

Prédiction des transitions spatiales de piraterie maritime : une approche duale multi-résolution

Loïc Salmon*, Pedro Merino Laso**

*Université de la Nouvelle-Calédonie, - BP R4 98851 Nouméa Cedex, Nouvelle-Calédonie
ISEA (Institut des Sciences Exactes et Appliquées)
loic.salmon@unc.nc

**French Maritime Academy (ENSM), 1 Rue de la Noë, 44300 Nantes, France
IRENav, EA 3634, BRCM Brest, Ecole Navale C600, 29240 Brest cedex 9, France
pedro.merino-laso@supmaritime.fr

Résumé. La littérature scientifique concernant les données spatio-temporelle se concentre principalement sur la prédiction de trajectoires d'objets mobiles ou l'observation d'événements sur des zones géographiques fixes. Peu d'études abordent l'analyse prédictive des variations dynamiques de zones spatiales elles-mêmes dans le temps. Cette recherche propose une méthodologie duale pour modéliser l'évolution de la piraterie maritime (~350 incidents/an mondialement) : (1) prédiction quantitative à résolution macroscopique (~4000 km/cellule) pour l'allocation stratégique des ressources, et (2) classification qualitative à résolution mésoscopique (~1000 km/cellule) pour détecter les transitions spatiales régionales. L'évaluation sur 15 947 incidents (1978-2024) révèle que la validation standard surestime systématiquement les modèles complexes, notamment en régression où LSTM est bien moins efficace en validation walk-forward. En classification, tous les modèles se dégradent en walk-forward, mais Logistic Regression démontre une robustesse avec une dégradation minimale, devenant le meilleur modèle en validation temporelle stricte. L'architecture hybride proposée (Ridge pour la régression et LSTM+Logistic pour la classification) offre une robustesse temporelle pour la surveillance opérationnelle.

1 Introduction

La piraterie maritime moderne représente un défi sécuritaire et économique persistant pour le commerce international, avec un coût global estimé à plusieurs milliards d'euros annuellement Bowden et al. (2010). Cette problématique ne se limite pas aux pertes financières directes : elle affecte également la stabilité des chaînes d'approvisionnement mondiales et génère des répercussions géopolitiques importantes dans les régions affectées. De ce fait, elle a été étudiée par de nombreuses disciplines Merino Laso et Salmon (2025).

L'observation des patterns géographiques de la piraterie révèle une caractéristique fondamentale souvent négligée dans la littérature existante : la mobilité spatiale des foyers d'activité pirate. Contrairement aux approches traditionnelles qui conçoivent les « zones à risque

Approche duale multi-échelle pour la prédiction adaptative de la piraterie maritime

» comme des entités géographiques fixes, l'analyse empirique démontre que ces zones évoluent considérablement au cours du temps. La Figure 1 illustre cette dynamique pour le Golfe d'Aden et la Somalie, zone emblématique de la piraterie moderne.

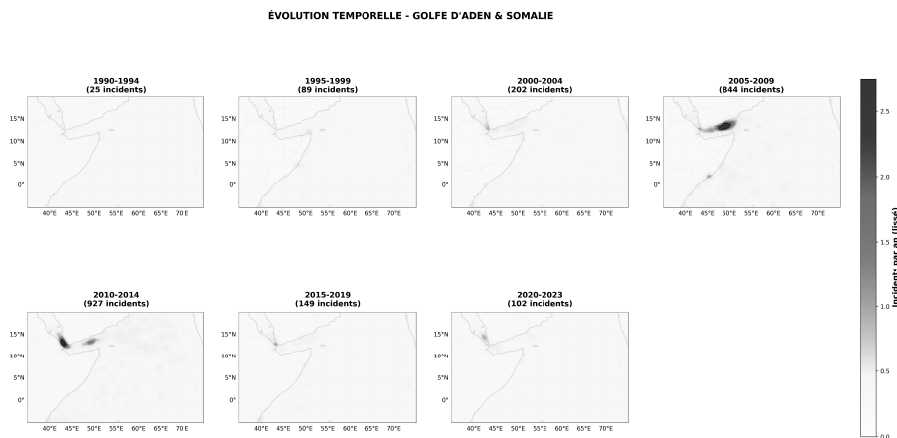


FIG. 1 – *Évolution spatio-temporelle de la piraterie dans le Golfe d'Aden et Somalie (1990-2023). La zone connaît une émergence progressive (1990-1999 : 25 incidents → 2005-2009 : 844 incidents), un pic historique (2010-2014 : 927 incidents) puis un déclin rapide suite aux déploiements militaires internationaux (2020-2023 : 102 incidents).*

Une approche multi-échelles peut permettre de répondre à des besoins opérationnels distincts tout en prenant en compte la variation de densité des zones de piraterie. Cependant, le choix de ces échelles est contraint par une réalité empirique : la piraterie maritime reste un phénomène relativement rare à l'échelle mondiale, avec environ 350 incidents documentés par an répartis sur l'ensemble des océans (15 947 incidents sur 46 ans). Cette rareté impose des résolutions spatiales suffisamment grossières pour maintenir un rapport signal/bruit acceptable.

