

# INTELLIGENCE ARTIFICIELLE



POUR QUANTIFIER LES DÉCHETS EN RIVIÈRE :  
DE L'INNOVATION TECHNOLOGIQUE  
À L'ENGAGEMENT SUR LE TERRAIN

---



avec le soutien de :



## A PROPOS DE SURFRIDER FOUNDATION

Surfrider Foundation est une association à but non lucratif, chargée de la protection et de la mise en valeur des lacs, des rivières, de l'océan, des vagues et du littoral. Elle regroupe à ce jour plus de 18 000 adhérents et intervient sur 12 pays via ses antennes bénévoles. L'ONG intervient sur 3 domaines spécifiques sur lesquels l'organisation a acquis une expertise reconnue depuis plus de 30 ans : les déchets aquatiques, la qualité de l'eau et la santé des usagers, l'aménagement du littoral et le changement climatique.

Pour en savoir plus : [surfrider.fr](https://surfrider.fr)

## CONTRIBUTIONS ET REMERCIEMENTS

→ Surfrider Foundation : Sabine Allou

→ Naia Science : Charles Ollion et Clément Leroux

→ Bénévoles de compétences : Antoine Girard et Maxime Lazennec

## REMERCIEMENTS

Ce projet a été rendu possible grâce à la contribution inestimable de nombreux bénévoles et équipes passionnées. Un grand merci à l'École IA Microsoft pour leur accompagnement via *ShareAI*, aux organisations l'École de l'IA, Naia Science, Heuritech, Neoxia, Metsys, Data4Good, Archi-volt pour leur mécénat de compétence, aux freelances pour leur expertise et leur flexibilité ainsi que tous les partenaires financiers qui ont soutenu le projet *Plastic Origins*. Nous sommes également très reconnaissants envers les bénévoles qui ont généreusement donné de leur temps et de leurs compétences. Enfin, merci aux chefs de projets et membres de l'équipe *Expertise Environnementale* de Surfrider Foundation, pour avoir mené à bien ce projet ambitieux.

## PHOTOGRAPHIES

Surfrider Foundation

## ILLUSTRATIONS ET MISE EN PAGE

→ [kanardo.com](https://kanardo.com)

## CONTACT

Sabine Allou, cheffe de projet Plastic Origins pour Surfrider Foundation  
[plasticorigins@surfrider.eu](mailto:plasticorigins@surfrider.eu)

## PROJET EN OPEN SOURCE

<https://github.com/surfriderfoundationeurope/surfnet>

---

*Photo de couverture* | Signalement de déchets échoués sur les berges de rivières grâce à l'application *Plastic Origins*, © Surfrider Foundation.

# TABLE DES MATIÈRES

---

|   |           |
|---|-----------|
| <b>RÉSUMÉ</b>   | <b>5</b>  |
| <b>DÉFINITION DES TERMES ET ACRONYMES</b>   | <b>8</b>  |
| <b>1. INTRODUCTION</b>  | <b>11</b> |
| <b>2. LE PROJET PLASTIC ORIGINS</b>   | <b>13</b> |
| <b>3. L'INTELLIGENCE ARTIFICIELLE AU CŒUR DU PROJET</b>   | <b>15</b> |
| 3.1. L'IA pour un outil de mesure quantitatif et standardisé  | 15        |
| 3.2. Une IA miniature dans le grand monde des IA  | 17        |
| <b>4. SURFNET: L'IA DE SURFRIDER</b>  | <b>19</b> |
| 4.1. Son cadre d'utilisation  | 19        |
| 4.2. Les choix technologiques   | 21        |
| 4.3. Son jeu de données d'entraînement inédit   | 22        |
| 4.4. Les différentes catégories de déchets à détecter   | 24        |
| 4.5. Des approches multiples pour améliorer le jeu de données   | 25        |
| 4.6. Les métriques et les résultats des détections sur images fixes   | 28        |
| 4.7. Le suivi des déchets dans une vidéo  | 30        |
| <b>5. DISCUSSIONS</b>   | <b>32</b> |
| 5.1. Sciences participatives et intelligence artificielle :<br>un duo complémentaire sur le terrain ?         | 32        |
| 5.2. Quels sont les bénéfices et les enjeux de l'intégration de l'IA sur nos<br>téléphones portables ?        | 33        |
| 5.3. Les développements de Surfnet permettent-ils de réaliser des diagnostics de<br>la pollution en rivière ? | 35        |
| 5.4. Comment mesurer l'impact environnemental de l'IA Surfnet par rapport à sa<br>mission écologique ?        | 35        |
| <b>6. PERSPECTIVES ET RECOMMANDATIONS</b>   | <b>38</b> |
| <b>7. BIBLIOGRAPHIE</b>   | <b>39</b> |
| <b>8. ANNEXES</b>   | <b>40</b> |
| Annexe 1 : Exemple d'images selon les différentes catégories du jeu de données                                | 40        |

# TABLE DES FIGURES

---

|  |    |
|--|----|
| <b>FIGURE 1</b> Prise de vue d'un déchet plastique échoué en rivière   | 7  |
| <b>FIGURE 2</b> Page de gauche   Bouteilles plastiques piégées dans la végétation rivulaire  | 11 |
| <b>FIGURE 3</b> Table de tri des déchets collectés par le projet Riverine Input  | 12 |
| <b>FIGURE 4</b> Collecte de déchets en kayak   | 13 |
| <b>FIGURE 5</b> Schéma simplifié de la plateforme numérique Plastic Origins  | 13 |
| <b>FIGURE 6</b> Utilisation de l'application Plastic Origins lors d'une sortie en kayak  | 15 |
| <b>FIGURE 7</b> Sections de rivière étudiées sur le Gave d'Oloron (64)   | 16 |
| <b>FIGURE 8</b> Graphique de comparaison des comptages manuels de bénévoles sur le terrain et du comptage de l'IA par vidéo              | 16 |
| <b>FIGURE 9</b> Bénévole qui filme les déchets sur les berges depuis son kayak   | 18 |
| <b>FIGURE 10</b> Utilisateur en train de photographier un déchet échoué  | 19 |
| <b>FIGURE 11</b> Vue du guide visuel sur l'application Plastic Origins   | 20 |
| <b>FIGURE 12</b> Bénévoles qui filment les déchets sur les berges depuis leur kayak  | 20 |
| <b>FIGURE 13</b> Schéma comparant la vision par ordinateur / IA à la vision humaine  | 21 |
| <b>FIGURE 14</b> Comparaison entre la détection d'objets et la segmentation  | 21 |
| <b>FIGURE 15</b> Schéma des phases d'entraînement et d'inférence d'une IA  | 22 |
| <b>FIGURE 16</b> Diversité d'images de déchets en rivière  | 23 |
| <b>FIGURE 17</b> Vue de la plateforme de labellisation Trashroulette   | 24 |
| <b>FIGURE 18</b> Les 10 catégories de déchets utilisées pour entraîner Surfnet   | 25 |
| <b>FIGURE 19</b> Répartition du nombre de comptages par catégorie  | 25 |
| <b>FIGURE 20</b> Multiples images issues de l'augmentation de données  | 26 |
| <b>FIGURE 21</b> Image issue de la génération de données   | 27 |
| <b>FIGURE 22</b> Résultats obtenus sur yolov8-s après plusieurs itérations   | 28 |
| <b>FIGURE 23</b> Exemple d'image avec erreur : le plus gros morceau de plastique est détecté mais le petit à sa gauche ne l'est pas      | 29 |
| <b>FIGURE 24</b> Méthode de tracking sur des images successives  | 30 |
| <b>FIGURE 25</b> Déchet flottant juste sous la surface de l'eau  | 31 |
| <b>FIGURE 26</b> Comparaison des comptages de l'IA à ceux d'une personne qui visionne la même vidéo sur 3 tronçons de rivière différents | 31 |
| <b>FIGURE 26</b> Tri et quantification de déchets après une collecte   | 32 |
| <b>FIGURE 27</b> Tutoriel pour embarquer les utilisateurs de l'application prototype   | 34 |
| <b>FIGURE 28</b> Ecran principal de détection en temps réel des déchets en rivière via l'application prototype                           | 34 |
| <b>FIGURE 29</b> Pop-up de fin d'enregistrement via l'application prototype  | 34 |
| <b>FIGURE 30</b> Cartographie de chaleur des déchets signalés via l'application Plastic Origins  | 36 |
| <b>FIGURE 31</b> Zoom sur le secteur de Sorde-l'Abbaye (40) qui montre la répartition des déchets le long du cours d'eau                 | 36 |
| <b>FIGURE 32</b> Déchets échoués sur les berges d'un cours d'eau   | 37 |



# RÉSUMÉ

---

**Ce livre blanc présente le projet Plastic Origins de Surfrider Foundation, qui a expérimenté l'intelligence artificielle pour cartographier et quantifier la pollution plastique dans les rivières européennes. L'objectif est de permettre aux citoyens de contribuer à la collecte de données en filmant les berges lors de sorties en kayak via une application mobile.**

L'IA développée, nommée Surfnet, analyse ces vidéos pour détecter les macrodéchets, en combinant technologies de vision par ordinateur et tracking vidéo. L'IA permet une collecte plus standard et à plus grande échelle que les méthodes manuelles, souvent sujettes à des erreurs d'observation. Un jeu de données d'entraînement de 5 000 images labellisées a été constitué grâce aux contributions de bénévoles et des techniques comme l'augmentation de données ont été employées pour améliorer les performances. Le projet met également en avant une démarche frugale en utilisant des technologies TinyML, visant à minimiser les coûts monétaires et environnementaux de l'IA, ou en diminuant les opérations hébergées sur le cloud par le développement de l'IA mobile.

