

EddyNet : Réseau de neurones convolutifs pour la détection et la classification des tourbillons océaniques

R. Lguensat¹

S. Rjiba²

R. Fablet²

E. Mason³

¹ Institut des Géosciences de L'Environnement ; Université Grenoble Alpes ; Grenoble, France

² IMT Atlantique ; UBL ; Lab-STICC ; Brest, France

³ Mediterranean Institute for Advanced Studies (IMEDEA/CSIC-UIB), Espagne

redouane.lguensat@univ-grenoble-alpes.fr

1 Résumé

Nous présentons EddyNet, une famille d'architectures d'apprentissage profond pour la détection et la classification automatique des tourbillons à partir de cartes d'élévation de la surface de la mer (SSH). La version classique d'EddyNet est formée par la concaténation d'un réseau de neurones convolutifs profond de type encodeur-décodeur suivi par une couche de classification pixel par pixel. La sortie d'EddyNet est une carte de la même taille que l'entrée où chaque pixel est classifié de la manière suivante : '0' : absence de tourbillons, '1' : tourbillon anticyclonique, '2' : tourbillon cyclonique. Nous présentons aussi une nouvelle version baptisée EddyResnet qui utilise des blocs résiduels, et nous la combinons avec la méthode du Level Set. Le code Python basé sur Keras et utilisable sur des processeurs graphiques (GPU), les données d'apprentissage et les poids appris d'EddyNet sont open-source et disponibles sur la page <https://github.com/redouanelg/EddyNet>.

2 Introduction et état de l'art

Les tourbillons océaniques à mésoéchelle peuvent être définis comme des masses d'eau en rotation, ils sont omniprésents dans l'océan et véhiculent des informations critiques sur la circulation océanique à grande échelle [1, 2]. Avec le développement des missions altimétriques et depuis la disponibilité de deux altimètres ou plus en même temps, les produits fusionnés de Sea Surface Height (SSH) ont atteint une résolution suffisante pour permettre la détection des tourbillons mésoéchelle [3, 4]. Les cartes SSH permettent de distinguer deux classes de tourbillons : i) les tourbillons anticycloniques reconnus par leur SLA positif (Sea Level Anomaly qui est une anomalie SSH par rapport à une moyenne donnée) et ii) les tourbillons cycloniques caractérisés par leur SLA négatif.

Ces dernières années, plusieurs études ont été menées dans le but de détecter et de classer les tourbillons de manière automatique. Deux grandes familles de méthodes prédominent dans la littérature, à savoir les méthodes basées sur les paramètres physiques et les méthodes basées sur les contours géométriques. La méthode des paramètres physiques la plus populaire est la méthode des paramètres Okubo-Weiss [6, 7]. La méthode des paramètres Okubo-Weiss est cependant critiquée pour ses paramètres basés sur l'expertise et spécifiques à la région, ainsi que pour sa sensibilité aux cartes SSH bruyantes [8]. D'autres méthodes ont été développées depuis lors en utilisant d'autres techniques telles que la décomposition des ondelettes [9], l'angle d'enroulement [10], etc. Les méthodes basées sur la géométrie reposent sur la prise en compte des tourbillons comme des formes elliptiques et l'utilisation de techniques de contour fermé, la méthode la plus populaire reste la méthode Chelton et al. [2] (ci-après appelée CSS11). Les méthodes basées apprentissage automatique ont également été utilisées dans le passé pour proposer une solution au problème [11, 12], récemment ils reçoivent à nouveau une attention croissante [13, 14].

Nous proposons dans ce travail de tirer part des progrès de l'apprentissage profond pour traiter la détection et de la classification des tourbillons océaniques. Notre méthode nécessite une base de données composée de cartes SSH et de leurs résultats de détection et de classification des tourbillons. Dans ce travail, nous formons notre base d'apprentissage à partir des résultats de *py-eddy-tracker* (ci-après PET14) [15], l'algorithme développé par Mason et al. est étroitement lié à CSS11 mais présente




FIGURE 1 – Exemple d'un couple d'apprentissage : carte SSH - résultat de segmentation, anticyclonique (vert), cyclonique (marron), absence de tourbillons (bleu) [5]

quelques différences significatives telles que le fait de ne pas permettre des extrêmes locaux multiples dans un tourbillon.

3 Méthode et résultats

3.1 EddyNet

L'architecture d'EddyNet [5] est inspirée de U-Net[16], elle consiste en un encodeur-décodeur convolutif avec des "skip connections" puis une couche de classification pixel par pixel. Nous laissons le lecteur prendre le soin de lire l'article [5] pour plus de détails, et nous focaliserons plus dans ce papier sur une nouvelle variante d'EddyNet.

