

L'intelligence artificielle pour suivre les macro-déchets en rivière, une solution généralisable ?

Les flux de déchets flottants en rivière : quel constat ?

D'après une étude scientifique récente, près de 1000 rivières sont à l'origine de 80 % des émissions de déchets plastiques vers les milieux marins, soit un flux estimé entre 0,8 et 2,7 millions de tonnes par an (Meijer et al., 2021). Récemment, une équipe allemande a mesuré sur le Rhin à proximité de Coblenz un flux annuel de macro-déchets proche de 4 000 tonnes dont 70 % correspondent à des déchets plastiques (Gnann et al., 2026). Une étude fine de ces flux est nécessaire afin d'appréhender et de remédier à ce phénomène de pollution dans les hydrosystèmes. En effet sous l'effet des dégradations mécaniques et physico-chimiques, ces macro-déchets se fragmentent continuellement en microplastiques, disséminant une pollution durable dans l'ensemble des compartiments environnementaux.

Les études sur les macro-déchets (déchets supérieurs à 5 cm tels que les bouteilles ou sacs) sont majoritairement menées sur les grandes rivières et fleuves mais peu de données quantitatives portent sur les rivières de petite et moyenne taille. Or, une compréhension fine de l'origine de ces déchets et de leur dynamique de transport est indispensable pour optimiser les stratégies de gestion. C'est pourquoi les équipes de recherche mènent des suivis de terrain (comptage visuel depuis un pont, relevés par drone, etc.). L'objectif est de collecter des données indispensables aux modèles d'estimation de la pollution fluviale, des outils clés pour déployer des stratégies de dépollution efficaces (Hurley et al., 2023). Cependant ces suivis sont essentiellement réalisés en conditions diurnes témoignant de la nécessité de développer des méthodes de suivis adaptées pour les conditions nocturnes afin d'estimer avec une bonne fiabilité les flux journaliers.

Les méthodes de suivi actuelles présentent en effet des lacunes pour étudier avec précision la variabilité annuelle des

flux de macro-déchets anthropiques. Le transit de ces débris ne se fait pas de manière linéaire avec le débit mais de façon sporadique (van Emmerik et al., 2023). Il est impératif de tenir compte des périodes de dépôt de déchets anthropiques sur les berges et les formes fluviales émergées lors d'activités récréatives pratiquées au printemps et en été, qui peuvent fortement augmenter les flux de flottants lors des premières crues automnales. Une approche de suivi diurne et nocturne pourrait alors intégrer cette hétérogénéité des dynamiques aux analyses permettant de mettre en évidence d'éventuels phénomènes d'hystérésis à l'échelle annuelle.

Utilisation de l'intelligence artificielle pour quantifier les flux de macro-déchets sur nos rivières

L'intelligence artificielle (IA) est en plein essor dans les sciences de l'environnement pour étudier les dynamiques spatio-temporelles des socio-systèmes. Cette démocratisation s'explique en partie par des capacités de calcul en constante augmentation, ainsi que par l'accès à des jeux de données de plus en plus complets et volumineux pour entraîner des modèles. Cet outil offre l'avantage de réaliser des traitements automatiques de tâches chronophages.

De premières études ont montré qu'il était possible de détecter automatiquement, avec une bonne fiabilité, les macro-déchets flottants à partir de vidéos prises par caméra ou drone depuis un point d'observation unique, et ce, sur une durée d'enregistrement très courte (van Lieshout et al., 2020). Toutefois, ces modèles ne sont pas généralisables à d'autres cours d'eau. L'objectif est de proposer une nouvelle méthode de suivi sur le terrain, avec la mise en place d'un premier réseau de caméras sur le Steingiesen, afin de surveiller les flux de déchets flottants de jour comme de nuit, et d'évaluer si des modèles entraînés sur le Steingiesen peuvent être utilisés sur la Bruche.