Bien que le projet sensibilise efficacement le grand public et les décideurs aux enjeux de la pollution plastique, des défis persistent, tant sur le terrain que sur le plan technologique pour en faire un véritable outil de diagnostic.

---

*Figure 1 | Page de gauche | Prise de vue d'un déchet plastique échoué en rivière, © Surfrider Foundation.*

# DÉFINITION DES TERMES ET ACRONYMES

---

**AFNOR** Association Française de Normalisation.  
Organisme chargé d'élaborer et de diffuser des normes en France.

**AZURE**  
Plateforme de cloud développée par Microsoft, offrant une large gamme de services (stockage, calcul, bases de données...).

**CNN** Convolutional Neural Network.  
Type de réseau de neurones artificiels particulièrement adapté aux tâches de vision par ordinateur, comme la reconnaissance d'objets dans des images.

**COMPUTER VISION**  
Domaine de l'intelligence artificielle qui vise à permettre aux ordinateurs de comprendre et d'interpréter des images et des vidéos.

**DATA.GOUV**  
Plateforme française qui met à disposition des données publiques ouvertes

**DCSMM**  
La Directive Cadre Stratégie pour le Milieu Marin est une législation européenne fondamentale visant à protéger et à conserver les milieux marins.

**DEEP LEARNING**  
Sous-domaine de l'apprentissage automatique qui utilise des réseaux de neurones artificiels à plusieurs couches pour apprendre des représentations complexes de données.

**ENTRAÎNEMENT**  
L'entraînement d'un modèle d'IA consiste à l'alimenter avec de grandes quantités de données pour lui permettre d'apprendre à reconnaître des patterns.

**ETL** Extract, Transform, Load.  
Processus informatique consistant à extraire, transformer et charger des données.

**FICHIERS CSV** Comma-Separated Values.  
Format de fichier texte simple permettant de stocker des données tabulaires.

**FINE-TUNING**  
L'ajustement fin d'un modèle pré-entraîné pour l'adapter à une tâche spécifique, optimisant ainsi ses performances sans nécessiter un nouvel entraînement complet.

## **INFÉRENCE**

L'inférence correspond à l'utilisation du modèle entraîné pour faire des prédictions sur de nouvelles données.

**LLM** Large Language Model.

Grand modèle de langage, un type d'intelligence artificielle capable de générer du texte, de traduire des langues, etc.

## **MACRODÉCHETS**

Les macrodéchets sont des déchets de grande taille (par comparaison aux micro-déchets), généralement supérieurs à 2,5 centimètres.

## **OSPAR**

Convention internationale visant à protéger le milieu marin de l'Atlantique du Nord-Est

## **POSTGRESQL**

Système de gestion de base de données relationnelle open source.

## **SERVEURS CPU ET GPU**

Une unité centrale de traitement (CPU) est un composant d'un serveur qui permet de gérer toutes les tâches informatiques nécessaires au fonctionnement du système d'exploitation et des applications. Une unité de traitement graphique (GPU) est un composant matériel similaire, mais plus optimisé, offrant des performances élevées pour des applications d'IA.

## **SURFNET**

Nom du modèle d'intelligence artificielle développé spécifiquement par Surfriider pour compter les déchets sur les berges de rivière à partir d'une vidéo.

## **SYSTÈMES D'EXPLOITATIONS IOS ET ANDROID**

Systèmes d'exploitation respectivement pour les appareils mobiles Apple et les smartphones et tablettes fonctionnant sous Android.

## **TINYML**

Sous-domaine de l'apprentissage automatique qui se concentre sur le développement de modèles d'IA suffisamment petits pour s'exécuter sur des appareils à faible puissance.

## **TRACKING**

Le tracking est le processus de localisation et de suivi d'objets en mouvement dans une séquence vidéo.

## **TRASHROULETTE**

Plateforme de labellisation en ligne pour annoter des images de déchets et constituer le jeu d'entraînement de Surfne.

## **ZONES D'ACCUMULATION**

Secteur d'un cours d'eau caractérisé par une concentration élevée de déchets, souvent dus à des ralentissements du courant, à la présence d'obstacles ou à des apports directs de déchets.



# 1 INTRODUCTION

**Chaque année, on estime que 20 millions de tonnes de déchets arrivent dans l'océan, dont 8 à 12 millions de déchets plastiques (Galgani 2016). Tous les écosystèmes marins et côtiers sont actuellement menacés par la pollution plastique qui touche non seulement les espèces (étrangement, ingestion...), les fonds marins (détérioration du plancher océanique) mais également les êtres humains (impacts sanitaires et socio-économiques). 80% de ces déchets plastiques proviendraient des activités à terre, transportés majoritairement par les rivières (GESAMP 1990). En traversant de nombreux terrains agricoles, industriels ou agglomérations urbaines, elles drainent de multiples éléments que l'on retrouvera ensuite en mer.**

Une fois introduits dans les rivières, le devenir des déchets plastiques est hautement variable, en fonction du type de plastique, de son degré de dégradation mais aussi des caractéristiques hydro-morphologiques des cours d'eau. Une partie de ces déchets transitera directement vers l'estuaire, alors que l'autre s'accumulera dans des zones de rétention. Les déchets sont ainsi piégés ou retenus temporairement, parfois pendant de longues périodes, par les berges et la végétation, avant d'être libérés lors de fortes précipitations ou d'inondations. Ces longs temps de séjour des déchets plastiques dans les rivières augmentent les effets négatifs sur les milieux aquatiques, telles que la formation de microplastiques par fragmentation.

De 2014 à 2018, le projet Riverine Input de Surfrider Foundation (Bruge 2018) a permis d'identifier avec précision la typologie et la quantité de déchets échoués sur les différents sites d'étude. Plusieurs méthodes ont été testées telles que la collecte et la caractérisation des déchets échoués sur les berges, le comptage des déchets flottants depuis les ponts, la mise en place de filets et de barrages flottants pour capter les déchets, ainsi que la géolocalisation des déchets basée sur des observations et comptages.

À la suite de ces différents tests, les protocoles de collecte de données sur les macrodéchets stockés sur les berges nous semblaient être une approche intéressante pour obtenir une vision de la pollution en rivière (Emmerik 2020). En effet, ces macrodéchets constituent une forme visible et tangible de pollution contrairement aux microplastiques ou aux déchets flottants, en suspension ou déposés au fond de l'eau. Ils offrent ainsi la possibilité de collecter des données concrètes sur la quantité et la composition des déchets présents dans ces milieux. Néanmoins, en 2019, il n'existait pas de protocole internationalement reconnu pour cadrer la mise en place d'activités de surveillance (González 2017).

C'est ainsi que nous avons cherché à développer un protocole novateur pour étudier le stock de plastiques sur les berges de rivières, intégrant trois principes fondamentaux. Tout d'abord, il est plus facile de détecter les déchets depuis l'eau, où la visibilité est améliorée, car l'observateur est au niveau des déchets et n'est pas gêné par la végétation. De plus, les déchets ne se stockent pas uniformément le long des cours d'eau, la couverture de grandes distances permet une meilleure compréhension de leur répartition. Enfin, ce protocole,

*Figure 2 | Page de gauche | Bouteilles plastiques piégées dans la végétation rivulaire, © Surfrider Foundation.*

conçu pour être simple et accessible, tire parti de l'omniprésence des smartphones de nos jours. L'application mobile associée à ce protocole facilite la collecte de données et encourage une participation citoyenne active.

Par ailleurs, l'intégration de l'intelligence artificielle (IA) pourrait encore renforcer ce protocole en facilitant l'acquisition de grandes quantités de données sur de longues distances. En utilisant des technologies d'IA, il serait possible d'automatiser la détection et la classification des déchets, ainsi que d'améliorer l'efficacité et la précision de la collecte et de l'analyse des données.

Est-il possible de créer une application utilisant l'intelligence artificielle pour faciliter et améliorer la précision de la collecte de données sur les déchets en rivière ?

Dans ce contexte, Surfrider a développé l'application mobile Plastic Origins (Lepâtre 2023). En collectant des données de manière dynamique le long des berges des rivières, ce protocole contribue à une vision globale de la pollution plastique sur des tronçons étendus. Elle vise ainsi à illustrer la pollution diffuse, que l'on ne peut quantifier précisément à cause de difficultés méthodologiques importantes.

Très concrètement, depuis leur téléphone, les utilisateurs ont la possibilité soit de signaler manuellement les déchets observés soit, d'enregistrer une vidéo de la berge qui sera traitée par un algorithme d'intelligence artificielle. L'intelligence artificielle permet de supprimer le « biais observateur ». Chaque utilisateur apporte une erreur qui lui est

propre (en fonction de son expérience, ses connaissances, ses capacités, son état de fatigue...). L'intérêt de faire de la détection et non de l'observation est de remplacer cette erreur variable (celle des observateurs) par une erreur constante et connue (celle de l'algorithme de détection), pour pouvoir notamment comparer les données entre elles. L'IA permet ainsi de générer des données fiables et robustes à travers un projet de science participative.

