

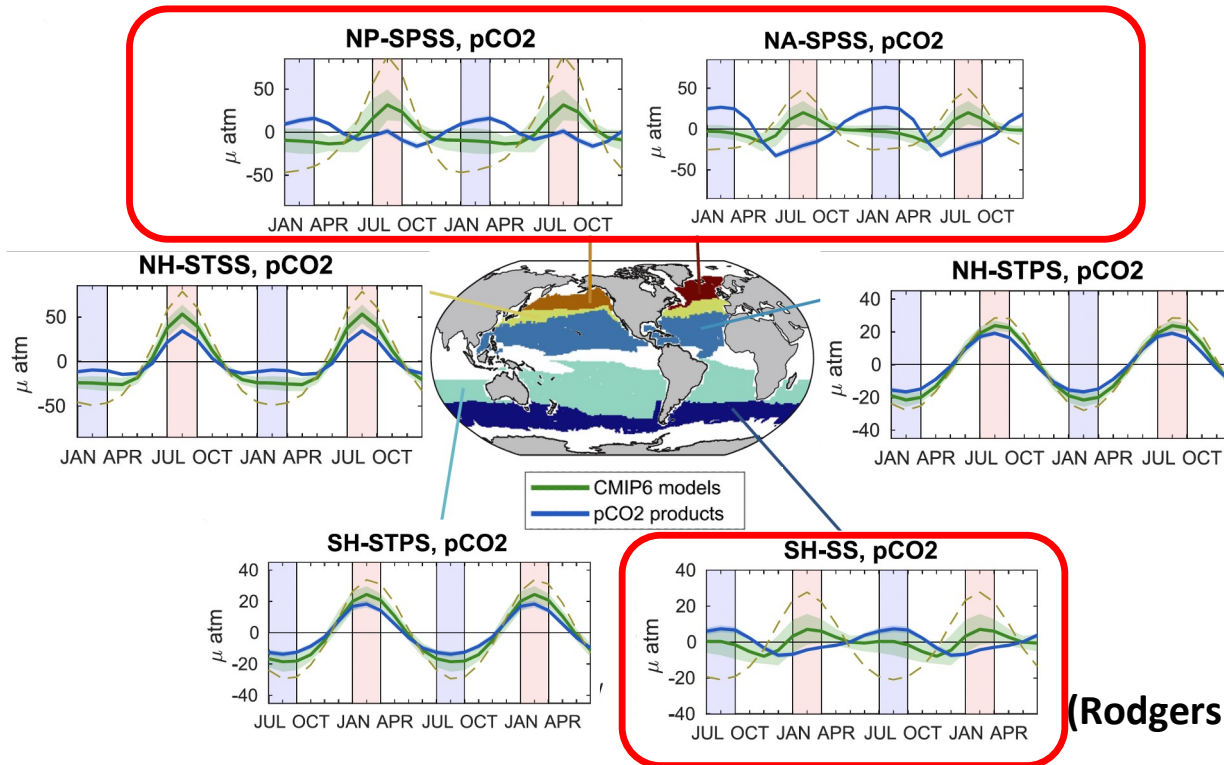


**MERCATOR
OCEAN**
INTERNATIONAL

Lien entre observations et modélisation biogéochimique

Alexandre Mignot, Quentin Hyvernats, Julien Lamouroux, Elodie Gutknecht,
Coralie Perruche et Xiaogang Xing (Seconde institute of oceanography)

“Equations governing biogeochemical state variables are empirical and, except for mass conservation, are not derived from fundamental laws and first principles such as the Navier–Stokes equations. As a result, there are no universally agreed upon parameterizations or optimal model structures. (Fennel et al., 2022)”