3.2 Level Set

La méthode Level Set est largement appliquée dans le domaine de la segmentation d'image avec des contours actifs vu sa capacité à gérer différents changements topologiques. L'idée de base est de définir une fonction implicite pour représenter les contours comme l'ensemble de niveaux zéro. Une région ouverte Ω est bornée par une interface Γ qui est définie à l'instant t au point x comme le niveau zéro d'une fonction lisse $\varphi(x,t)$. Cette fonction a les propriétés suivantes :

$$\varphi(x,t) > 0 \text{ si } x \in \Omega \quad \varphi(x,t) < 0 \text{ si } x \notin \Omega \quad \varphi(x,t) = 0 \text{ si } x \in \Gamma$$

3.3 Apprentissage profond pour Level Set

Dans ce travail, nous formons notre base d'apprentissage à partir de la base d'apprentissage utilisée pour EddyNet [5]. À partir des cartes de segmentations, nous avons calculé la transformation Level Set. Le but sera de prédire, à partir d'une carte SSH, une carte de niveau distance signée au lieu d'une carte de segmentation. La valeur de cette carte pour un pixel donné est la distance signée entre le pixel et la frontière de segmentation. Les signes indiquent les étiquettes de segmentation. Nous cherchons ensuite à établir une interface qui sépare avec précision les tourbillons de l'arrière-plan. Les distances signées pour les pixels à l'intérieur et à l'extérieur de l'interface doivent être respectivement positives et négatives, et leurs valeurs absolues peuvent augmenter progressivement à mesure que les positions des pixels s'éloignent progressivement des contours de l'objet. Avec la distance signée, la carte de segmentation finale peut être générée facilement par la transformation de Heaviside qui projette les réels négatifs à 0 et les réels positifs à 1. Donc, au lieu d'apprendre directement une étiquette binaire pour chaque pixel indépendamment, notre réseau est formé pour apprendre les cartes de niveaux pour les tourbillons. L'avantage de combiner des Level Set avec des réseaux profonds est que la fonction Level Set peut exprimer les étiquettes de segmentation par les signes. En même temps, les valeurs absolues peuvent changer progressivement, de sorte que notre réseau sera capable de modéliser la corrélation des pixels. Cela aide le réseau à apprendre le changement progressif autour des frontières plus naturellement et facilement. Un autre avantage réside dans le fait que les valeurs positives les plus importantes seront au centre des tourbillons et les valeurs négatives les plus importantes seront le plus loin possible du contours des tourbillons. Cette distribution fait que les erreurs des faux tourbillons seront fortement pénalisés alors que les erreurs de forme seront plutôt tolérées.

3.4 EddyResNet

L'architecture d'EddyResNet est largement inspirée de ResNet, mais nous l'utilisons pour un problème de régression. Elle consiste en un encodeur-décodeur convolutif avec des "skip connections". Un module ResNet contient une couche convolutive 3*3 suivie d'une normalisation par batch puis d'une activation de type "ReLU" puis une couche convolutive 3*3 et une normalisation par batch. La sortie est additionnée à l'entrée pour enfin être activée par un "ReLU". Ce module constitue la brique élémentaire de notre architecture. Pour l'encodeur, ce module va être suivi par des max pooling 2*2 pour réduire la dimension de l'entrée et des dropouts pour minimiser le phénomène de sur-apprentissage. Pour la partie décodeur, il sera suivi par des convolutions transposées (dé-convolution) pour restaurer la résolution d'origine. L'architecture est illustrée dans la figure 2.

Ce modèle nous permet de prédire une carte de niveau. À partir de cette carte, un résultat est obtenu sur la valeur de chaque pixel pour déduire une carte de segmentation. Notre modèle final cherchera à minimiser la fonction de coût relative à la pré-

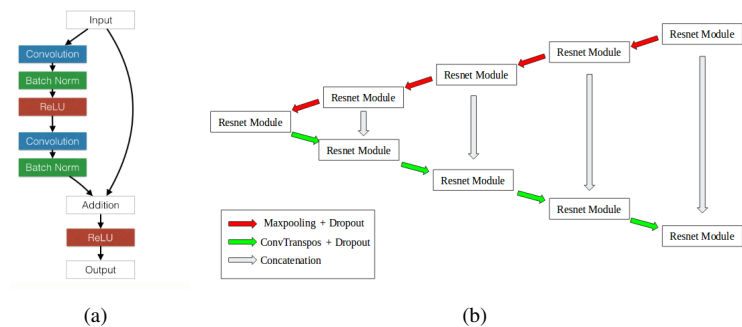


FIGURE 2 – Architecture de ResNet

diction de la carte de niveau ainsi que la carte de segmentation. Donc c'est une combinaison linéaire entre l'erreur quadratique logarithmique moyenne pour le Level Set et l'erreur sur le Dice coefficient pour la segmentation.

3.5 Performance

Le tableau suivant montre la comparaison entre la version d'Eddynet présentée dans [5], une version d'Eddynet avec le Level Set, puis la nouvelle architecture "EddyResnet" avec Level Set. La nouvelle méthode présentée surperforme les autres versions en terme de mesure F1, ce qui confirme l'utilité de l'ajout du Level Set, et aussi l'apport des blocs résiduels.