Les outils informatiques (sites internet, bases de données, intelligence artificielle, etc.) utilisés dans le cadre du projet Plastic Origins ont été majoritairement développés par des bénévoles. Cela a permis de réduire drastiquement le coût du projet. Sans leur aide précieuse, ce projet n'aurait pu voir le jour. Ainsi, la diffusion de nos résultats permet non seulement de partager notre savoir-faire technologique, mais aussi de reconnaître et de valoriser le travail des bénévoles qui ont rendu cela possible.

L'objectif de ce livre blanc est de diffuser les développements technologiques dans le domaine de l'intelligence artificielle réalisés au sein de Surfrider. À travers ces pages, nous visons à offrir une compréhension transparente des technologies employées, de leur fonctionnement, des hypothèses et choix stratégiques qui les sous-tendent, ainsi que du cadre d'utilisation et des limites associées. Nous examinerons également les résultats obtenus jusqu'à présent et les perspectives, offrant ainsi un aperçu complet de l'impact de ces développements sur notre mission et notre engagement envers la préservation des milieux aquatiques.

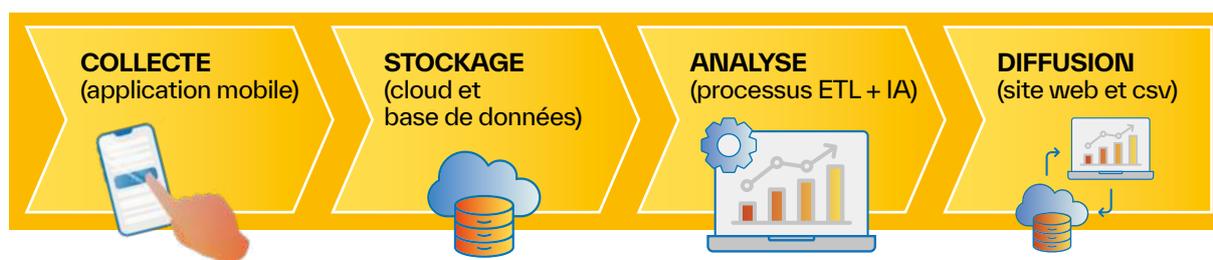


Figure 3 | Ci-dessus | Table de tri des déchets collectés par le projet Riverine Input, © Lucie Francini.



# 2 Le projet Plastic Origins

Plastic Origins est un outil numérique qui permet de collecter, stocker, analyser et diffuser des informations sur les déchets plastiques dans les rivières. L'outil est composé de plusieurs logiciels qui travaillent ensemble.



## 2.1 COLLECTE

L'application mobile permet l'acquisition des données : moyen de locomotion utilisé pour le suivi, rive étudiée et typologie des déchets observés.

En mode manuel, en parallèle de l'identification des déchets, la géolocalisation de ces derniers est obtenue en récupérant les données GPS issues du téléphone. La date et l'heure à laquelle les données ont été collectées sont également enregistrées.

Pour le mode automatique, l'application permet d'enregistrer une vidéo de la berge grâce à la caméra de son téléphone et de collecter les positions GPS du mobile.

## 2.2 STOCKAGE

Les données collectées par l'application mobile Plastic Origins sont stockées en deux endroits principaux :

*Figure 4 | En haut | Collecte de déchets en kayak, © Surfrider Foundation. Figure 5 | Ci-dessus | Schéma simplifié de la plateforme numérique Plastic Origins, © Surfrider Foundation.*

- Les fichiers bruts, y compris les données textes, les photos et les vidéos, sont stockés dans le cloud Azure.
- Les données transformées et analysées sont stockées dans une base de données structurée PostgreSQL.

Cela permet une sauvegarde sécurisée et un accès facile aux données depuis n'importe où.

## 2.3 ANALYSE

Le processus ETL (Extraction, Transformation, Chargement) est une suite d'opérations, dont l'étape clé permet de transformer des données brutes en un format exploitable pour l'analyse.

Dans un premier temps, les détections faites par l'IA sont associées aux données des campagnes automatiques et s'ajoutent aux détections manuelles. Ensuite, les données GPS collectées par l'application sont fusionnées aux différentes données sur les déchets pour créer une représentation spatiale précise de leur emplacement. Enfin, toutes ces données sur les déchets sont croisées avec les données d'une table « Rivière » de référence<sup>1</sup> pour renseigner le nom des rivières sur lesquelles ont été faits les suivis.

## 2.4 DIFFUSION

Ces différentes informations mises bout à bout permettent de construire une représentation spatio-temporelle de la présence des déchets dans les rivières. Le partage de ces données est essentiel pour promouvoir la transparence, la collaboration et l'action contre la pollution plastique.

Une carte interactive est disponible sur le site web de Plastic Origins<sup>2</sup>. Cette carte permet de visualiser l'emplacement des déchets signalés et d'accéder à des informations supplémentaires telles que la date d'observation et le type de déchet.

Un formulaire de demande d'accès aux données est également disponible sur cette page web et des fichiers CSV annuels sont mis en ligne publiquement sur le site data.gouv<sup>3</sup>. Cela permet aux chercheurs ou aux organisations intéressées d'accéder facilement aux données et de les analyser.

Notes | 1. [European catchments and Rivers network system](#) (Ecrins) | 2. [www.plasticorigins.eu](#) | 3. [www.data.gouv.fr](#)



**L'application est téléchargeable gratuitement sur iOS et Android.** Elle est disponible en 4 langues : Français, Anglais, Espagnol et Italien. Il suffit de se créer un compte utilisateur pour accéder aux deux modes d'acquisition disponibles : un mode manuel où l'utilisateur signale lui-même la présence de déchet plastique, un mode automatique où une vidéo enregistrée par l'utilisateur est ensuite traitée par une intelligence artificielle.



# 3 L'intelligence artificielle au cœur du projet

Depuis quelques années, les progrès de l'intelligence artificielle ont impacté l'ensemble des secteurs de l'économie. Comme les autres, l'écologie et l'environnement ont vu se développer des initiatives utilisant l'intelligence artificielle.

## 3.1 L'IA POUR UN OUTIL DE MESURE QUANTITATIF ET STANDARDISÉ

Nous partons du principe que des impacts positifs liés à l'usage de l'IA sont également possibles dans ces secteurs. En particulier, les technologies d'analyses automatiques d'images fournissent de précieux indicateurs sur l'usage des ressources naturelles ou de leur dégradation. En étudiant des images, nous pouvons par exemple mesurer la pollution atmosphérique<sup>4</sup>, quantifier la raréfaction ou le mésusage de l'eau potable<sup>5</sup> ou encore iden-

tifier la modification des traits côtiers<sup>6</sup>. Il devient ainsi envisageable de s'appuyer sur ce type de technologies pour détecter les déchets et les polluants.

Dans le cas de Surfrider Foundation, afin de mieux décrire la présence de plastique dans les rivières, l'ONG a été confrontée au problème de collecte de données à grande échelle. Rien qu'en France, les rivières s'étendent sur environ 623 464 km (Office français pour la biodiversité s.d.), ce qui rendait inenvisageable d'utiliser des méthodes de comptage uniquement manuelles. En effet, le comptage manuel, bien qu'utile à petite échelle, est sujet à la

Figure 6 | En haut | Utilisation de l'application Plastic Origins lors d'une sortie en kayak, © Surfrider Foundation.

Notes | 4. [Projet Bergson de l'Agence Spatiale Européenne](#) | 5. [Projet Foncier innovant de Bercy, Google et Capgemini](#) | 6. [Projet DEA Coastlines de Geoscience Australia](#)