Notre approche cible principalement la planification stratégique (allocation budgétaire annuelle, déploiement de forces navales) plutôt que les interventions tactiques immédiates. À l'échelle macro (grilles 5×5, 10×10), les décideurs ont besoin de prédictions quantitatives pour l'allocation stratégique des ressources à l'échelle océanique. Ces maillages grossiers (environ 4000 km par cellule) optimisent le rapport signal/bruit, mais masquent les dynamiques émergentes régionales. À l'échelle méso (grilles 15×15, 20×20), les acteurs opérationnels requièrent une détection qualitative des transitions spatiales. Ces maillages plus fins (environ 1000 km par cellule) offrent une sensibilité spatiale accrue au prix d'une dégradation prédictive quantitative.

Un autre enjeu méthodologique est au cœur de cette étude : à savoir comment valider rigoureusement des modèles de prédiction temporelle. La validation standard est efficace mais permet aux modèles d'apprendre sur toute la plage temporelle, incluant des périodes postérieures au test. Cette fuite d'information temporelle peut artificiellement gonfler les performances, particulièrement pour les modèles complexes comme LSTM capables de mémoriser des patterns spécifiques Cerqueira et al. (2019).

Le travail développé dans cette étude s'intéresse aux questions suivantes :

1. QR1 : Quelle est la performance relative des modèles (LSTM, Ridge, Logistic, RF) (c.f. Section 3.3.2) selon une validation temporelle stricte vs standard (c.f. Section 3.3.3) ?
2. QR2 : L'approche duale (régression grossière + classification fine) permet-elle de répondre efficacement aux besoins opérationnels distincts ?
3. QR3 : Quel est l'impact relatif de la résolution spatiale, de la fréquence temporelle et de l'architecture sur la performance prédictive ?
4. QR4 : Comment concevoir un système opérationnel exploitant les forces complémentaires des différentes résolutions spatiales ?

Les contributions principales de ce travail sont les suivantes :

1. **Contribution méthodologique** : Première comparaison systématique de la validation simple vs. walk-forward en prédiction spatio-temporelle sécuritaire, révélant une inversion de hiérarchie des modèles selon le protocole de validation.
2. **Contribution architecturale** : Proposition et validation d'une approche duale multi-résolution combinant la régression Ridge (macro) et la classification LSTM+Logistic (méso) pour répondre aux besoins opérationnels distincts.
3. **Contribution empirique** : Analyse de l'impact du déséquilibre de classes et validation de stratégies de sous-échantillonnage permettant d'améliorer significativement la détection des transitions minoritaires critiques.

La suite de l'article est organisée comme suit : la Section 2 présente l'état de l'art sur la prédiction spatio-temporelle et la piraterie maritime. La Section 3 détaille notre méthodologie duale multi-résolution. La Section 4 présente les résultats expérimentaux. La Section 5 discute les implications et propose une architecture opérationnelle. La Section 6 conclut sur les apports et perspectives.

2 État de l'art

Les approches existantes qui pourront être appliquées à la prédiction de la piraterie maritime peuvent être regroupées en trois catégories principales : les approches géographiques traditionnelles concernant la piraterie, la modélisation prédictive moderne, et les considérations méthodologiques de validation temporelle.

Les premières études géographiques se sont concentrées sur l'identification de « hotspots » statiques, utilisant des techniques de cartographie des densités d'incidents pour définir des zones à risque élevé Marchione et Johnson (2013); Zhou et al. (2023). Ces approches, bien que fondatrices, présentent une limitation fondamentale : la conception statique de l'espace géographique, inadaptée à la nature dynamique de la piraterie. Plus récemment, Li et Yang (2023) ont développé une méthodologie de fouille de données spatio-temporelles appliquée aux incidents de piraterie, intégrant des techniques de clustering pour identifier les concentrations géographiques d'attaques. Certains travaux Salmon et Merino Laso (2024) ont identifié concrètement cette évolution spatio-temporelle en analysant les déplacements des zones de piraterie.