TABLE 1 – Comparaison des performances de la version classique d'Eddynet, eddynet avec Level Set et la version EddyResNet avec Level Set. On mesure ces performances avec 3 différents critères qui sont : la précision, le rappel et la F-mesure. On reporte aussi la valeur de l'exactitude générale.

Model	#Params	Train Loss	Metrics	Anticyclonic	Cyclonic	Non Eddy	Mean	Global Accuracy
				Results				
Eddynet	178,595	Dice Loss	precision	0.525	0.466	0.965	0.652	90.7%
			recall	0.668	0.662	0.932	0.754	
			F1 score	0.588	0.547	0.948	0.694	
Eddynet with Level Set	178,595	Dice Loss + Logarithmic MSE	precision	0.571	0.523	0.959	0.685	91.9%
			recall	0.603	0.610	0.950	0.721	
			F1 score	0.586	0.563	0.955	0.701	
EddyResNet with Level Set	1,225,861	Dice Loss + Logarithmic MSE	precision	0.621	0.583	0.961	0.722	92.8%
			recall	0.63	0.611	0.959	0.734	
			F1 score	0.626	0.597	0.960	0.728	

Références

- [1] W. R. Holland, "The role of mesoscale eddies in the general circulation of the ocean—numerical experiments using a wind-driven quasi-geostrophic model," *Journal of Physical Oceanography*, vol. 8, no. 3, pp. 363–392, 1978.
- [2] D. B. Chelton, M. G. Schlax, and R. M. Samelson, "Global observations of nonlinear mesoscale eddies," *Progress in Oceanography*, vol. 91, no. 2, pp. 167–216, 2011.
- [3] J. H. Faghmous, I. Frenger, Y. Yao, R. Warmka, A. Lindell, and V. Kumar, "A daily global mesoscale ocean eddy dataset from satellite altimetry," *Scientific data*, vol. 2, 2015.
- [4] A. Pascual, Y. Faugère, G. Larnicol, and P.-Y. Le Traon, "Improved description of the ocean mesoscale variability by combining four satellite altimeters," *Geophysical Research Letters*, vol. 33, no. 2, 2006.
- [5] R. Lguensat, M. Sun, R. Fablet, E. Mason, P. Tandeo, and G. Chen, "Eddynet : A deep neural network for pixel-wise classification of oceanic eddies," in *IEEE International Geoscience and Remote Sensing Symposium*, 2018.
- [6] A. Okubo, "Horizontal dispersion of floatable particles in the vicinity of velocity singularities such as convergences," in *Deep sea research and oceanographic abstracts*, vol. 17, no. 3. Elsevier, 1970, pp. 445–454.
- [7] J. Weiss, "The dynamics of enstrophy transfer in two-dimensional hydrodynamics," *Physica D : Nonlinear Phenomena*, vol. 48, no. 2-3, pp. 273–294, 1991.
- [8] D. B. Chelton, M. G. Schlax, R. M. Samelson, and R. A. de Szoeke, "Global observations of large oceanic eddies," *Geophysical Research Letters*, vol. 34, no. 15, 2007.
- [9] A. Turiel, J. Isern-Fontanet, and E. García-Ladona, "Wavelet filtering to extract coherent vortices from altimetric data," *Journal of Atmospheric and Oceanic Technology*, vol. 24, no. 12, pp. 2103–2119, 2007.
- [10] I. A. Sadarjoen and F. H. Post, "Geometric methods for vortex extraction," in *Data Visualization '99*. Springer, 1999, pp. 53–62.
- [11] M. Castellani, "Identification of eddies from sea surface temperature maps with neural networks," *International journal of remote sensing*, vol. 27, no. 8, pp. 1601–1618, 2006.
- [12] J. Hai, Y. Xiaomei, G. Jianming, and G. Zhenyu, "Automatic eddy extraction from sst imagery using artificial neural network," *The international archives of the photogrammetry, remote sensing and spatial information science*, pp. 279–282, 2008.
- [13] M. D. Ashkezari, C. N. Hill, C. N. Follett, G. Forget, and M. J. Follows, "Oceanic eddy detection and lifetime forecast using machine learning methods," *Geophysical Research Letters*, vol. 43, no. 23, 2016.
- [14] D. Huang, Y. Du, Q. He, W. Song, and A. Liotta, "Deepedly : A simple deep architecture for mesoscale oceanic eddy detection in sar images," in *2017 IEEE 14th International Conference on Networking, Sensing and Control (ICNSC)*, May 2017, pp. 673–678.
- [15] E. Mason, A. Pascual, and J. C. McWilliams, "A new sea surface height-based code for oceanic mesoscale eddy tracking," *Journal of Atmospheric and Oceanic Technology*, vol. 31, no. 5, pp. 1181–1188, 2014.
- [16] O. Ronneberger, P. Fischer, and T. Brox, "U-net : Convolutional networks for biomedical image segmentation," in *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, 2015, pp. 234–241.