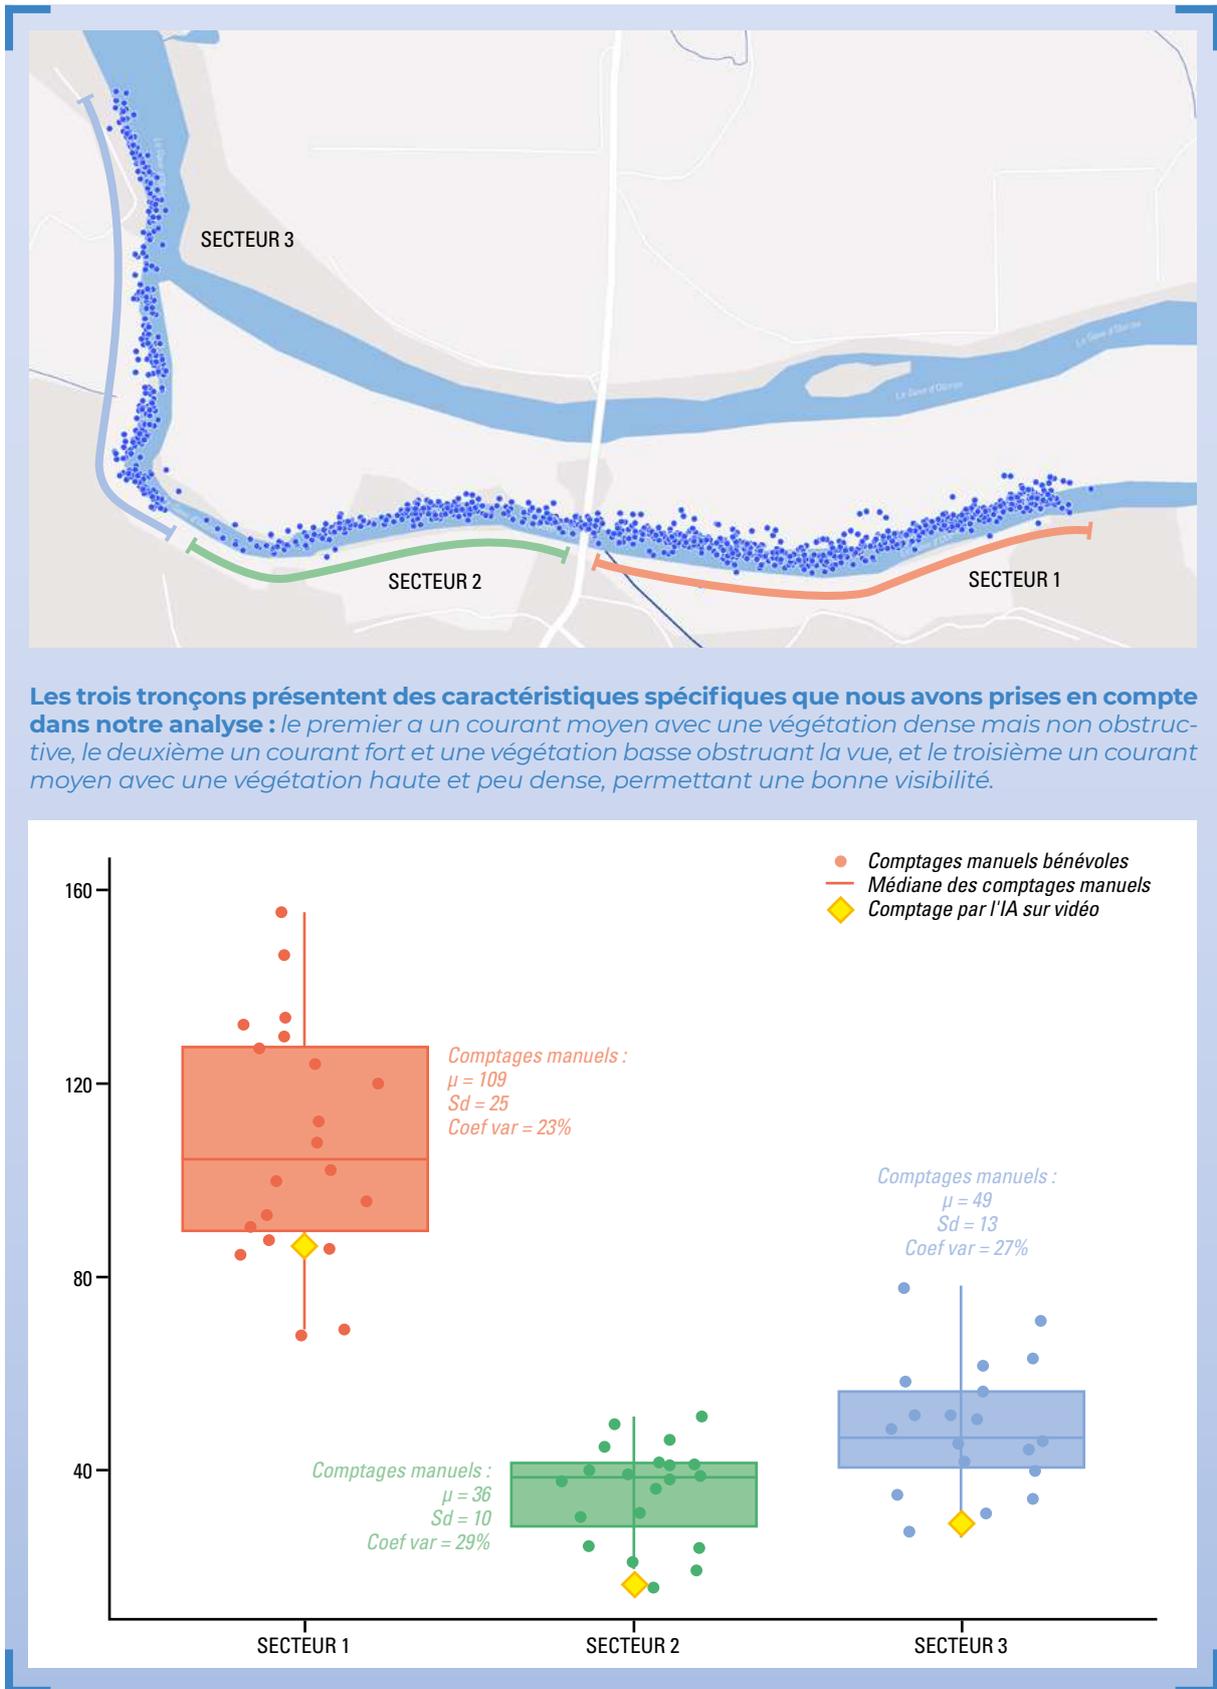


Figure 7 | En haut | Sections de rivière étudiées sur le Gave d'Oloron (64) | Figure 8 | Ci-dessous | Graphique type "Boîtes à moustaches" pour comparer les comptages manuels des bénévoles sur le terrain et le comptage de l'IA par vidéo ( $\mu$  = médiane,  $sd$  = écart type et coefficient de variation). D'après Chagneux 2023

fatigue et aux erreurs d'identification, notamment pour les observateurs novices. L'intégration de l'IA sur les téléphones pourrait constituer un moyen puissant pour accroître considérablement la collecte de données et favoriser une véritable démocratisation de la détection des déchets plastiques dans les cours d'eau. En conséquence, une des idées fortes du projet a été d'introduire l'intelligence artificielle comme outil de mesure quantitatif qui puisse être utilisé par des milliers d'utilisateurs qui collecteraient des données dans le cadre du projet Plastic Origins. D'autre part, l'IA permet de standardiser l'acquisition de données, grâce à l'automatisation de la collecte, l'analyse et l'interprétation des informations à grande échelle.

Pour confirmer l'intérêt d'une méthode standardisée pour notre projet, nous avons réalisé une mise en situation sur une portion de rivière où nous avons comparé des comptages manuels de 20 binômes de bénévoles aux résultats de l'analyse vidéo par l'IA.

Les comptages manuels réalisés par les 20 binômes de bénévoles révèlent une variabilité significative pour les trois tronçons étudiés. De son côté, l'IA tend à sous-estimer systématiquement le nombre de déchets par rapport à la majorité des observations humaines, bien qu'elle respecte la tendance générale de la pollution constatée (avec un nombre de déchets plus élevé dans T1 que dans T2 et T3). Cette différence pourrait s'expliquer par des difficultés de détection de certains types de déchets ou par des limitations liées à la qualité des images.

L'écart observé entre les méthodes de comptage pourrait soulever des doutes quant à la fiabilité ou la complémentarité des deux méthodes. Toutefois, l'objectif principal n'étant pas d'obtenir un décompte exact mais plutôt de mettre en évidence l'état de pollution des cours d'eau étudiés, nous considérons ces résultats comme satisfaisants. Si l'IA sous-estime le nombre total de déchets, elle

L'intelligence artificielle permet de supprimer le « biais observateur ». Chaque utilisateur apporte une erreur qui lui est propre (en fonction de son expérience, ses connaissances, ses capacités, son état de fatigue...). L'intérêt de faire de la détection et non de l'observation est de remplacer cette erreur variable (celle des observateurs) par une erreur constante et connue (celle de l'algorithme de détection). Elle nous permet de générer des données robustes à travers un projet de science participative.

permet néanmoins de standardiser la méthode d'acquisition dans le temps. Des nouveaux travaux pourraient permettre d'affiner le modèle automatique pour réduire cet écart.

### 3.2 UNE IA MINIATURE DANS LE GRAND MONDE DES IA

La dynamique des développements en intelligence artificielle a été portée ces dernières années par une croissance significative de la taille des modèles et des jeux de données. Cette évolution a atteint un tournant majeur, notamment depuis 2023, avec l'émergence des IA génératives. Ces « super » modèles, parfois appelés également modèles de fondations tant leurs capacités sont grandes, ont pris une place très importante dans l'écosystème technologique IA. Ils sont cependant aujourd'hui questionnés quant aux investissements nécessaires à leur développement ainsi que sur leur impact environnemental grandissant.

Les exemples les plus connus comme chatGPT 3.5 (175B de paramètres) d'OpenAI ou plus récemment Llama 3 de Meta (70B de paramètres) permettent de se représenter la complexité de ces intelligences artificielles qui utilisent plusieurs centaines de milliards de paramètres et des milliers de milliards de données pour atteindre leurs performances. Ces ordres de grandeur se traduisent aujourd'hui par des besoins en infrastructure, 24 000 serveurs graphiques (GPU) (Meta 2024), et en investissement, 100 millions de dollars, pour entraîner Llama 3 par exemple, qui sont d'une part hors de portée de la plupart des concepteurs d'IA et d'autre part pas soutenable sur le long terme étant donné les besoins énergétiques nécessaires à leur utilisation. La consommation annuelle équivalente pour chatGPT est estimée à 30 000 foyers par exemple (Crawford 2024).