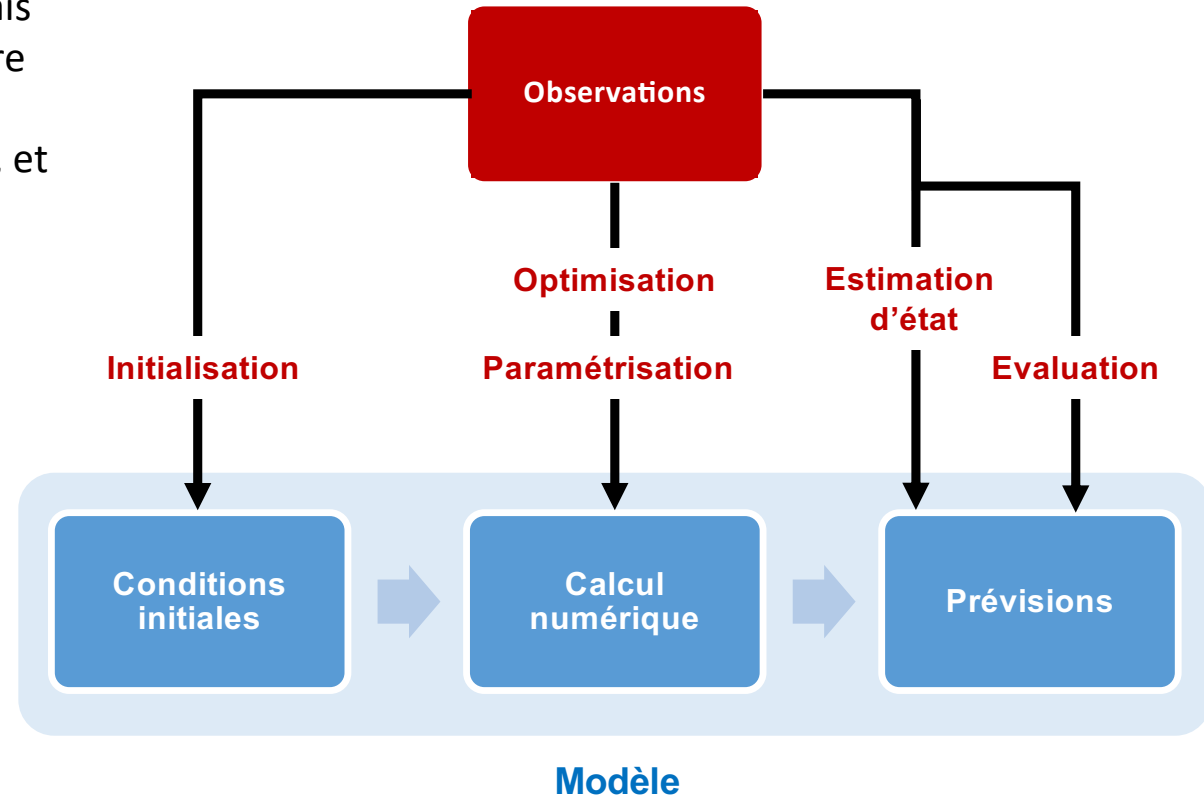


(Rodgers et al., 2023)

La nature empirique des modèles BGC engendre des **biais systématiques**, lesquels persistent d'un modèle à l'autre, malgré des structures et des paramètres distincts.

Les observations sont essentielles pour corriger les biais systématiques (**paramétrisation, optimisation**), réduire les erreurs aléatoires (**estimation d'état**), évaluer la performance des prévisions des modèles (**évaluation**), et définir les conditions initiales (**initialisation**).


- **Initialisation** : définir les conditions initiales
- **Paramétrisation** : tester/définir la structure du modèle
- **Optimisation** : optimiser les paramètres
- **Estimation d'état** : modification des variables d'états
- **Evaluation** : comparaison modèle-observation



“Until recently, observational data sets have been **too limited** in space, time or breadth [...]. **The rise of global autonomous biogeochemical observation networks is beginning to alleviate this problem** and will likely prove transformative for further development of models ” (Fennel et al., 2022)


WORLD OCEAN ATLAS 2023

Oxygène

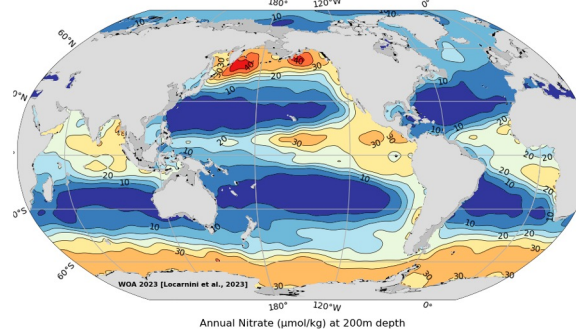
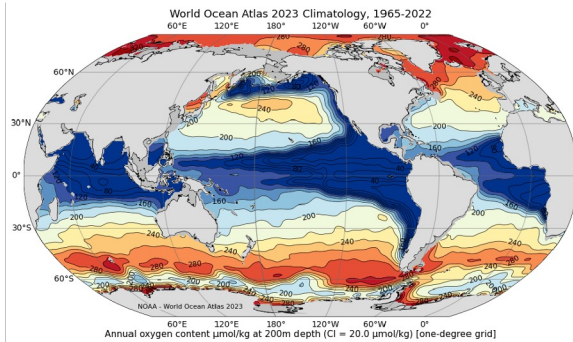