L'application des techniques d'apprentissage automatique a ouvert de nouvelles perspectives méthodologiques. Shortland et Vothknecht (2011) ont utilisé des modèles de forêts aléatoires pour prédire la probabilité d'attaques en fonction de variables économiques et sécuritaires. Plus récemment, Talpur et al. (2025) ont proposé une revue exhaustive sur l'IA en sécurité maritime, couvrant notamment les LSTM pour la détection d'anomalies. D'autres travaux

Qin et al. (2025) utilisent une architecture hybride (LSTM, GRU avec des mécanismes d'attention) pour la prédiction criminelle avec des résultats surpassant les modèles de référence.

La littérature récente en apprentissage temporel a souligné l'importance critique de la validation rigoureuse. Bergmeir et Benítez (2012) démontrent que la validation croisée standard peut conduire à des estimations optimistes des performances dans les séries temporelles. Cerqueira et al. (2019) proposent un cadre systématique pour l'évaluation des modèles prédictifs temporels, mettant en garde contre les fuites d'information.

L'analyse critique de la littérature révèle plusieurs limitations. Premièrement, la quasi-totalité des études adopte une résolution spatiale unique, ignorant le compromis entre la précision prédictive et la capacité de détection. Les travaux référencés dans Merino Laso et Salmon (2025) et Talpur et al. (2025) confirment cette limitation. Deuxièmement, l'absence d'une approche duale exploitant les complémentarités entre échelles spatiales pour répondre à des besoins opérationnels distincts. Enfin, une évaluation insuffisamment rigoureuse sur des données temporelles. Notre étude s'inscrit dans cette lignée en appliquant une validation walk-forward rigoureuse exhaustive sur un problème de sécurité maritime.

3 Méthodologie

3.1 Corpus et prétraitement

Notre approche repose sur l'intégration de trois sources de données internationales :

- **IMB (International Maritime Bureau)** : incidents documentés entre 1993-2020 avec géolocalisation précise Benden et al. (2021)
- **IMO-GISIS (International Maritime Organization)** : Piracy and Armed Robbery (PAR) associé au Global Integrated Shipping Information System (GISIS) collectées par l'OMI couvrant 2006 à aujourd'hui¹
- **ASAM (Anti-Shipping Activity Messages)**² : messages d'alerte avec informations détaillées (type de navire visé, la date, la position, ainsi que la description de l'attaque)

L'analyse porte sur 15.947 incidents de piraterie documentés entre 1978 et 2024, fusionnés après déduplication spatio-temporelle (21266 incidents bruts → 15947 uniques). Cette période de 46 années permet d'observer des cycles complets d'évolution des activités pirates.

3.2 Approche duale multi-résolution

Notre méthodologie exploite stratégiquement deux discrétisations spatiales complémentaires répondant à des besoins opérationnels distincts (c.f. Tableau 1). Le choix de ces résolutions est contraint par la rareté intrinsèque des événements de piraterie : avec seulement 15 947 incidents documentés sur 46 années à l'échelle mondiale (soit environ 350 incidents par an répartis sur tous les océans), une granularité spatiale trop fine résulterait en une faible densité excessive des données, compromettant la capacité prédictive des modèles.

1. <https://gisis.imo.org/>

2. <https://msi.nga.mil/Piracy>

Caractéristique	Maillage grossier (5×5, 10×10)	Maillage fin (15×15, 20×20)
Objectif	Prédiction quantitative	Classification qualitative
Besoin	Allocation stratégique océanique	Détection transitions régionales
Résolution	environ 4000 km/cellule	environ 1000 km/cellule
Cellules actives	17-39	Jusqu'à 89
Seuil activité	>5 incidents	>3 incidents
Densité incidents	50-200/cellule	10-50/cellule
Usage	Planification budgétaire annuelle et Déploiement forces navales	Ajustement zones patrouille et Alerte précoce nouveaux risques
Justification	Signal/bruit optimisé Dimensionnalité réduite	Couverture géographique plus fine

TAB. 1 – Comparaison des stratégies de maillage pour l'analyse des incidents maritimes

3.3 Espace de configurations et architectures

3.3.1 Configurations testées

Notre évaluation exhaustive explore systématiquement plusieurs dimensions pour identifier les configurations optimales :

- **Dimension spatiale** : Résolutions de 5×5 à 20×20, explorant le compromis densité/granularité.
- **Dimension temporelle** : Fréquences mensuelle (M), trimestrielle (Q) et semestrielle (6M) pour capturer différents cycles temporels de la piraterie.
- **Protocoles de validation** : Validation standard (split aléatoire 80/20) vs validation walk-forward (9 fenêtres de 2 ans) pour évaluer l'impact de la fuite temporelle.
- **Classification spécifique** : Différentes valeurs de seuils S_s (stable), S_c (changement) et S_e (émergence) testées empiriquement.
- **Gestion du déséquilibre** : Six stratégies de sous-échantillonnage de la classe majoritaire Stable (de 100% à 5%).