En parallèle de cette croissance portée par l'IA générative et les grands modèles de langage (LLM), un effort inverse et moins médiatisé poursuit également son développement : il s'agit des approches TinyML, qui cherchent au contraire à réduire au maximum la taille des modèles pour permettre entre autres l'usage de l'intelligence artificielle sur téléphone mobile (Ollion 2023).

Afin de prendre en compte ces différentes problématiques, nous nous sommes rapidement orientés vers les approches TinyML, en testant notamment des modèles comme mobilenet (2M de paramètres) ou les versions miniaturisées de Yolov8 (3M de paramètres pour yolov8-nano, 11M de paramètres pour yolov8-small), pour des coûts de

développements de quelques centaines d'euros et des coûts d'usage marginalement nuls sur les téléphones mobiles. Les possibilités de portabilité sont évidemment bien plus grandes, car il n'y a pas besoin de groupement de milliers de serveurs pour concevoir ni utiliser cette intelligence artificielle. Enfin, bien que le calcul de l'empreinte environnementale reste à estimer, il est certain qu'elle sera inférieure de plusieurs ordres de grandeur comparativement aux modèles actuels.

L'intégration de l'IA dans les projets environnementaux doit s'accompagner d'une réflexion globale sur les impacts de cette technologie. Si les bénéfices potentiels sont nombreux, il est essentiel de privilégier des solutions durables et responsables. Le TinyML, en proposant une alternative plus légère et plus économe en énergie, s'inscrit dans cette démarche.



Figure 9 | Ci-dessus | Bénévole qui filme les déchets sur les berges depuis son kayak, © Surfrider Foundation.



# 4 Surfnet: l'IA de Surfrider

**La première étape, essentielle pour la suite, est de définir avec précision l'objectif du modèle d'intelligence artificielle. Il va déterminer la façon dont on collecte les données à l'entraînement et à l'utilisation, l'effort de R&D à fournir et le type de modèle que l'on va utiliser. De plus, cela permet de communiquer clairement aux différentes personnes impliquées dans la conception et l'utilisation ce que l'on cherche réellement à accomplir, évitant ainsi les potentiels fantasmes liés à l'IA.**

L'objectif de l'IA Surfnet est de compter les macrodéchets visibles sur les berges de rivière depuis un kayak, à partir d'une vidéo prise par un dispositif embarqué.

*Dans la suite de ce document, « Surfnet » se réfère au moteur d'IA conçu par Surfrider : il est open-source, téléchargeable et son utilisation est documentée afin d'être accessible à toute équipe intéressée par la problématique des déchets.*

## 4.1 SON CADRE D'UTILISATION

Afin de réaliser l'objectif de Surfnet, nous avons imaginé et expérimenté plusieurs cadres d'utilisation, c'est-à-dire, concrètement, comment l'utilisateur va se servir de l'application.

Le cadre doit répondre aux objectifs suivants :

- Collecter des données intéressantes pour Surfrider (permettre d'observer la bonne typologie de déchets intéressants, etc...).
- Permettre au moteur Surfnet d'être performant (si la prise de vue est mauvaise ou les objets trop petits ou trop difficiles à identifier, le moteur d'IA ne sera pas performant).
- Être ergonomique pour les utilisateurs et permettre l'adoption de l'application par le plus grand nombre.

**Figure 10 | En haut |** Utilisateur en train de photographier un déchet échoué, © Surfrider Foundation.

Cette recherche est l'un des points les plus critiques du projet, et fait appel non seulement à des compétences métier, d'intelligence artificielle, de design d'application, mais aussi de nombreux tests et confrontations aux utilisateurs sur le terrain.

Le cadre que nous avons finalement choisi est le suivant :

- **Les utilisateurs filment la rive depuis la rivière elle-même**, en général à bord d'un kayak.
- **La prise de vue est dirigée vers la berge**, perpendiculaire à celle-ci et à une distance de 2 à 5 mètres de la berge. On évite au maximum les prises de vue en perspective avec un point de fuite, car les objets ne seront plus reconnaissables.
- **La vitesse du Kayak doit être faible**, autour de 4km/h, afin d'avoir une vidéo nette et dépourvue de flou dû au mouvement. Certaines parties des cours d'eau ne pourront donc pas être prises en compte à cause de la présence de rapides ou d'obstacles.

L'appareil de prise de vue est stabilisé autant que possible (à la main dans la plupart des cas). Cela implique en général qu'une personne dirige le kayak alors que l'autre filme la berge. Des stabilisateurs de téléphones accrochés au kayakiste ou au kayak lui-même, ainsi que des GoPros, ont été envisagés, mais pour rester dans un cadre simple et accessible au plus grand nombre, la majorité des utilisateurs prennent directement les prises de vue depuis un smartphone standard.

Un enjeu important est de guider l'utilisateur pour une capture optimale de la prise de vue. Pour cela,

nous avons dispensé des formations à un certain nombre de bénévoles et mis en ligne directement sur l'application, un tutoriel avec un guide visuel pour repérer la berge.

À noter que malgré les contraintes définies, nous avons pensé Surfnet pour avoir une relative robustesse à la variabilité des conditions de prise de vue étant donné les contraintes de terrain :

- Luminosité, très variable en fonction de l'orientation de la berge, du soleil et de la météo.
- Taille des objets, variable en fonction de la perspective et la distance à la berge.
- Forme des objets, très variable de façon inhérente aux déchets plastiques.
- Occlusions partielles, étant donné que les objets sont pris dans les berges et la végétation.
- De nombreux autres paramètres sont également variables : flou, humidité, inclinaison de l'appareil, etc.



*Figure 11 | Ci-dessus | Vue du guide visuel sur l'application Plastic Origins | Figure 12 | En haut | Bénévoles qui filment les déchets sur les berges depuis leur kayak, © Surfriider Foundation.*

## 4.2 LES CHOIX TECHNOLOGIQUES

### LE MOTEUR D'IA DANS SON ENSEMBLE

Une fois le cadre d'utilisation et de prise de vue définis, de nombreuses décisions sont à prendre concernant le moteur Surfnet. La première est la façon de compter les déchets. Nous avons opté pour une méthode standard, se déroulant de la façon suivante, qui sera détaillée dans les chapitres suivants :

- Découpage de la vidéo en images successives.
- Sur chaque image, détection automatique de chaque déchet.
- Suivi des déchets sur les images successives (Tracking).
- Comptage des déchets trackés.

### LA MÉTHODE DE DÉTECTION

C'est la partie critique où le système doit identifier

et localiser les déchets dans une image. Nous avons opté pour une méthode d'intelligence artificielle de vision par ordinateur (dite *computer vision*) : une branche de l'intelligence artificielle qui permet aux ordinateurs de détecter des formes, des objets et des motifs dans les images. Dans notre cas, ces objets sont des déchets, qui peuvent être multiples, sur des images de berges de rivière. Techniquement, l'idée est d'utiliser un réseau de neurones artificiels (dans notre cas appelé CNN pour *Convolutional Neural Network*), qui est la méthode à l'état de l'art aujourd'hui pour faire de la détection d'objets.

Parmi les réseaux de neurones permettant la détection d'objets, il y a deux grandes classes de méthodes :

- La détection d'objet, qui identifie chaque objet et fournit les coordonnées d'une boîte englobante de l'objet.
- La segmentation d'objet, qui, en plus de la dé-