BGC-Argo


Nitrate




“Each ocean observing system collecting nutrient data adds additional data coverage and may have different **data uncertainties and calibrations that must be reconciled before combining into an internally consistent climatology.** (Garcia et al. 2024)”



Distribution of WOA Nitrate obs

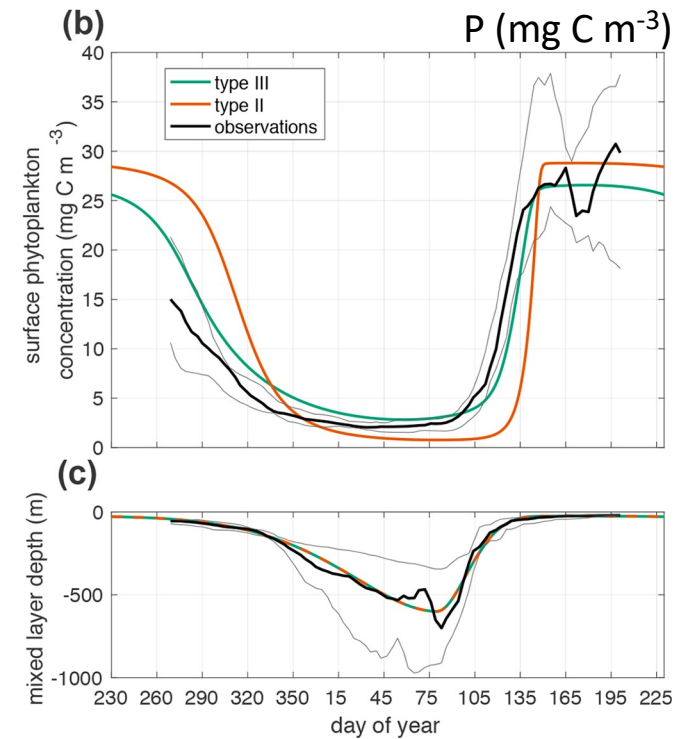




Distribution of BGC-Argo Nitrate obs



Garcia et al. (2024)




Comparaison de deux fonctions de prédation du zooplancton avec les données BGC-Argo




« our study suggests that **BGC-Argo observations** can therefore **be used** to infer the functional form of **grazing functions**, an aspect of plankton ecology that is otherwise very difficult to quantify. »

Freilich, Mignot et al. (2021)

Optimisation de paramètres d'un modèle BGC (PISCES) 1D à partir de données BGC-Argo



- ★ Variables observées par BGC-Argo
- ★ Variables générées par l'IA à partir de T,S, oxygène BGC-Argo

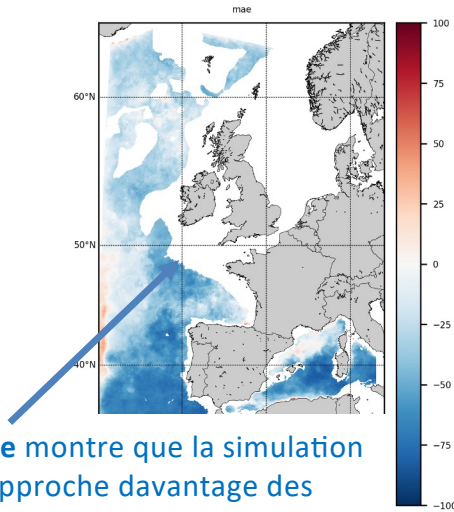
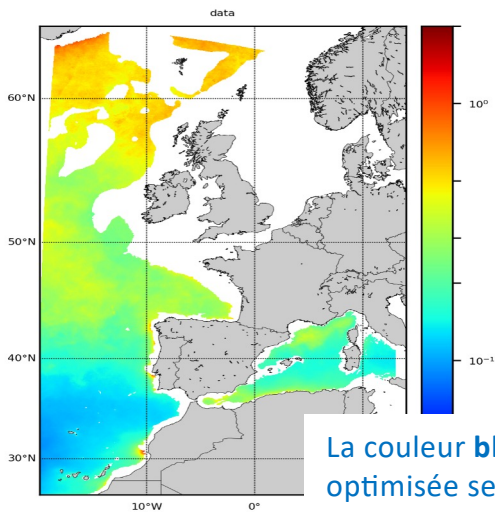