3.3.2 Description des architectures

Voici les différentes architectures testées sur l'ensemble des configurations décrites dans la section précédente, les détails spécifiques de chaque architecture sont donnés en Tableau 2 :

Ridge Regression : Régression linéaire avec régularisation L2 (paramètre $\alpha=1.0$). La pénalisation L2 ajoute le terme $\alpha \sum_i w_i^2$ à la fonction de coût, contrôlant la complexité du modèle en pénalisant les coefficients élevés pour éviter le surajustement.

LSTM (Long Short-Term Memory) : Réseau de neurones récurrent avec mémoire à long terme, architecture à 2 couches (32→16 neurones) avec dropout et batch normalization. Capable de capturer des dépendances temporelles grâce à ses portes d'oubli, d'entrée et de sortie.

Logistic Regression : Modèle linéaire pour classification probabiliste multinomiale avec régularisation L2 ($C=0.1$). Utilise la fonction softmax pour transformer les scores linéaires en probabilités de classes.

Random Forest : Ensemble de 200 arbres de décision avec $\text{max_depth}=20$, combinant leurs prédictions par vote majoritaire (classification) ou moyenne (régression) pour améliorer la robustesse.

Élément	Random Forest	Ridge Reg.	Logistic Reg.	LSTM Light
Type	Ensemble (Arbres)	Régression linéaire	Classification linéaire	Réseau séquentiel
Architecture	200 estimateurs	Régression L2	Multinomial	2 couches LSTM
Paramètres	max_depth=20	alpha=1.0	C=0.1	32 → 16
Régularisation	min_samples_split=5	L2	L2 (saga)	Dropout + BN
Optimiseur	-	-	-	Adam (0.001)
Loss	Gini/Entropie	MSE	Multinomial	MSE/Cross-entropy
Objectif	Robustesse	Stabilité	Classification	Séquences temp.

TAB. 2 – Comparaison détaillée des architectures de modèles testées

3.3.3 Méthodes de validation utilisées

Les deux méthodes de validation utilisées dans cet article sont la validation standard et la validation walk-forward. La validation standard correspond à un split aléatoire 80/20 où les données sont divisées sans considération temporelle. Les données sont mélangées aléatoirement, permettant au modèle d’apprendre potentiellement sur des périodes futures par rapport au test, créant une « fuite d’information temporelle ». La validation walk-forward est une division séquentielle stricte où l’entraînement sur $[t_0, t_1]$ précède toujours le test sur $[t_1, t_2]$. Aucune donnée future n’est accessible pendant l’entraînement, garantissant un test réaliste des capacités prédictives.

3.4 Variables d’entrée

Pour chaque séquence temporelle de 6 trimestres, le modèle utilise 6 variables d’entrée par pas de temps (c.f. Equation 1). Cette approche capture le niveau d’activité, la volatilité, les tendances directionnelles et la normalisation statistique, permettant au modèle de modéliser plusieurs échelles temporelles. D’autres variables testées (coordonnées spatiales x,y, valeurs des cellules voisines) dégradaient significativement les performances et ont été écartées.

$$F_t = \begin{bmatrix} x_t & \text{(valeur brute)} \\ \mu_t & \text{(moyenne mobile locale)} \\ \sigma_t & \text{(écart-type, volatilité)} \\ \Delta_t & \text{(tendance : } x_t - x_{t-5}) \\ \max_t & \text{(pic historique)} \\ z_t & \text{(z-score normalisé)} \end{bmatrix} \quad (1)$$

3.5 Classification des transitions spatiales

Pour chaque cellule active des maillages fins, nous classifions la transition entre t et $t + 1$ selon 5 catégories opérationnelles (c.f. Tableau 3. Trois configurations de seuils ont été évaluées empiriquement, variant de *très sensible* ($S_s = 5, S_c = 15, S_e = 1$) à *agressif* ($S_s = 25, S_c = 50, S_e = 3$), avec la configuration médiane *modérée* ($S_s = 20, S_c = 35, S_e = 2$).