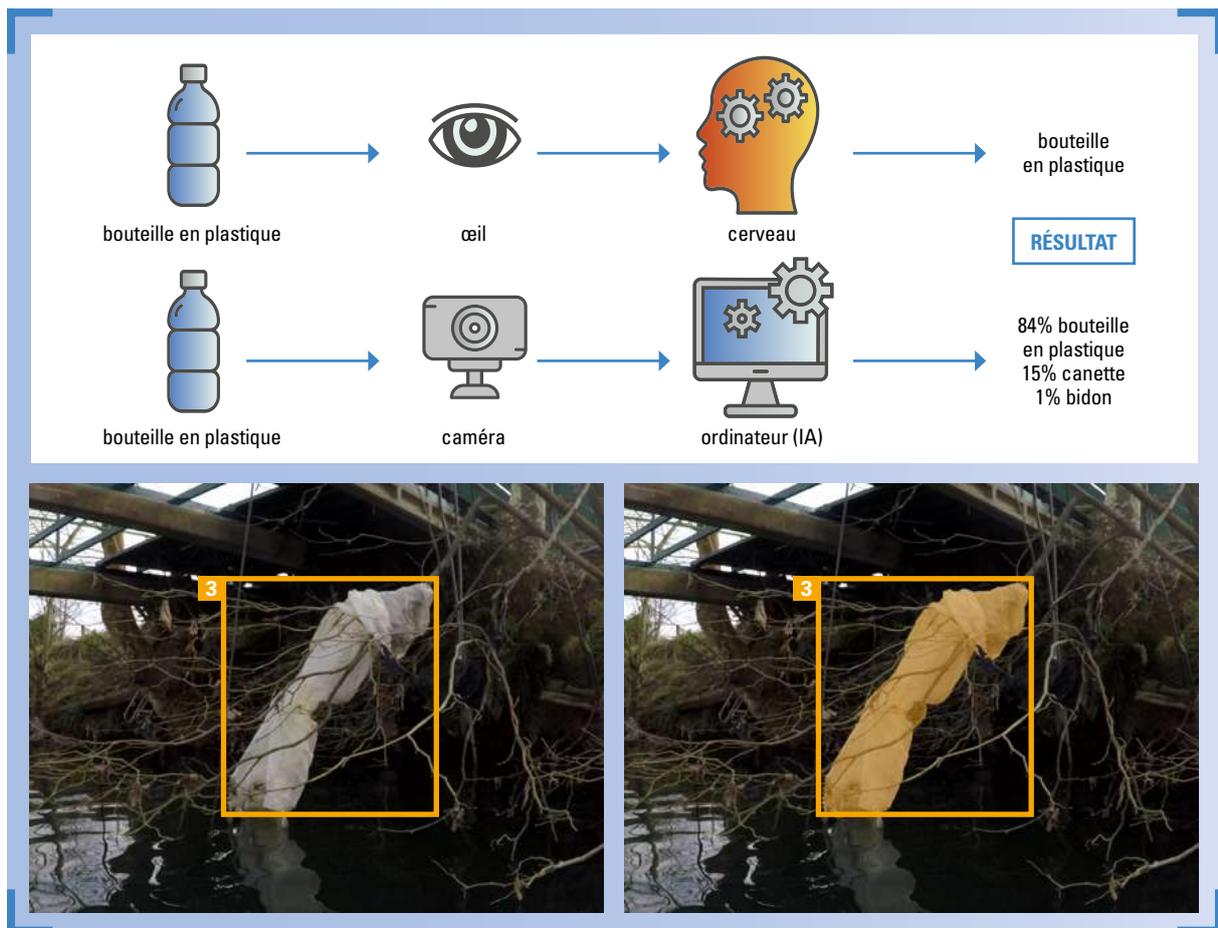


Figure 13 | En haut | Schéma comparant la vision humaine à la vision par ordinateur (IA) |

Figure 14 | En bas | Comparaison entre la détection d'objets (à gauche) et la segmentation (à droite).

tection, détoure précisément l'objet. A priori, afin de compter, nous n'avons besoin que de la première, nous avons donc opté pour cette méthode pour entraîner Surfnet à détecter des objets à l'aide d'un jeu de données détaillé dans la section suivante (paragraphe 4.3).

### LE CHOIX DU MODÈLE

Il existe de nombreuses architectures de réseaux de neurones permettant de détecter des objets. Durant le projet, nous avons travaillé sur différentes versions de modèle (ResNet, centerNet, yolov5, yolov8), et itéré sur plusieurs stratégies de données et d'entraînement, afin d'obtenir les meilleurs résultats. Les enjeux principaux que nous avons retenus sont :

- La taille du modèle (c'est-à-dire le nombre de paramètres présents dans le modèle) : plus un modèle est gros, plus il est coûteux à entraîner et à exécuter.
- La communauté open source et la portabilité du modèle : nous visons des modèles open source avec une communauté active, assurant la pérennité des développements pour ne pas tomber dans une technologie rapidement obsolète et non maintenue.
- L'efficacité du modèle à détecter des objets, notamment petits et en régime de jeu de données de taille réduite. À noter qu'aujourd'hui l'ensemble des réseaux de neurones en vision sont « pré-entraînés », c'est à dire que l'on peut bénéficier d'un entraînement déjà réalisé et générique, puis réentraîner sur notre jeu de données spécifique, ce qui

améliore grandement les performances.

Durant nos expérimentations, nous avons constitué un jeu de données, puis entraîné les réseaux de neurones à reconnaître les déchets sur ce jeu de données. Les prochaines sections détaillent les choix et résultats associés à ce travail.

### 4.3. SON JEU DE DONNÉES D'ENTRAÎNEMENT INÉDIT

La performance des modèles d'IA dépend fortement de la qualité et de la quantité des données utilisées pour leur entraînement. En effet, le jeu de données est en quelque sorte la matière première de l'apprentissage et, dans notre cas, il se matérialise sous la forme d'une collection de photos avec des informations sur les déchets visibles sur chaque image. Le jeu de données fournit ainsi les exemples nécessaires à l'IA pour apprendre à reconnaître et analyser les différentes formes de déchets que l'on peut observer sur les berges de rivière.

Une fois la **phase d'entraînement** passée, le modèle entraîné sera utilisé pour analyser de nouvelles images issues de vidéos. C'est la **phase d'inférence**, pendant laquelle l'IA fera des détections sous forme de prédiction.

Afin d'optimiser les performances de notre modèle d'IA pendant sa phase d'inférence, le jeu de données d'entraînement doit représenter la réalité des berges de rivière qui seront filmées via l'application Plastic Origins. En effet, un modèle entraîné dans

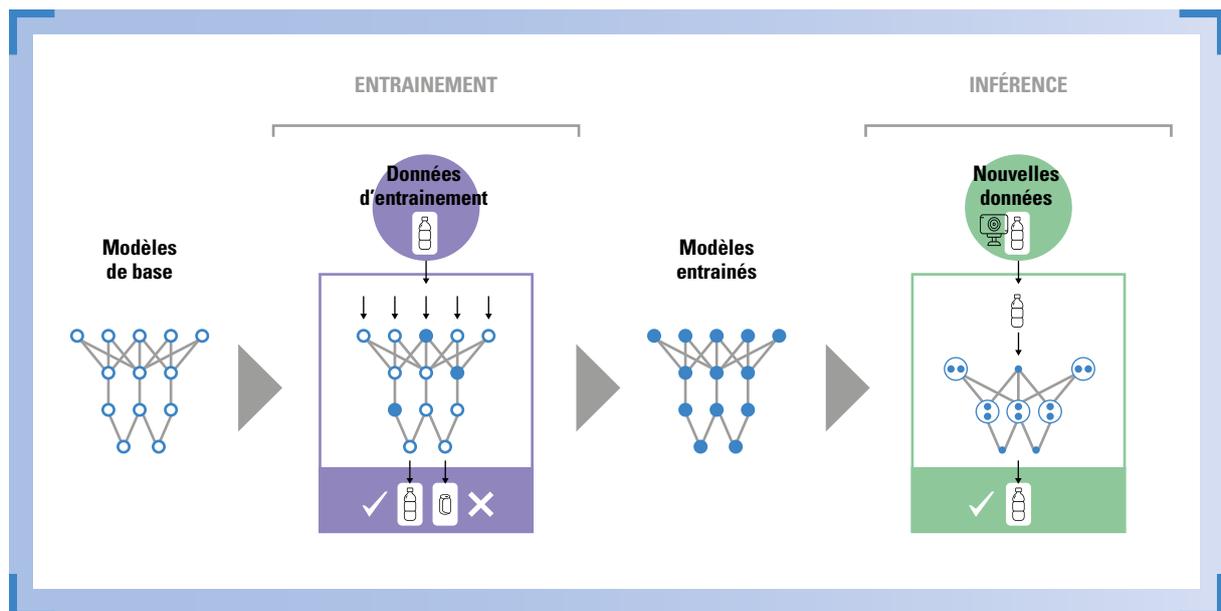


Figure 15 | Ci-dessus | Schéma des phases d'entraînement et d'inférence d'une IA.

Pendant la phase d'inférence, l'IA entraînée nous dira : "D'après ce que j'ai déjà pu voir, je pense qu'il y a de fortes chances que l'objet, à cet endroit de l'image, soit une bouteille plastique".

des conditions proches de la réalité sera plus apte à détecter les déchets, même lorsque les vidéos auront des variations importantes d'arrière-plan. Concrètement, les images d'entraînement doivent représenter des déchets sur des portions entières de berges de rivières, avec leurs complexités morphologiques et la diversité de la végétation. Or, il n'existait pas de jeu de données disponible qui correspondait à notre contexte spécifique d'étude. Le jeu de données le plus connu sur les déchets s'appelle TACO<sup>7</sup>, mais les images contiennent des déchets capturés à des distances relativement faibles et souvent dans des contextes urbains ou domestiques.

Nous avons donc créé notre propre base de données pour entraîner l'IA Surfnet. Avec l'aide de bénévoles qui ont multiplié les sorties terrain, nous avons compilé des milliers de photographies de déchets échoués sur les berges des rivières. Les images capturent les déchets dans les conditions réelles en couvrant une grande variabilité d'arrière-plans, de conditions de lumière, d'angles de vue et de qualité d'image.

Une fois toutes ces images collectées, il reste une étape indispensable : la labellisation des images. Chaque image doit être annotée manuellement, c'est à dire qu'il faut entourer le ou les déchets avec un rectangle pour indiquer leur localisation précise sur la photo et chaque déchet doit être associé à une catégorie (*les catégories sont décrites dans le paragraphe 4.4.*). Cette labellisation manuelle est fastidieuse mais obligatoire. En 2019, il n'existait pas d'outils open source d'annotation gratuit, contrairement à aujourd'hui. C'est pourquoi nous avons créé une plateforme de labellisation en ligne : [www.trashroulette.com](http://www.trashroulette.com). En s'appuyant sur un tutoriel détaillé, des centaines d'internautes ont pu annoter des images et contribuer efficacement au projet.