Ce nouveau jeu de paramètres permet au modèle PISCES 1D de reproduire les variables d'état en cohérence avec les observations

Implémentation du jeu de paramètre obtenu en 1D dans un modèle 3D régional



Chla satellite (mg m-3)

% d'amélioration par rapport au modèle NEMO-PISCES de référence




La couleur **bleue** montre que la simulation optimisée se rapproche davantage des estimations de Chla par satellite comparée à la simulation de référence (amélioration de 40- 50 %)

- Produit pCO₂ 3D issu des obs.
- Simulation de référence
- Simulation optimisée



(Rodgers et al., 2023)

Paramètres les plus impactants




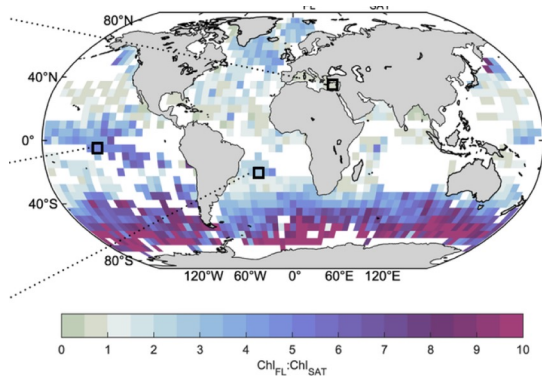
L'optimisation des paramètres grâce aux données BGC-Argo permet de **corriger les biais systématiques** (chl-a, nutriments, oxygène, carbone) et de réajuster le cycle saisonnier du pCO₂.

Hyvernat et al. (in preparation)

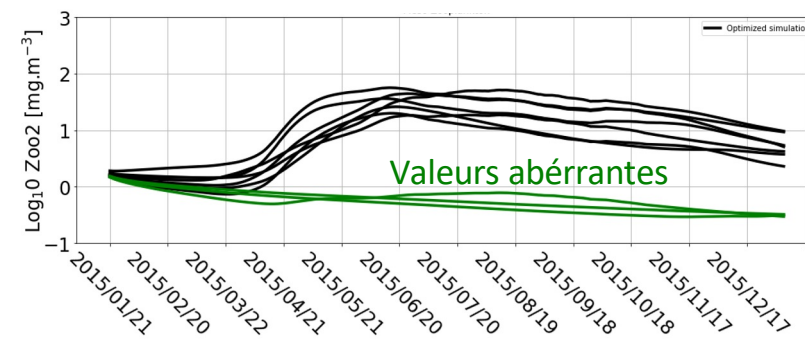
Quels enseignements peut-on tirer de cette étude ?

1. **Les variables générées par l'IA** à partir des données T, S et oxygène des BGC-Argo apportent de la **nouvelle information pour contraindre les modèles**.
2. **Cohérence nécessaire** entre les données Chla du **satellite** et celles des **BGC-Argo**.
3. **Cohérence des erreurs** entre satellite (*erreur biodiversité ~ 100-200 %*) et BGC-Argo (*erreur ~10-30 %*)
4. **Rôle crucial des observations de zooplancton** : une optimisation peut conduire à des résultats aberrants pour le méso-zooplancton, même si les autres variables sont correctement modélisées.