Figure 1 : Localisation des sites d'études sur la rivière du Steinglessen et de la Bruche (Eurométropole de Strasbourg, France)

Apprentissage profond pour l'analyse in situ des déchets flottants en rivière

Des caméras pour observer la rivière en continu

Pour surveiller les déchets flottants de manière automatique et continue, deux caméras ont été installées sur les berges du Steinglessen, l'une à l'entrée du cours d'eau et l'autre à sa sortie (Fig.1). Ces caméras, fixées sur les berges offrent un angle de vue oblique. Si cette configuration est plus proche de la réalité d'un déploiement terrain à long terme, elle est aussi plus exigeante pour les algorithmes de détection, car la perspective déforme les objets et les effets de reflet sur l'eau multiplient les fausses détections visuelles des modèles.

Dès lors, un protocole a été mis en place : plusieurs types de déchets anthropiques (bouteilles en verre, sacs et bouteilles plastiques, polystyrène) ainsi que des débris naturels (bois) ont été introduits manuellement dans le cours d'eau en amont de chaque caméra. Des passages en kayak ont également été enregistrés pour constituer des exemples d'objets non-déchet. Afin de ne laisser aucune trace dans le milieu naturel protégé, l'ensemble des objets introduits a été récupéré à l'aval par un équipier en kayak.

Ce protocole a permis de constituer un jeu de données de référence de 6013 images

annotées manuellement, sous différentes conditions d'ensoleillement.

Prévenir la fuite de données : une étape clé souvent négligée

La première étape pour entraîner un modèle d'IA est de mettre en forme le jeu de données sur lequel le modèle va apprendre à détecter des déchets. Ce jeu de données se décompose en trois groupes: le jeu d'entraînement, le jeu de validation et le jeu de test. Toutefois, lors de la répartition de la donnée dans ces derniers, un piège réside dans le découpage purement aléatoire des images, qui risque de répartir des données redondantes entre ces différents groupes. En pratique, si deux images quasi identiques d'une même bouteille en plastique se retrouvent l'une dans le jeu d'entraînement et l'autre dans celui de test, le modèle obtiendra d'excellents scores simplement par mémorisation,

sans démontrer une réelle capacité de généralisation à des données inédites. Ce phénomène, qualifié de fuite de données, conduit à une surestimation des performances du modèle et donc constitue un problème lorsque nous voulons déployer le modèle d'IA sur plusieurs rivière.

Pour y remédier, une méthode en trois étapes a été développée :

- Attribuer une identité numérique : chaque image reçoit une signature numérique résumant son contenu visuel, l'heure de la prise de vue et la présence d'éventuels déchets.
- Mesurer la ressemblance : un premier algorithme place ces images sur un plan en deux dimensions. Deux photos prises à quelques secondes d'intervalle, et celles avec de grande similitude visuelle se retrouvent à proximité.



Figure 2 : Méthodologie employée

c. Former des groupes d'images : toujours dans le plan à deux dimensions, un second algorithme détecte la proximité de ces images et les rassemble en petits groupes d'images similaires.

Cela permet donc aux modèles de s'entraîner sur un groupe de données similaires puis de se valider et se tester sur des images différentes. Cette approche a permis de construire un jeu de données sans fuite, plus représentatif des conditions réelles.

Prévenir la fuite de données : une étape clé souvent négligée

Pour détecter des objets dans les images, il existe plusieurs familles de modèle d'IA. Pour cette étude, la famille d'algorithmes YOLO (You Only Look Once) a été privilégiée pour leurs rapidité de détection en temps réel sur des vidéos. Trois générations ont été comparées (YOLOv5, YOLOv8, YOLOv11) chacune déclinée en version légère (nano – économe en puissance de calcul) et intermédiaire (medium – plus lourde en puissance de calcul mais plus précise).

Ces modèles ne sont pas entraînés de zéro : ils s'appuient sur un apprentissage par transfert ce qui permet d'accélérer leur entraînement. Ces modèles ont été pré-entraînés sur le jeu de données COCO (comprenant des milliers d'objets du quotidien), puis affinés sur les images du Steingiessen. Cette stratégie est particulièrement bien adaptée dans le cas d'un jeu de données de terrain limité.