La création de cette plateforme de labellisation nous a permis de construire un jeu de données composé d'environ 5 000 images pour un total de 8 000 labellisations. Bien que celui-ci soit petit comparé aux gigantesques modèles comme Google, il dépasse largement celui de TACO en termes

de volume. De plus, nos données sont très spécifiques tout en couvrant une variété de contextes naturels.

Ce jeu de données nous fournit ainsi une base solide pour l'entraînement initial de Surfnet. Cependant, il ne permet pas encore d'atteindre le palier de performances. Cela signifie qu'avec plus d'images annotées, les performances de notre modèle pourraient être augmentées de manière significative (plusieurs techniques d'amélioration du jeu de données sont décrites dans le paragraphe 4.5.).

Le jeu de données est accessible en open-source à l'adresse suivante : [universe.roboflow.com/surfrider-foundation-europe/plastic-origins](http://universe.roboflow.com/surfrider-foundation-europe/plastic-origins)

À noter que cette version ne contient que ~4300 images car certaines ont été filtrées avant publication pour des raisons de qualité.



Figure 16 | Ci-dessus | Diversité d'images de déchets en rivière, © Surfrider Foundation.

Notes / 7. [tacodataset.org](http://tacodataset.org)

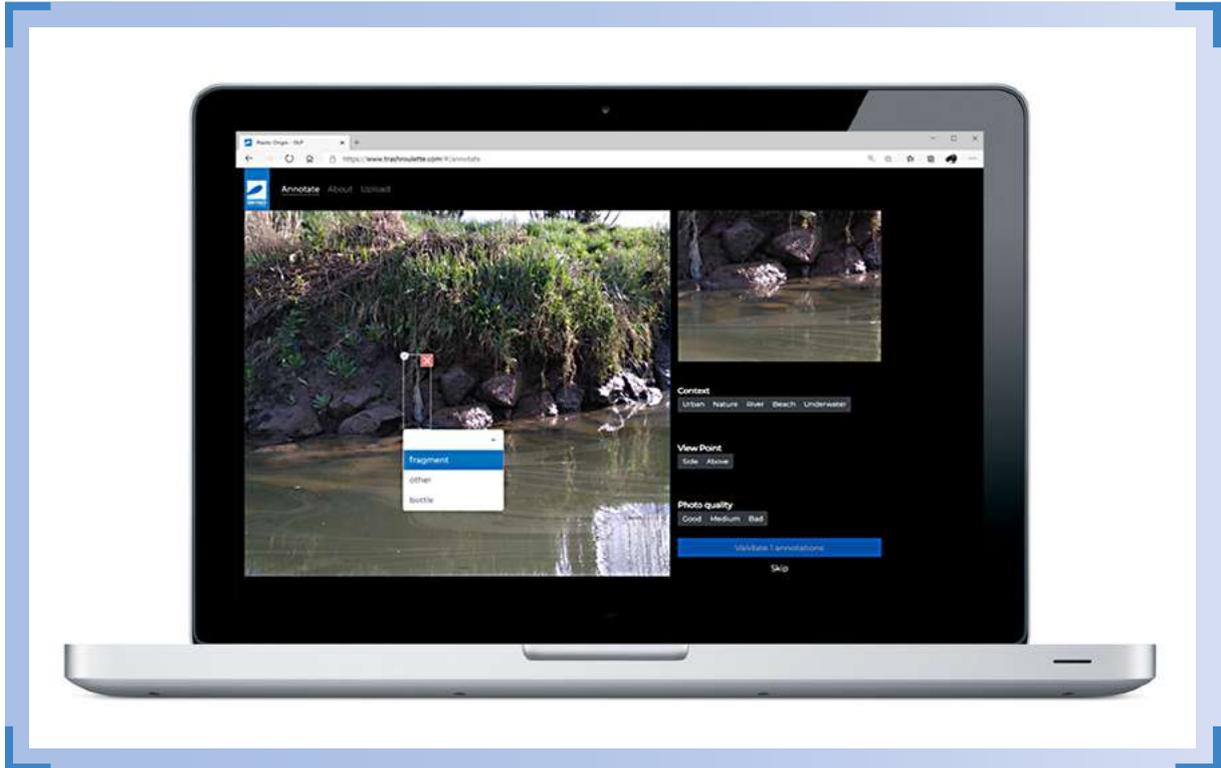


Figure 17 | Ci-dessus | Vue de la plateforme de labellisation Trashroulette.

#### 4.4. LES DIFFÉRENTES CATÉGORIES DE DÉCHETS À DÉTECTER

Afin de dresser un état des lieux précis de la pollution plastique en rivière, il est intéressant de catégoriser les déchets qui seront observés sur les berges. Il existe déjà des classifications de déchets élaborées par des experts, comme la classification OSPAR/DCSMM, qui propose une liste standardisée utilisée dans la surveillance des déchets marins (Hanke 2013). Ces classifications incluent différentes catégories basées sur le type de matériau (plastique, métal, verre, etc.) et des sous-catégories spécifiques décrivant des objets particuliers (bouteilles en plastique, filets de pêche, canettes, etc.). Elles se basent principalement sur des caractéristiques sémantiques et ont été conçues pour des observations de déchets collectés, permettant ainsi de les manipuler pour préciser leur typologie.

Sur le terrain, les opérateurs peuvent facilement identifier des déchets en se basant sur leur compréhension et leur connaissance des objets. Par exemple, une personne peut reconnaître une bouteille en plastique écrasée comme une bouteille en plastique, même si sa forme est altérée, car elle

peut faire abstraction des variations de taille, de forme et de couleur des objets. En revanche, l'IA se base uniquement sur des caractéristiques visuelles pour détecter les objets. Si un objet est déformé, sale, partiellement caché ou dans un état de décomposition avancé, l'IA peut avoir du mal à le classer correctement.

En travaillant avec des experts sur les déchets, nous avons alors défini une classification personnalisée des macro-déchets, qui concilie la facilité d'annotation et l'utilisation pratique pour un système de vision par ordinateur (Chagneux 2023). Cette classification comprend 10 catégories, classées dans 3 familles :

- Des objets rigides en forme de bouteille, de canette, de bidon, de pneu, qui sont souvent observés en rivière et facilement reconnaissables par leurs formes définies.
- Des objets fragmentés, fréquemment retrouvés le long des berges mais dont les aspects sont plus variés.
- Deux autres catégories pour les déchets clairement identifiables mais ne rentrant pas dans les catégories précédentes, ou pour ceux qui ne sont pas identifiables.

Ces 10 catégories ont ainsi été utilisées lors de la

labellisation des images pour constituer le jeu de données d'entraînement (*Annexe 1*). Même si elles représentent bien la diversité des déchets que nous retrouvons habituellement sur les berges de rivière, la répartition du nombre de labels par catégorie n'est pas uniforme. Certaines catégories ont nettement plus d'annotations que d'autres, c'est le cas de la catégorie « Bâche, sac en plastique, fragments » qui en constitue la moitié. Cette répartition inégale entre les catégories de déchets peut impac-

ter les performances du modèle *Surfnet* dans l'identification et la classification des catégories de déchets sous-représentées dans le jeu de données.

#### 4.5. DES APPROCHES MULTIPLES POUR AMÉLIORER LE JEU DE DONNÉES

Pour pallier notre jeu de données relativement petit mais aussi le déséquilibre du nombre