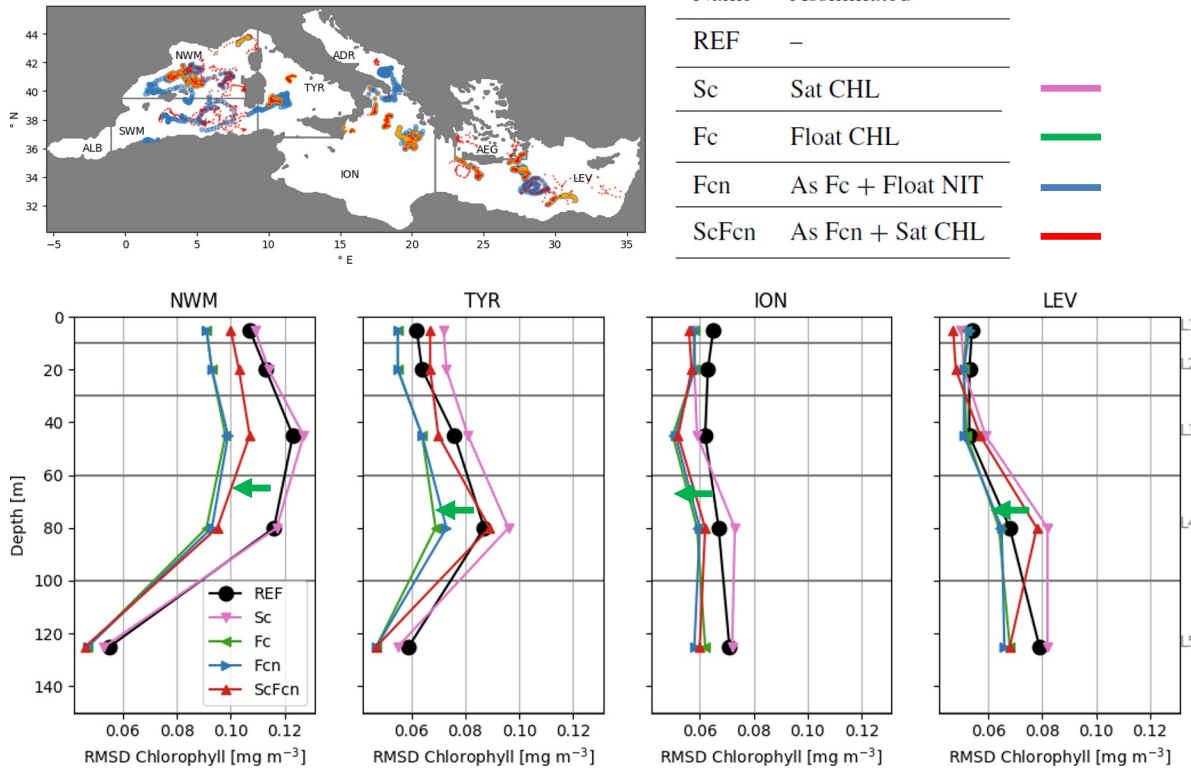
Ratio between BGC-Argo
Chla and satellite Chla



Meso-zooplankton



Assimilation multi-plateforme conjointe satellite (Chla) et BGC-Argo (Chla, nitrate)



“The RMSD increase [...] can be ascribed to **discrepancies between the two datasets** obtained by different measurement methods [...] fluorescence-derived methods and reflectance-based models **have different sensitivity and calibration pattern**”

“In perspective, when **the inconsistency between satellite and float will be solved**, the multi-platform assimilation will provide improvements over large areas thanks to the relevant spatial coverage of satellite observations”

Assimilation de la **Chla satellite** : augmente l'erreur (RMSD)

Assimilation de la **Chla et Nitrate BGC-Argo**: diminue l'erreur (RMSD)

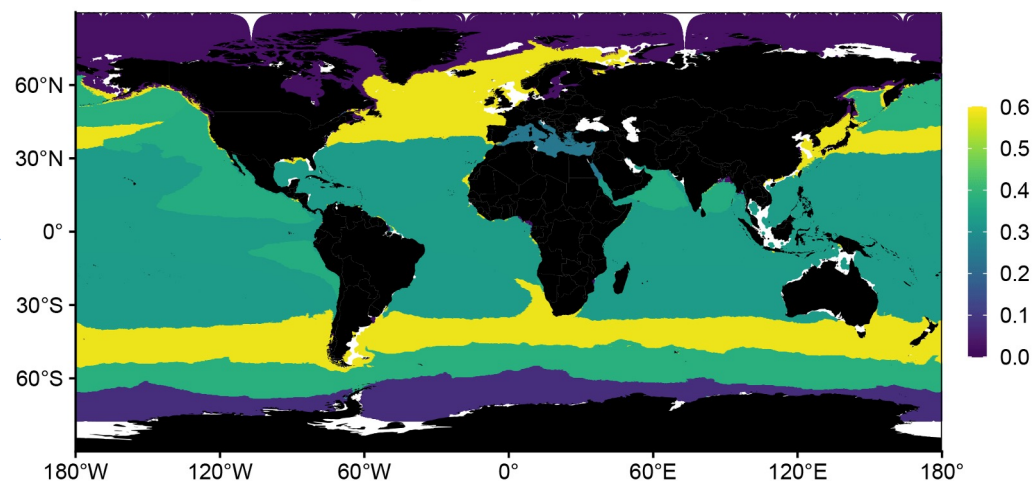
Évaluation des sorties du modèle global du Copernicus marine service à l'aide du réseau de flotteurs BGC-Argo