Au total, dix scénarios d'entraînement ont été comparés, en faisant varier :

- le type de découpage du jeu de données (aléatoire vs. sans fuite temporelle)
- la proportion d'images « négatives » (images sans aucun déchet) ajoutées à l'entraînement (de 0 % à 40 %) pour apprendre au modèle de ne pas donner de fausses alertes de détection.

Principaux résultats : performances de détection

Les performances sont évaluées à l'aide de métriques standard en détection d'objets :

- la précision (parmi les objets détectés, quelle proportion est correcte ?)
- le rappel (parmi tous les objets présents, quelle proportion est détectée ?)
- le mAP@50 (mean Average Precision à un seuil de recouvrement de 50 %), synthèse des deux métriques précédentes

Les résultats mettent en évidence l'impact critique du protocole de division des données sur l'évaluation des performances. Un découpage aléatoire conduit à des métriques artificiellement élevées (Tab.1), traduisant un phénomène de fuite temporelle par lequel le modèle

mémorise des scènes déjà rencontrées plutôt qu'il n'apprend à généraliser. Après correction de ce biais, les performances chutent significativement, révélant les capacités réelles des modèles dans des conditions proches du déploiement terrain.

La configuration la plus performante (YOLOv11-m entraîné avec 20 % d'images négatives sur un jeu de données sans fuite) atteint un mAP@50 de 0,648 et un rappel de 0,630 (Tab.1). L'ajout d'images sans aucun déchet s'avère bénéfique jusqu'à ce seuil de 20 % : au-delà, le modèle devient trop restrictif et le rappel se dégrade. Ces résultats, bien que plus modestes que ceux issus d'un découpage aléatoire, constituent une estimation fiable des performances attendues en conditions réelles : s'ils permettent d'ores et déjà d'avoir un aperçu relatif des flux réels, ils soulignent également la nécessité de poursuivre l'optimisation des modèles.

Configuration	Précision	Rappel	mAP@50
YOLOv8-n – découpage aléatoire	0,970	0,888	0,939
YOLOv11-m – découpage aléatoire	0,955	0,937	0,962
YOLOv8-n – sans fuite de données	0,551	0,508	0,488
YOLOv11-m – sans fuite de données	0,491	0,529	0,536
YOLOv8-n – sans fuite de données + 20% d'image négative	0,704	0,582	0,618
YOLOv11-m – sans fuite de données + 20% d'image négative	0,704	0,630	0,648

Tableau 1 : Performances comparées des principales configurations de modèles YOLO sur le Steingiessen

Aller plus loin : estimer la taille des déchets depuis une image

Au-delà de la détection, l'étude propose une méthode pour estimer les dimensions physiques des déchets (largeur et longueur) à partir des seules images de la caméra.

Le principe repose sur la géométrie projective : en connaissant précisément les paramètres de la caméra (focale, distorsion) et sa position dans l'espace

(hauteur, orientation), il est possible de convertir les coordonnées pixels de la boîte englobante prédite par YOLO en dimensions métriques réelles sur le plan d'eau, exprimées en centimètres.

Les imprécisions inhérentes aux boîtes englobantes automatiques sont corrigées par un ajustement statistique permettant d'affiner l'estimation des dimensions réelles des objets. Testée sur 20 objets aux dimensions connues, la méthode atteint une erreur moyenne de 2,03 cm en largeur et de 1,45 cm en hauteur, des valeurs qui



Figure 3 : Exemples de détections des modèles YOLOs sur les rivières de la Bruche et du Steingiessen



témoignent d'une bonne précision géométrique du modèle pour l'estimation des dimensions des déchets flottants. Cette métrique permettrait aux collectivités de calibrer au mieux les infrastructures de collecte et d'anticiper les volumes à traiter.


