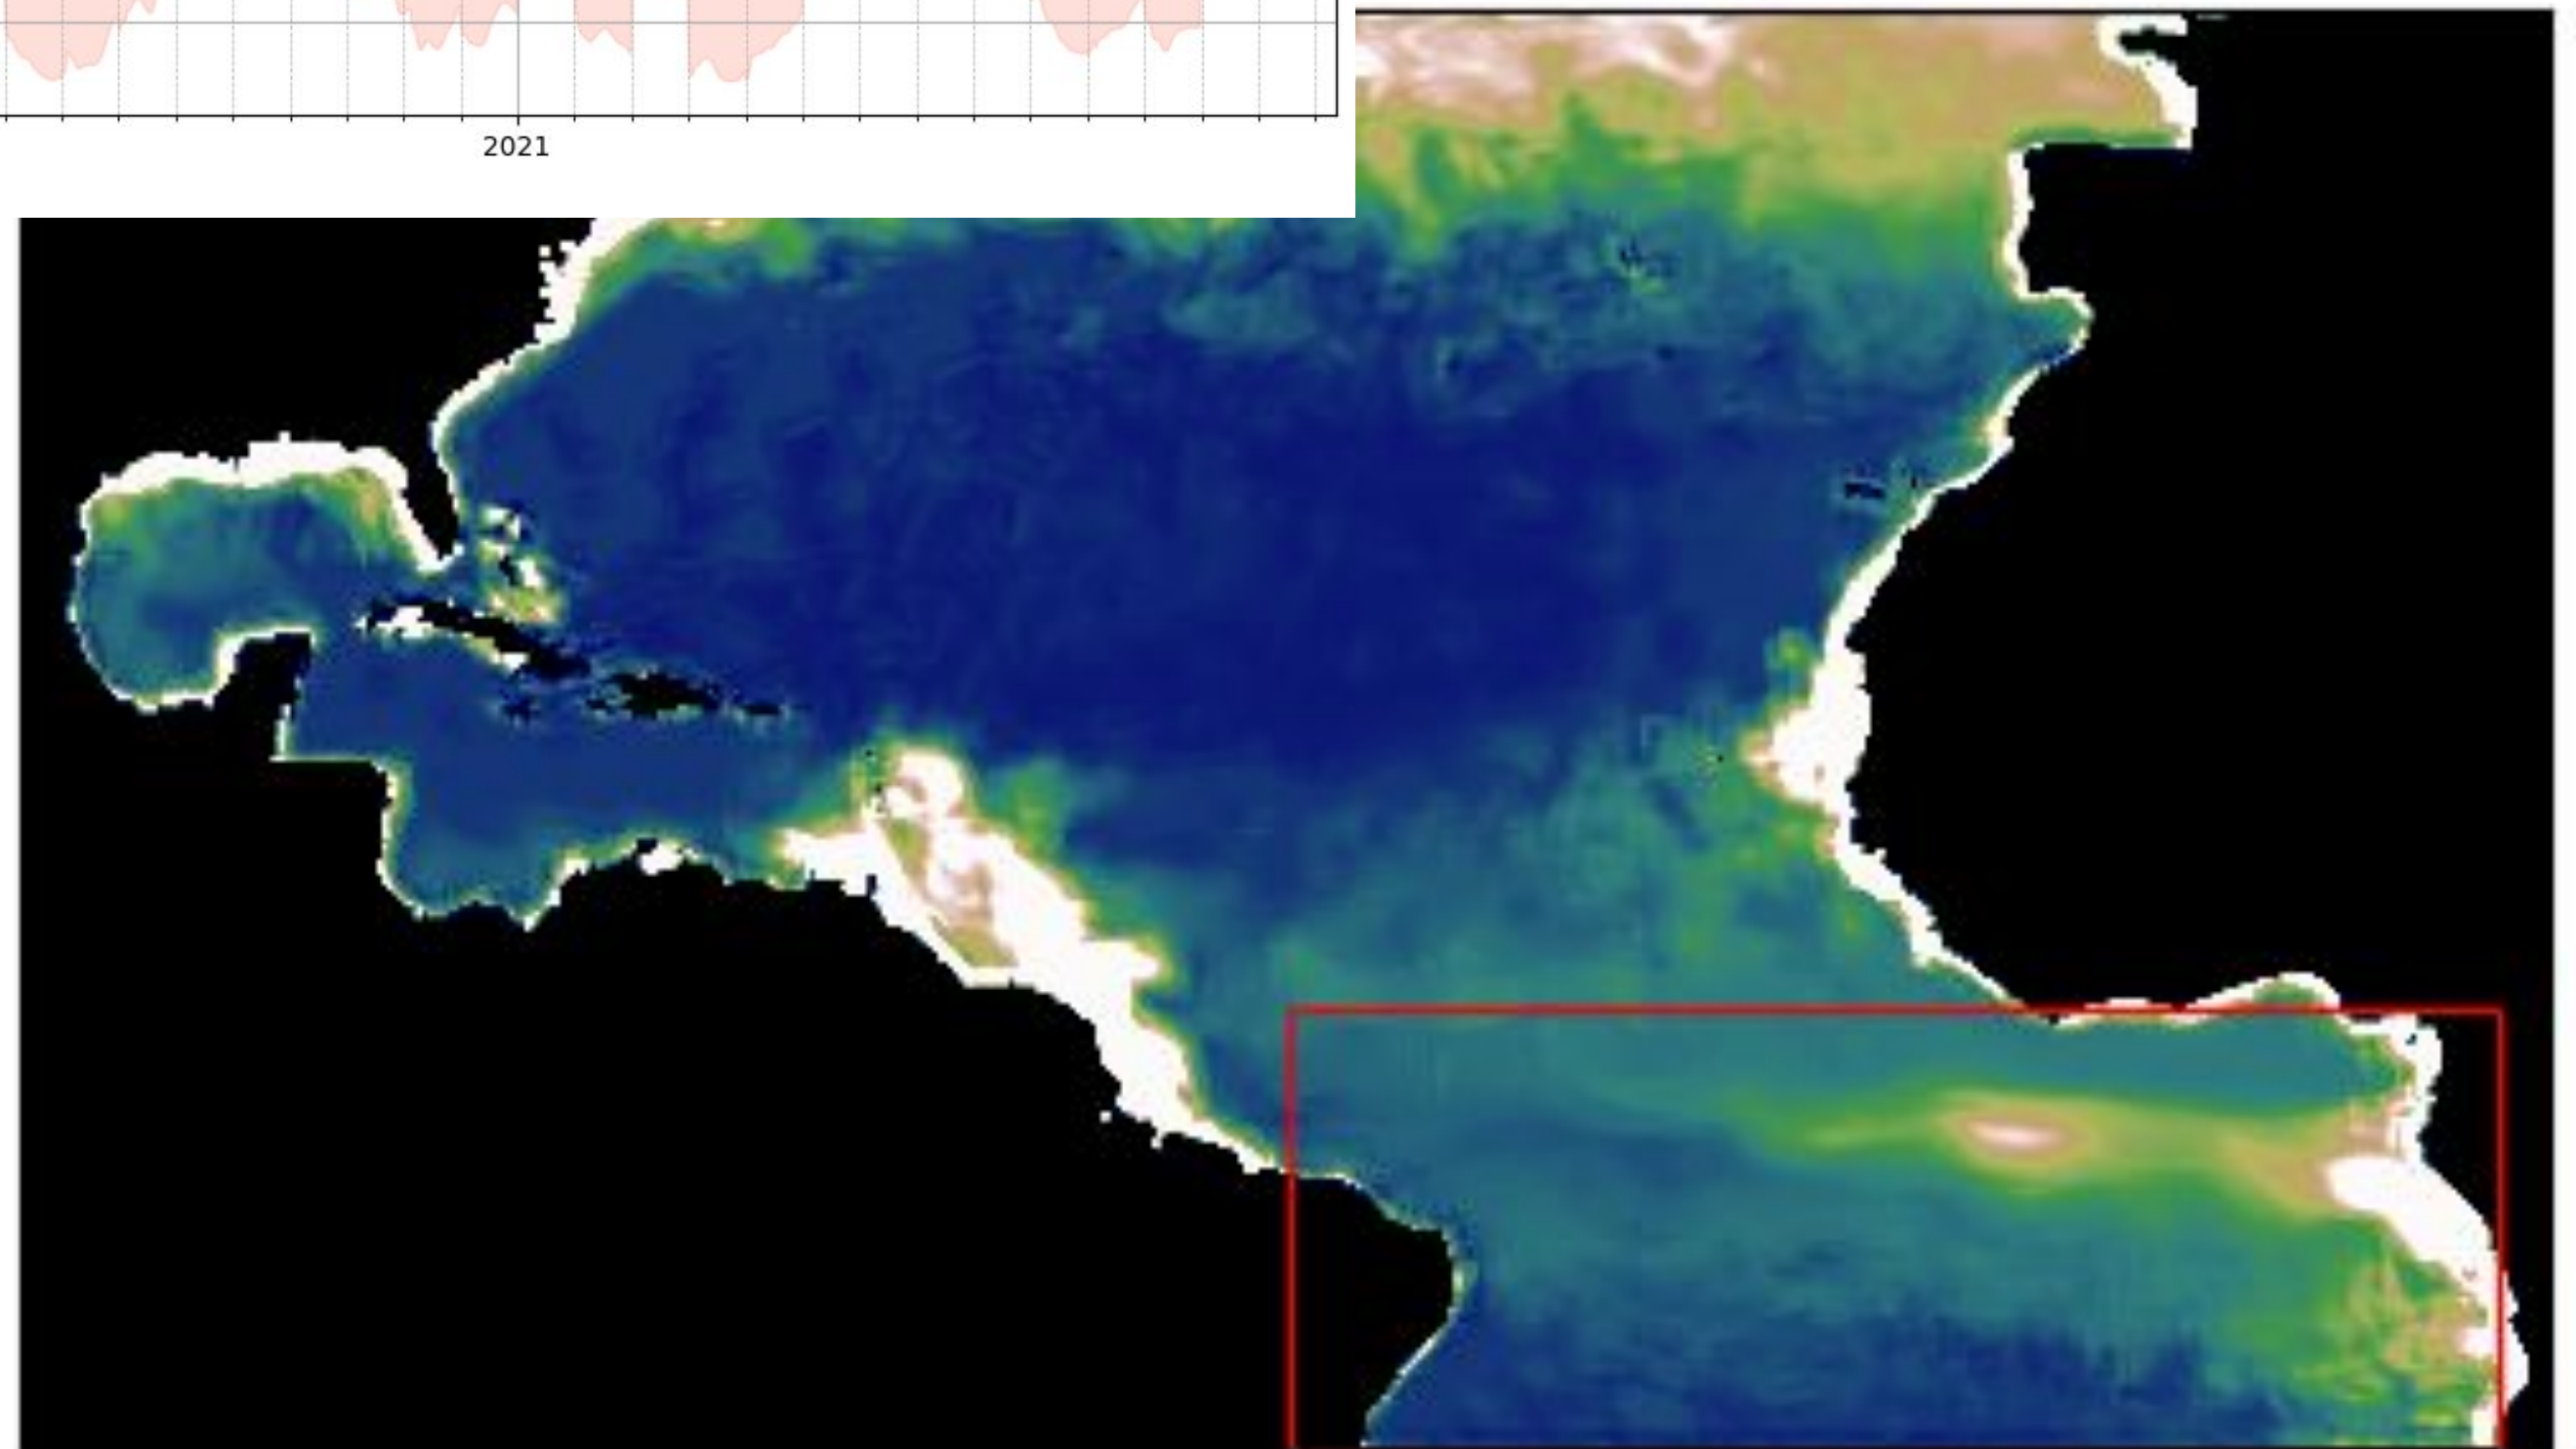
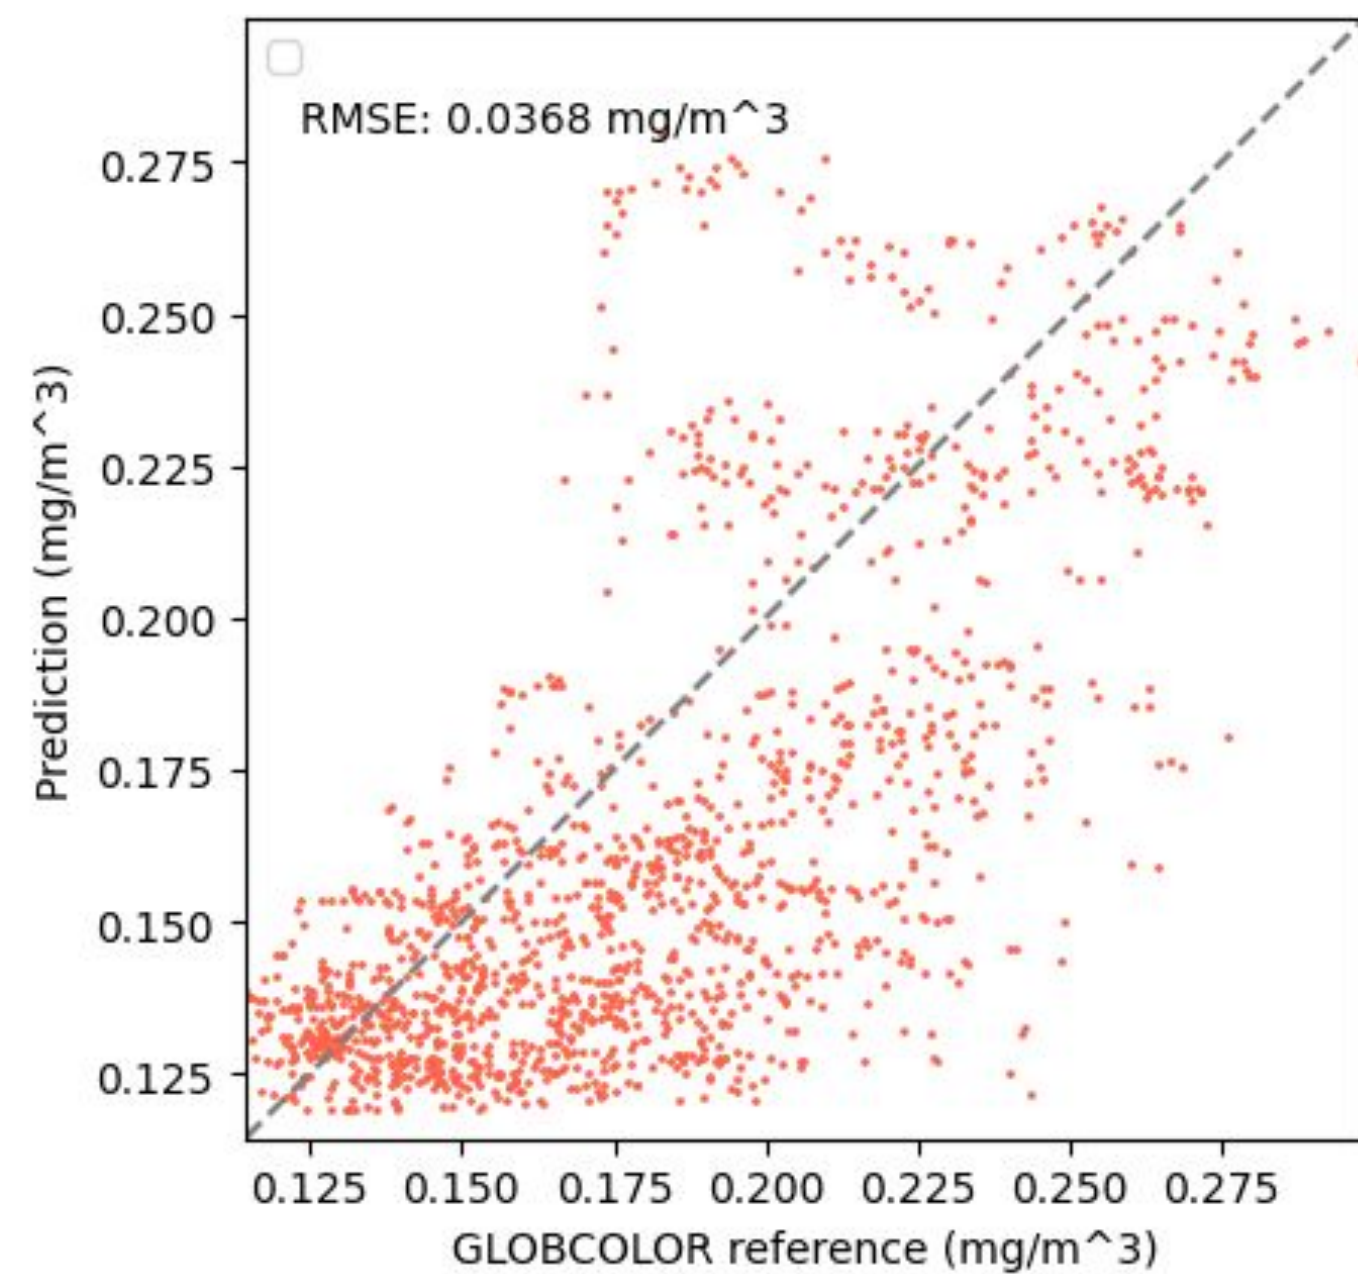

Comparaison de séries temporelles (moyennes spatiales): reconstruction (UNet), données de référence (Globcolour) et climatologie (Globcolour, 1998-2022)