3.6 Stratégies de sous-échantillonnage

L’augmentation de la résolution spatiale engendre un déséquilibre significatif des classes de transition : la classe **Stable** devient dominante (>70% des échantillons pour 20×20), tandis que les transitions (Émergence, Intensification, Déclin) restent minoritaires. Ce déséquilibre

Transition	Condition	Signification opérationnelle
Émergence	$x_t \leq 0$ et $x_{t+1} \geq S_e$	Nouvelle zone à risque
Intensification	$\Delta \geq +S_c\%$	Risque croissant
Stable	$-S_s\% \leq \Delta \leq +S_s\%$	Statu quo
Déclin	$\Delta \leq -S_c\%$	Risque décroissant
Extinction	$x_t \geq 1$ et $x_{t+1} = 0$	Fin d'activité

TAB. 3 – Classification des transitions spatiales. Les seuils S_s (stable), S_c (changement) et S_e (émergence) sont évalués lors de la classification.

nuit à la capacité des modèles, particulièrement LSTM, à détecter les motifs rares mais opérationnellement importants. Pour chaque stratégie, nous conservons l'intégralité des classes minoritaires (Émergence, Intensification, Déclin, Extinction) et sous-échantillons aléatoirement la classe Stable selon le ratio spécifié (c.f. Tableau 4)

Stratégie	Ratio Stable	Description
no_undersampling	100%	Aucun sous-échantillonnage (baseline)
balanced_50	50%	Classe stable réduite à 50%
balanced_25	25%	Classe stable réduite à 25%
balanced_10	10%	Classe stable réduite à 10%
balanced_5	5%	Classe stable réduite à 5%
equal_classes	Auto	Toutes les classes égales à la plus petite

TAB. 4 – Stratégies de sous-échantillonnage

4 Résultats

4.1 Résultats de la régression quantitative (maillage grossier)

4.1.1 Impact de la résolution spatiale et de la fréquence temporelle

Configuration	R^2 moy.	R^2 max	Paramètre	Densité %0
Résolution spatiale				
5×5	0,729	0,786	~17 cellules	65%
10×10	0,607	0,737	~39 cellules	70%
15×15	0,560	0,658	~60 cellules	85%
20×20	0,516	0,602	~89 cellules	>90%
30×30	0,505	0,564	~120 cellules	>95%
Fréquence temporelle				
Trimestriel (Q)	0,637	0,786	18 mois	-
Mensuel (M)	0,619	0,779	6 mois	-
Semestriel (6M)	0,494	0,701	36 mois	-

TAB. 5 – Impact combiné résolution spatiale et fréquence temporelle (split 80-20)

Analyse : L'affinement spatial dégrade la performance (-31% 5×5→30×30) par faiblesse de densité croissante (65%→95% cellules vides), diluant le signal des 15 947 incidents. Le trimestriel optimise le compromis signal/bruit, aligné aux cycles pirates (Q vs 6M : +29%). La résolution grossière (5×5, 50-200 incidents/cellule) reste indispensable pour la régression quantitative.

4.1.2 Régression : Impact du protocole de validation

L'évaluation comparative révèle un effet méthodologique important sur l'estimation des performances. Le tableau 6 présente les résultats pour la fréquence trimestrielle (Q), optimale selon l'analyse de la section précédente.

Config	Valid. Simple (80/20)		Walk-Forward (9 fenêtres)		
	LSTM	Ridge	LSTM	Ridge	Persist
5×5 Q	0,726	0,786	0,619	0,753	0,708
10×10 Q	0,706	0,543	0,591	0,623	0,542
15×15 Q	0,607	0,661	0,549	0,607	0,506
20×20 Q	0,631	0,531	0,489	0,581	0,484
Moy.	0,668	0,630	0,562	0,641	0,560

TAB. 6 – Performances R^2 en régression selon méthodologie (Trimestriel)

En validation simple (80/20), LSTM apparaît compétitif avec Ridge sur certaines résolutions (5×5, 10×10, 20×20), suggérant une architecture capable de capturer des dynamiques complexes. Cependant, la validation walk-forward révèle une réalité différente : Ridge surpasse systématiquement LSTM sur **toutes** les résolutions testées, avec des écarts allant de +5,4% à +21,6%. La dégradation moyenne de -15,8% démontre que LSTM bénéficie d'une fuite d'information temporelle en validation simple.

4.2 Résultats de la classification qualitative (maillages fins)

L'analyse de classification des transitions spatiales est donnée par le tableau 7 présentant les performances F1-macro pour la fréquence trimestrielle optimale avec le threshold "very_sensitive".