23 Assessment metrics

Process	Metric	Definition	Units	Assessment level
Carbonate chemistry	$p\text{CO}_2^{\text{mixed}}$	Depth-averaged $p\text{CO}_2$ in the mixed layer	μatm	State variable
	$\text{DIC}^{\text{mixed}}$	Depth-averaged DIC in the mixed layer	$\mu\text{mol kg}^{-1}$	State variable
	$\text{Alk}^{\text{mixed}}$	Depth-averaged Alk in the mixed layer	$\mu\text{mol kg}^{-1}$	State variable
	DIC^{meso}	Depth-averaged DIC in the mesopelagic layer	$\mu\text{mol kg}^{-1}$	State variable
	Alk^{meso}	Depth-averaged Alk in the mesopelagic layer	$\mu\text{mol kg}^{-1}$	State variable
	pH^{mixed}	Depth-averaged pH in the mixed layer	Total	State variable
	pH^{meso}	Depth-averaged pH in the mesopelagic layer	Total	State variable
Biological carbon pump	$\text{Chl}^{\text{mixed}}$	Depth-averaged Chl a in the mixed layer	mg m^{-3}	State variable
	$\text{NO}_3^{\text{mixed}}$	Depth-averaged NO_3 in the mixed layer	$\mu\text{mol kg}^{-1}$	State variable
	$\text{PO}_4^{\text{mixed}}$	Depth-averaged PO_4 in the mixed layer	$\mu\text{mol kg}^{-1}$	State variable
	Si^{mixed}	Depth-averaged Si in the mixed layer	$\mu\text{mol kg}^{-1}$	State variable
	$\text{NO}_3^{\text{meso}}$	Depth-averaged NO_3 in the mesopelagic layer	$\mu\text{mol kg}^{-1}$	State variable
	$\text{PO}_4^{\text{meso}}$	Depth-averaged PO_4 in the mesopelagic layer	$\mu\text{mol kg}^{-1}$	State variable
	Si^{meso}	Depth-averaged Si in the mesopelagic layer	$\mu\text{mol kg}^{-1}$	State variable
	$\text{POC}^{\text{mixed}}$	Depth-averaged POC in the mixed layer	mg m^{-3}	State variable
	POC^{meso}	Depth-averaged POC in the mesopelagic layer	mg m^{-3}	State variable
	ChlDCM	Magnitude of DCM	mg m^{-3}	Emergent property
	H_{DCM}	Depth of DCM	m	Emergent property
H_{nit}	Depth of nitracline	m	Emergent property	
Oxygen levels	$\text{O}_2^{\text{mixed}}$	Depth-averaged O_2 in the mixed layer	$\mu\text{mol kg}^{-1}$	State variable
	O_2^{meso}	Depth-averaged O_2 in the mesopelagic layer	$\mu\text{mol kg}^{-1}$	State variable
	O_2^{min}	Value of O_2 minimum	$\mu\text{mol kg}^{-1}$	Emergent property
	$H_{\text{O}_2^{\text{min}}}$	Depth of O_2 minimum	m	Emergent property



Median model efficiency



The model efficiency statistical score tests whether the model outperforms a BGC-Argo climatology (values >0)

Les plus fortes erreurs du modèle se concentrent dans les régions de l'Arctique et de l'océan Austral

Mignot et al. (2023)

*“we strongly recommend **enhancing the Arctic region and in the Southern Oceans** where in situ observations are scarce. These observations are critical to better constrain the model in these two regions where the assimilation of satellite observations is not possible for most of the year.”*

Points clés:

1. Les observations sont essentielles pour **l'initialisation, la paramétrisation, l'optimisation, l'estimation d'état, et l'évaluation** des modèles BGC.
2. L'expansion du réseau d'observation **BGC-Argo** joue un rôle **clé** dans l'amélioration des modèles océaniques.
3. Les variables générées par **l'IA** à partir des données de température, salinité et oxygène issues des BGC-Argo fournissent des **informations supplémentaires** précieuses pour affiner les modèles.
4. Les différents réseaux d'observation (**navires, BGC-Argo et satellites**), doivent être **harmonisés** en termes de **calibration** et d'estimations des **erreurs**.
5. Les observations **BGC-Argo** sont indispensables dans les **hautes latitudes**, où les données des navires et des satellites sont peu nombreuses et où les modèles présentent d'importants biais systématiques, notamment pour des variables comme le pCO₂.
6. Besoin crucial des **observations de zooplancton** pour calibrer les modèles.

Besoins