# Résultats: A. T. Nord (Chl-a)






# Résultats: A. T. Equatorial (Chl-a)



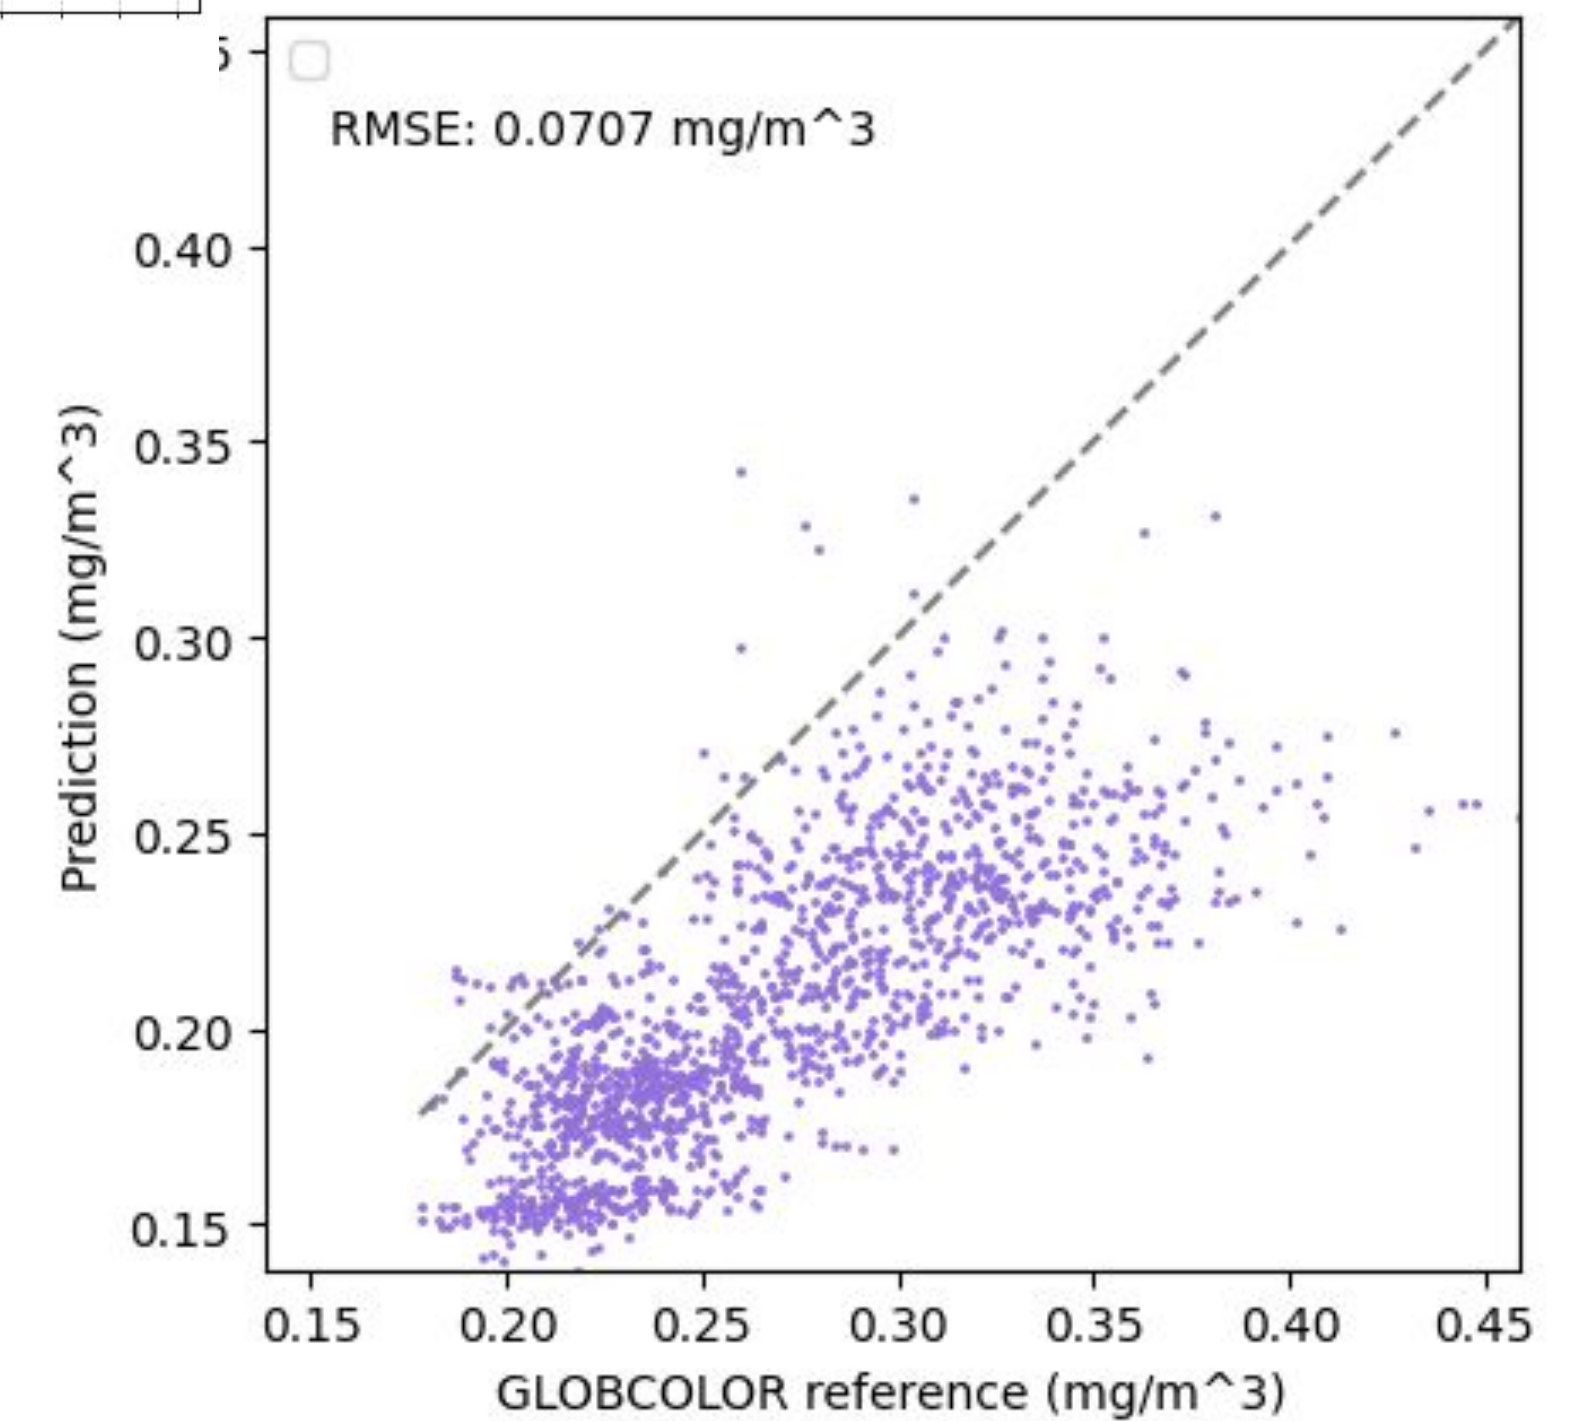


# Résultats: ITCZ (Chl-a)



# Résultats: Mauritanie (Chl-a)

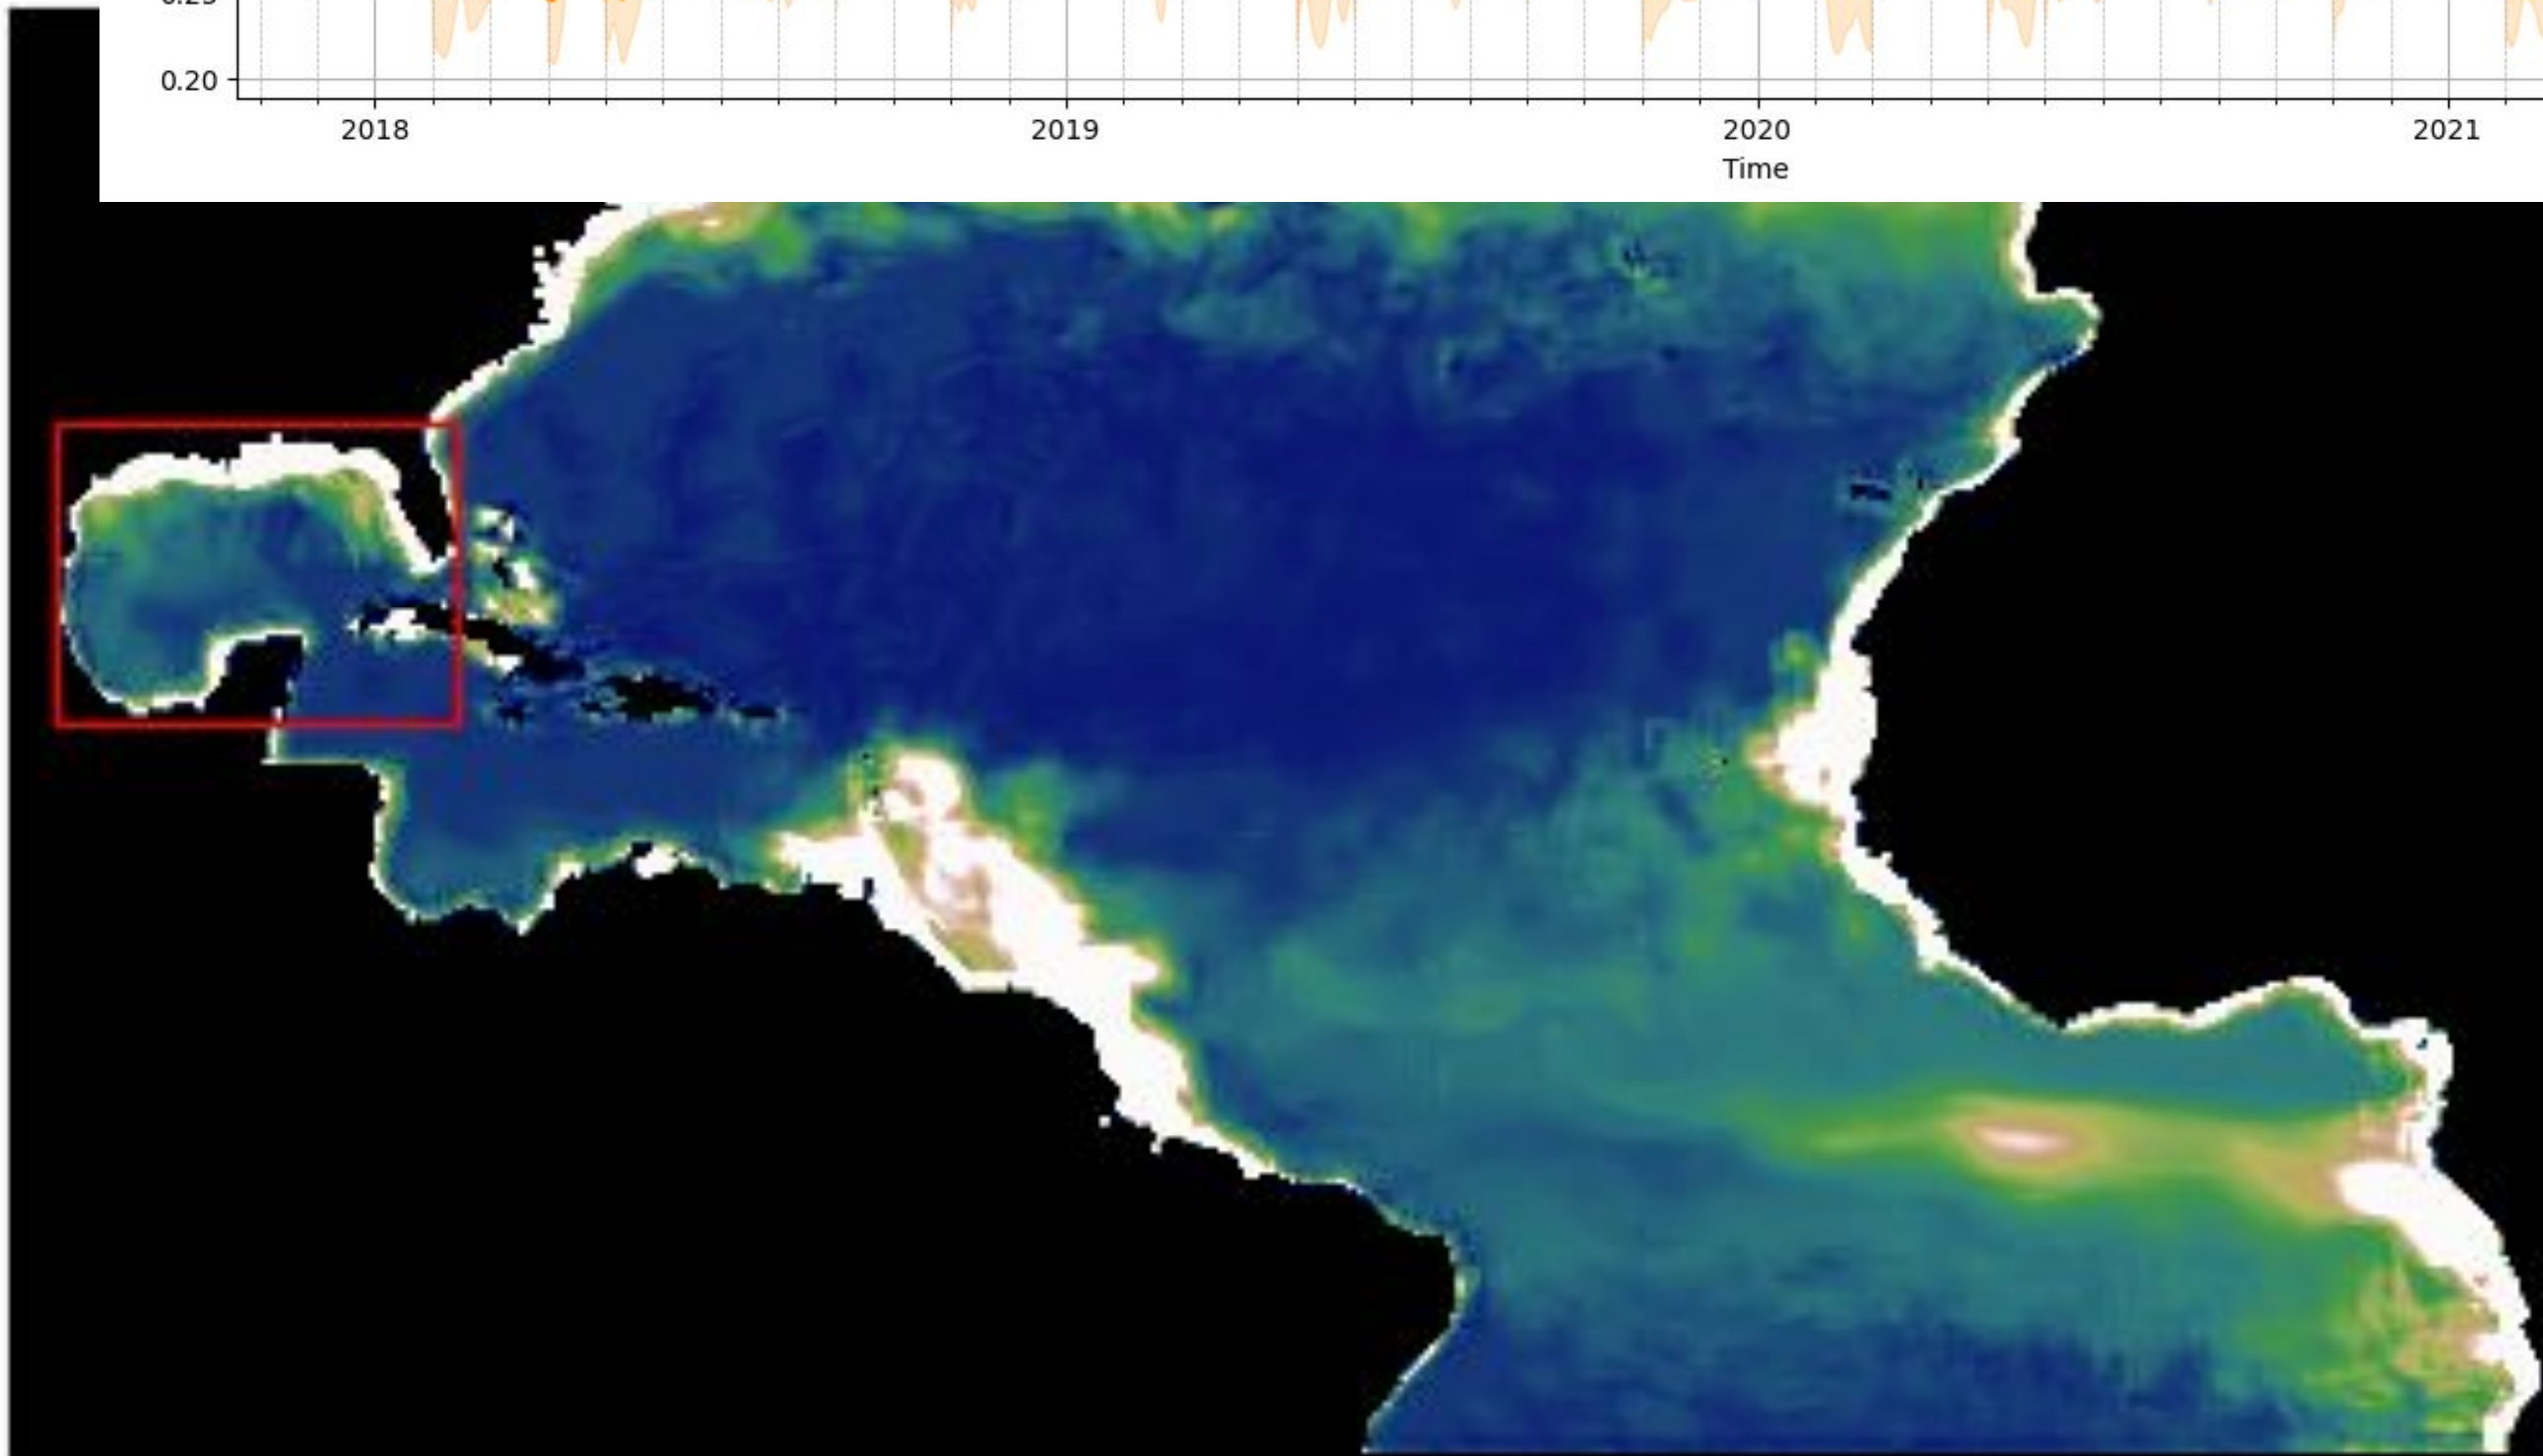