Config	Valid. Simple (80/20)			Walk-Forward (9 fenêtres)		
	LSTM	Logistic	RF	LSTM	Logistic	RF
5×5 Q	0,545	0,556	0,586	0,519	0,547	0,526
10×10 Q	0,594	0,570	0,596	0,528	0,567	0,545
15×15 Q	0,616	0,587	0,606	0,537	0,562	0,538
20×20 Q	0,626	0,607	0,623	0,577	0,586	0,569
Moy.	0,595	0,580	0,603	0,540	0,566	0,545

TAB. 7 – Performances F1-macro en classification selon méthodologie (Trimestriel Q, threshold very_sensitive sans sous échantillonnage)

4.2.1 Dégradation uniforme mais différenciée des modèles

L'analyse révèle un phénomène cohérent avec les observations en régression : tous les modèles se dégradent lors du passage en validation walk-forward, confirmant que le split aléatoire surestime systématiquement les performances par fuite d'information temporelle. LSTM et Random Forest connaissent une dégradation similaire (-9,2% pour LSTM et -9,6% pour Random Forest). A l'inverse la Logistic Regression subit une dégradation de -2,4% minime par rapport aux architectures complexes.

Le Tableau 8 présente les résultats obtenus pour chaque classe :

Transition	15×15			20×20		
	Logistic	LSTM	RF	Logistic	LSTM	RF
Stable	0,778	0,896	0,800	0,805	0,914	0,815
Extinction	0,587	0,626	0,566	0,611	0,626	0,596
Intensification	0,481	0,424	0,441	0,512	0,456	0,484
Déclin	0,551	0,520	0,520	0,603	0,584	0,590
Émergence	0,413	0,220	0,363	0,399	0,307	0,360
F1-macro	0,562	0,537	0,538	0,586	0,577	0,569

TAB. 8 – Performance par classe de transition pour les maillages fins 15×15 et 20×20 (Walk-Forward validation, sans sous-échantillonnage)

Bien que LSTM atteigne des performances compétitives en F1-macro globale, cette performance masque une limitation opérationnelle importante : le modèle sous-performe significativement sur la classe Émergence sur toutes les grilles.

4.2.2 Impact du sous-échantillonnage sur la détection des transitions minoritaires

Face au déséquilibre des classes observé, nous avons évalué l’impact des stratégies de sous-échantillonnage (Tableau 9). LSTM montre une sensibilité importante au déséquilibre : la stratégie `balanced_25` améliore F1-macro de +5,5% et F1-Émergence de +53,7%. Logistic Regression démontre une robustesse naturelle : la meilleure stratégie (`balanced_10`) n’améliore que de +0,5% F1-macro et +1,3% F1-Émergence.

	F1	Stable	Émergence	Intensification	Déclin	Extinction
LSTM						
sans échantillonnage	0,577	0,914	0,307	0,456	0,584	0,626
best (25%)	0,609	0,905	0,472	0,455	0,587	0,625
Gain	+5,5%	-1,0%	+53,7%	-0,2%	+0,5%	-0,2%
Logistic						
sans échantillonnage	0,586	0,805	0,399	0,512	0,603	0,611
best (10%)	0,589	0,812	0,404	0,516	0,602	0,613
Gain	+0,5%	+0,9%	+1,3%	+0,8%	+0,3%	+0,8%

TAB. 9 – Impact comparatif du sous-échantillonnage (20×20 Q Walk-Forward)

5 Discussion

5.1 Implications méthodologiques et architecture proposée

La validation révèle un effet méthodologique cohérent sur l’ensemble des tâches et architectures. En régression comme en classification, le split aléatoire surestime systématiquement les performances par fuite d’information temporelle. LSTM subit une dégradation de -15,8% en régression et -9,2% en classification lors du passage au walk-forward. RF montre un pattern similaire en classification (-9,6%). Cependant, l’observation la plus significative concerne Logistic Regression : contrairement aux architectures complexes, elle démontre une certaine stabilité temporelle avec une dégradation minimale en classification. Cela s’explique par l’absence de capacité de mémorisation excessive et la régularisation L2 qui pénalise uniformément tous les coefficients.

Approche duale multi-échelle pour la prédiction adaptative de la piraterie maritime

De plus, les résultats montrent une sensibilité différente entre architectures face au déséquilibre de classes. LSTM nécessite un sous-échantillonnage agressif (conservation d'unique-ment 25% de la classe Stable) pour améliorer la détection d'Émergence de +53,7%. Sa mémoire récurrente accumule les biais vers les classes fréquentes, créant une dépendance aux transitions majoritaires. À l'inverse, Logistic Regression démontre une robustesse naturelle importante aux déséquilibres des classes.