Vers une généralisation sur la Bruche et un observatoire des flux de déchets flottants en rivière à l'échelle du Bas-Rhin

Un des enjeux majeurs de cette étude est d'évaluer si un modèle entraîné sur le Steingiesen peut être appliqué directement sur un cours d'eau différent (ici la Bruche) sans ré-entraînement. Au travers des différents scénarios d'entraînement (Tab.1) réalisés nous avons tenté de mettre en évidence un modèle adapté à la situation. Cette capacité de généralisation est cruciale pour envisager un déploiement à grande échelle sans avoir à collecter et annoter des images sur chaque site.

Les premières applications du modèle YOLOv11-m sur des images de la Bruche

montrent des résultats encourageants pour les déchets anthropiques les plus courants (Fig.3) tout en confirmant la difficulté attendue pour les classes rares (débris naturels) et les conditions d'éclairage différentes. Ces résultats soulignent la nécessité de diversifier les données d'entraînement pour améliorer la robustesse des modèles face à la variabilité des sites.

Cette étude ouvre de nouvelles perspectives quant à la généralisation de modèles d'apprentissage profond pour détecter automatiquement, en temps réel et en continu, tout objet flottant en rivière. Dans cette optique, de nouvelles stations autonomes, à bas coût (~600€) et dotées d'une IA embarquée sont d'ores et déjà en cours de développement et d'expérimentation sur le terrain. Ces dispositifs offrent une capacité de mise à l'échelle de l'observatoire, ouvrant la voie à l'extension de l'étude des flux de déchets à d'autres rivières du Bas-Rhin (Ill, Fecht, Moder, etc.). Le déploiement d'un tel observatoire ouvre alors la possibilité de saisir la variabilité des flux de débris anthropiques, d'orienter des actions de nettoyage et donc de cibler les tronçons de rivière les plus concernés par cette pollution. Ces stations autonomes, les "ROV-E", feront l'objet d'un prochain In Situ.



Conception graphique : Zone Atelier
Environnementale Urbaine, ZAEU,
Céline Merlaud - Oxo Mini Agence

Acronymes

EMS (acronyme) : Eurométropole de Strasbourg.

IA (acronyme) : ensemble des théories et des techniques développant des programmes informatiques complexes capables de simuler certains traits de l'intelligence humaine.

ROV-E (acronyme) : River Observation & Vision Equipment

Publications associée

Gnann, N., Höreth, K., Schweigert, N., Evers, M., Ternes, T. A., & Hamann, L. (2026). The river Rhine transports around 4,000 tonnes of macrolitter towards the North Sea each year. *Communications Sustainability*, 1(1), 5.

Hurley, R., Braaten, H. F. V., Nizzetto, L., Steindal, E. H., Lin, Y., Clayer, F., ... & Olsen, M. (2023). Measuring riverine macroplastic: Methods, harmonisation, and quality control. *Water Research*, 235, 119902.

Meijer, L. J., Van Emmerik, T., Van Der Ent, R., Schmidt, C., & Lebreton, L. (2021). More than 1000 rivers account for 80% of global riverine plastic emissions into the ocean. *Science advances*, 7(18), eaaz5803.

van Emmerik, T. H., Frings, R. M., Schreyers, L. J., Hauk, R., de Lange, S. I., & Mellink, Y. A. (2023). River plastic transport and deposition amplified by extreme flood. *Nature Water*, 1(6), 514-522.

van Lieshout, C., van Oeveren, K., van Emmerik, T., Postma, E., 2020. Automated river plastic monitoring using deep learning and cameras. *Earth and space science* 7, e2019EA000960.

Auteurs et contacts

Gauthier Grimmer, UMR LIVE 7362 CNRS / Faculté de géographie de Strasbourg (g.grimmer@unistra.fr)

Romain Wenger, CESBIO-CNRS/CNRS/INRAE/IRD / Université de Toulouse (romain.wenger@utoulouse.fr)

Valentin Chardon, UMR LIVE 7362 CNRS / Faculté de géographie de Strasbourg (valentin.chardon@live-cnrs.unistra.fr)