# Résultats: Amazone (Chl-a)





# Résultats: G. Mexique (Chl-a)




# Limites du projet

- Le modèle de nitrate surpasse celui de la chlorophylle. Le première a une légère tendance à **surestimer**, tandis que la dernière a tendance à **sous-estimer**, notamment dans les régions fortement influencées par **l'upwelling**. Une analyse des erreurs plus détaillée est nécessaire.
- Il existe également des limites liées à la performance et à la fiabilité **des prévisions physiques**, ainsi qu'à la qualité et à la **disponibilité des données** biochimiques.
- L'augmentation de la **complexité** du modèle et de la **résolution** des données a le potentiel de produire de meilleurs résultats, mais cela s'accompagne d'un **coût accru en ressources**.
- Les limitations des **autoencoders**, celles inhérentes à l'architecture et celles dues à la nature du problème étudié.
- Faible **explicabilité**

# Étapes suivantes

- **Expansion** pour une couverture plus globale, à la fois spatiale et en termes de variables prévues. Cela inclura probablement l'utilisation d'architectures autres que les autoencoders.
- **Interprétabilité** et explicabilité
- Des **solutions hybrides**, s'appuyant sur des prévisions numériques et l'IA pour la correction des biais, l'assimilation des données, etc.



**Merci beaucoup!**