Basée sur les résultats walk-forward validés, nous proposons une architecture à trois niveaux (c.f. Tableau 10). Cette architecture exploite les forces complémentaires : Ridge pour la prédiction quantitative robuste, LSTM (avec rééquilibrage) pour la détection des transitions rares, Logistic pour la validation et l'interprétabilité.

Niv.	Objectif	Modèle (Performance)	Avantages
1	Stratégique	Ridge 5x5 Q ($R^2=0,753$)	Planification budgétaire
2	Monitoring	LSTM 20x20 Q 25% ($F1=0,609$)	Détection Émergence (+53,7%)
3	Validation	Logistic 20x20 Q ($F1-Intens=0,512$)	Robustesse et interprétabilité

TAB. 10 – Architecture à trois niveaux pour l'analyse de la piraterie maritime

5.2 Limites et perspectives

Notre approche présente plusieurs limitations importantes. Premièrement, l'hypothèse de stationnarité locale suppose la persistance des actions récentes, mais elle est vulnérable aux ruptures géopolitiques soudaines (déploiements militaires, coups d'État). Deuxièmement, l'absence de variables externes comme le prix du pétrole ou les indices de fragilité étatique limite notre capacité à anticiper les changements structurels.

Une contrainte fondamentale réside dans la rareté intrinsèque des données : avec seulement 15 947 incidents sur 46 ans à l'échelle mondiale, nous sommes contraints à des résolutions spatiales relativement grossières (1000-4000 km par cellule) pour maintenir un signal exploitable. Des tests empiriques sur des maillages plus fins (30x30, 40x40, 50x50) ont confirmé cette limitation avec des performances dégradées ($R^2 < 0,5$, $F1\text{-macro} < 0,4$) et plus de 95% de cellules vides. Cette limitation empêche l'analyse à des échelles véritablement locales (dizaines de kilomètres) qui seraient pertinentes pour des décisions tactiques immédiates, mais reste adaptée aux besoins stratégiques et de planification régionale.

Pour gérer ces limitations de granularité spatiale et permettre une transition vers des applications tactiques, plusieurs pistes sont envisageables. La première est une approche hiérarchique descendante où les prédictions macro (5x5) pourraient servir de contraintes pour une désagrégation spatiale fine. En s'inspirant des travaux de Berrocal et al. (2010) sur le downscaling statistique, nos prédictions grossières pourraient être utilisées comme distributions a priori, affinées localement par des covariables haute résolution (densité du trafic AIS, distance aux ports, conditions météorologiques). Cette approche permettrait de maintenir la cohérence avec les prédictions stratégiques tout en offrant une résolution tactique. La deuxième piste est de faire un zoom adaptatif sur zones critiques. Pour les cellules identifiées comme "émergentes" ou "intensifiées", une analyse locale à résolution plus fine (50-100 km) pourrait être faite. Bien que l'incertitude augmente à cette échelle, les informations obtenues pourraient guider le déploiement tactique des ressources.

Concernant les autres perspectives de recherche, l'intégration multi-modale de données AIS, des données sur l'incident (type de navire, activité du navire, informations sur les attaquants) et géopolitiques enrichirait le contexte décisionnel. L'exploration de techniques de rééquilibrage de classes (SMOTE, génération synthétique par GAN) pourrait améliorer davantage la détection des transitions rares Yang et al. (2024). La méthode SHAP (SHapley Additive exPlanations) Lundberg et Lee (2017) permettrait d'expliquer l'impact des variables d'entrée et d'éclairer les mécanismes sous-jacents des prédictions. Enfin, l'extensibilité à d'autres enjeux sécuritaires (trafic de drogue, pêche illégale) validerait la généralité de l'approche duale.

6 Conclusion

Cette recherche propose une approche duale innovante pour la prédiction spatio-temporelle de la piraterie, combinant prédiction quantitative grossière et classification qualitative plus fine.

Nous avons observé l'effet de surajustement temporel des LSTM en validation walk-forward pour la régression et constaté de meilleurs résultats pour les modèles linéaires (Ridge, Logistic) dans des conditions de validation rigoureuses. L'analyse du déséquilibre de classes révèle que le sous-échantillonnage améliore les performances de LSTM en classification, avec des gains importants sur les transitions minoritaires, tout en maintenant la complémentarité avec Logistic pour une couverture optimale. Les résultats de cet article valident une approche duale exploitant les complémentarités entre résolutions spatiales : Ridge sur maillage 5×5 pour l'allocation stratégique océanique, LSTM (avec sous-échantillonnage à 25% de la classe stable) sur maillage 20×20 pour le monitoring régional des transitions, complété par Logistic (sans sous-échantillonnage) pour la validation spécialisée sur les classe Intensification et Déclin.

L'approche duale multi-résolution, validée sur 15947 incidents de 1978 à 2024, ouvre la voie à une surveillance maritime adaptative répondant simultanément aux besoins macro-décisionnels et méso-opérationnels. Les perspectives incluent l'intégration de données multi-modales, l'exploration de techniques de rééquilibrage alternatives (SMOTE, GAN) ou encore l'extension à d'autres domaines de la sécurité maritime.

Références

- Benden, P., A. Feng, C. Howell, et G. V. Dalla Riva (2021). Crime at sea : A global database of maritime pirate attacks (1993–2020). *Journal of Open Humanities Data*.
- Bergmeir, C. et J. M. Benítez (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences* 191, 192–213.
- Berrocal, V. J., A. E. Gelfand, et D. M. Holland (2010). A spatio-temporal downscaler for output from numerical models. *Journal of Agricultural, Biological, and Environmental Statistics* 15, 176–197.
- Bowden, A., K. Hurlburt, E. Aloyo, C. Marts, et A. Lee (2010). The economic cost of maritime piracy. Technical report, One Earth Future Foundation, Broomfield, CO. Working Paper.
- Cerqueira, V., L. Torgo, et I. Mozetic (2019). Evaluating time series forecasting models : An empirical study on performance estimation methods. *CoRR abs/1905.11744*.

- Li, H. et Z. Yang (2023). Towards safe navigation environment : The imminent role of spatio-temporal pattern mining in maritime piracy incidents analysis. *Reliability Engineering & System Safety* 238, 109422.
- Lundberg, S. M. et S.-I. Lee (2017). A unified approach to interpreting model predictions. In *Advances in neural information processing systems*, Volume 30.
- Marchione, E. et S. D. Johnson (2013). Spatial, temporal and spatio-temporal patterns of maritime piracy. *Journal of Research in Crime and Delinquency* 50(4), 504–524.
- Merino Laso, P. et L. Salmon (2025). Maritime piracy bibliometric analysis : A literature overview and map review. *The Journal of Navigation*, 1–18.
- Qin, Z., B. Wei, et C. Gao (2025). Innovative lsgtime model for crime spatiotemporal prediction based on mindspore framework.
- Salmon, L. et P. Merino Laso (2024). Analyse de données de piraterie en mer pour l'observation des zones maritimes à risque. *Gestion et Analyse de données Spatio-Temporelles (GAST)*, 1–4.
- Shortland, A. et M. Vothknecht (2011). Treasure mapped : Using satellite imagery to track the developmental effects of somali piracy. *Journal of Peace Research* 48(6), 771–781.
- Talpur, K., R. Hasan, I. Gocer, S. Ahmad, et Z. Bhuiyan (2025). Ai in maritime security : Applications, challenges, future directions, and key data sources. *Information* 16(8), 658.
- Yang, Y., H. A. Khorshidi, et U. Aickelin (2024). A review on over-sampling techniques in classification of multi-class imbalanced datasets : insights for medical problems. *Frontiers in Digital Health Volume 6 - 2024*.
- Zhou, Y., J. Li, et M. Chen (2023). Discovering maritime-piracy hotspots : A study based on ahp and spatio-temporal clustering. *Annals of Operations Research* 328(1), 345–367.

Summary

Scientific literature on spatio-temporal data primarily focuses on predicting trajectories of moving objects or observing events over fixed geographical areas. Few studies address the predictive analysis of dynamic variations of spatial areas themselves over time. This research proposes a dual methodology to model the evolution of maritime piracy (~350 incidents/year globally): (1) quantitative prediction at macroscopic resolution (~4000 km/cell) for strategic resource allocation, and (2) qualitative classification at mesoscopic resolution (~1000 km/cell) to detect regional spatial transitions. Evaluation on 15,947 incidents (1978-2024) reveals that standard validation systematically overestimates complex models, particularly in regression where LSTM is significantly less effective in walk-forward validation. In classification, all models deteriorate in walk-forward validation, but Logistic Regression demonstrates robustness with degradation lower than complex architectures, becoming the best model under strict temporal validation. The proposed hybrid architecture (Ridge for regression and LSTM+Logistic for classification) offers temporal robustness for operational monitoring.