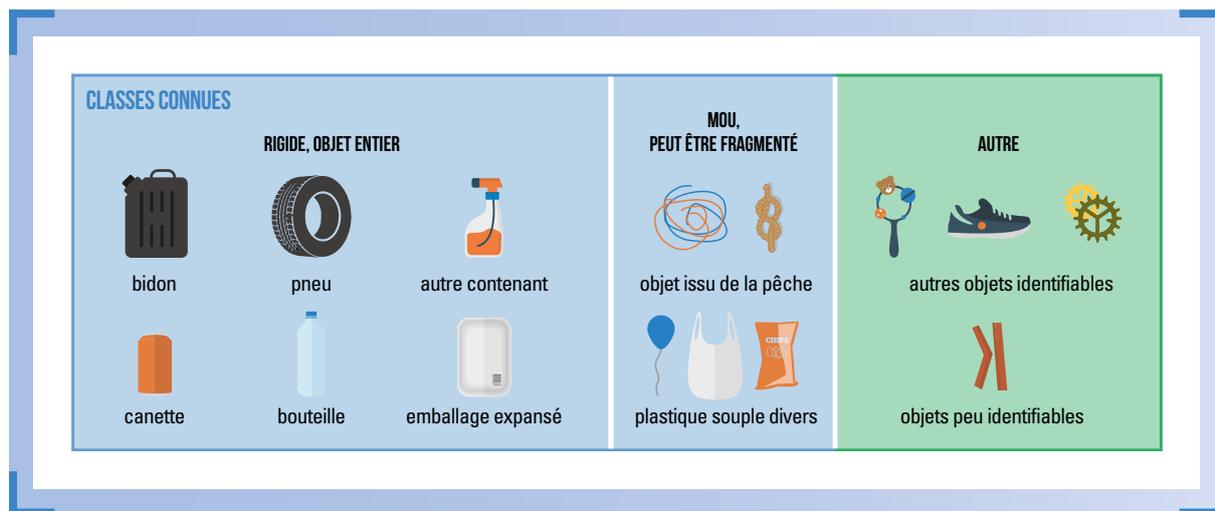
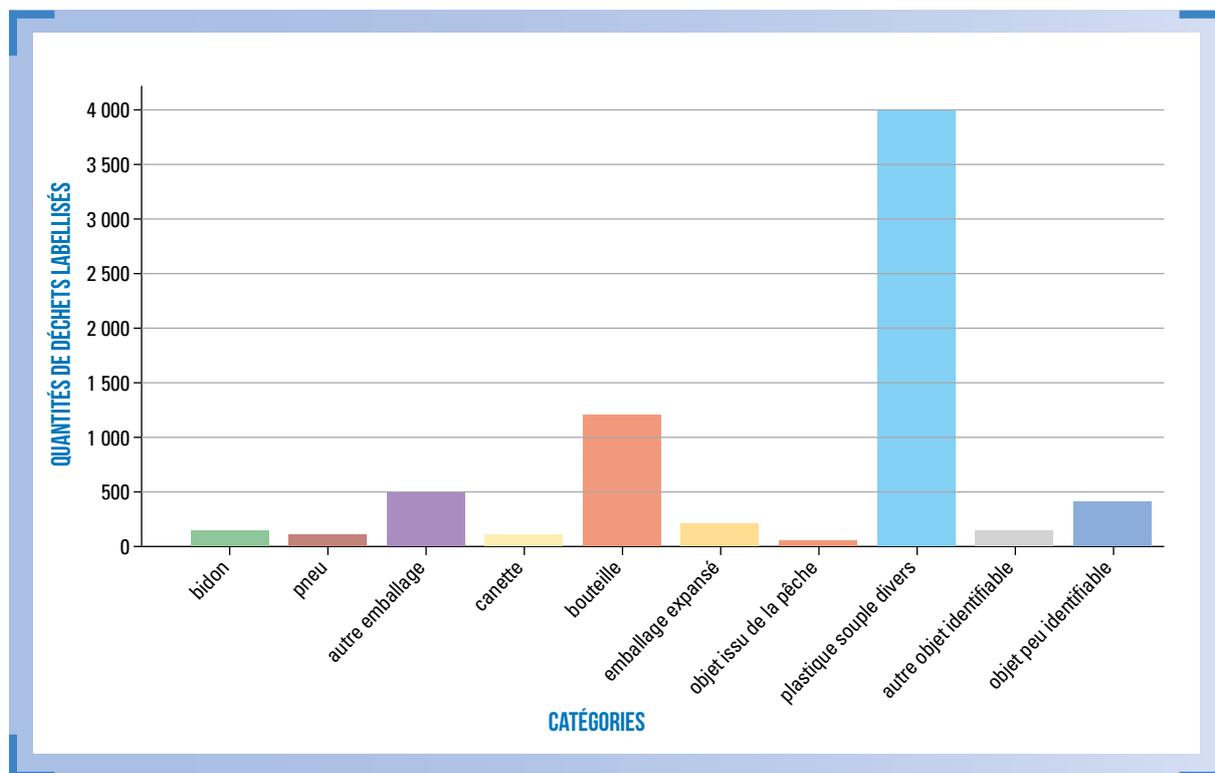


Figure 18 | Ci-dessus | Les 10 catégories de déchets utilisées pour entraîner Surfnet. | Figure 19 | Ci-dessous | Répartition du nombre de labels par catégorie. 8 000 labels ont été annotés sur les 5 000 images du jeu de données.



d'images par catégories, plusieurs techniques ont été explorées pour augmenter artificiellement le nombre d'images au total et par catégories de déchets :

- L'augmentation du jeu de données.
- La génération de données synthétiques.
- L'utilisation de modèles de fondation pour l'aide à l'annotation.

**1. L'augmentation du jeu de données** est une technique permettant d'artificiellement multiplier la taille de notre petit jeu de données, en appliquant des transformations géométriques et colorimétriques aux images. Ces transformations modifient l'image, mais doivent conserver la possibilité visuelle de détection des objets : on ne doit pas cacher ou trop altérer les objets afin qu'ils restent reconnaissables. Les augmentations les plus communes sont le retournement de l'image (symétrie horizontale dans notre cas), ajustement de la couleur ou du contraste, distorsion de l'image, application de filtres de flou. Non seulement cette tech-

nique permet d'apporter une diversité artificielle aux images, augmentant virtuellement le nombre d'images d'entraînement, mais en plus elle permet d'améliorer la robustesse du système aux perturbations que l'on introduit : typiquement le flou, le changement de contraste ou de luminosité sont des effets qui arrivent très régulièrement du fait du déplacement de la caméra et de sa position par rapport au soleil. L'utilisation d'augmentations bien choisies nous permet d'améliorer d'environ 20% la performance finale.

**2. La génération de données synthétiques** est une technique qui permet de créer artificiellement des images d'entraînement. Moins commune que la précédente, elle a été testée dans le cadre de Plastic Origins de la façon suivante :

- Extraire de vidéos de rivière des images de berge ne contenant aucun déchet.
- À partir d'une base de données de déchets segmentés extraites du jeu de données TACO, découper ces objets et les coller sur l'image de berge à

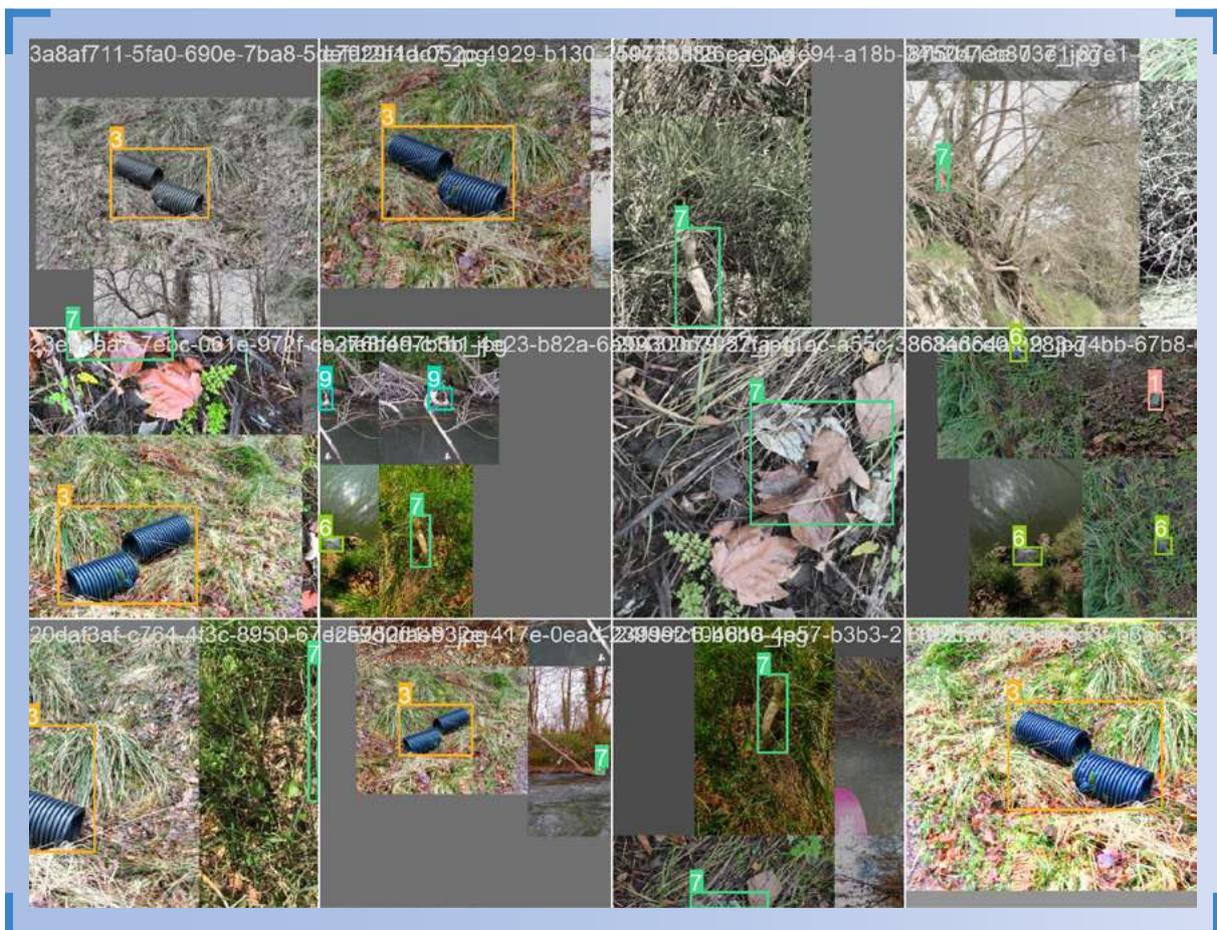


Figure 20 | Ci-dessus | Multiples images issues de l'augmentation de données : rotations, miroir, changement de contraste, luminosité, colorimétrie, etc.



**Figure 21 | Ci-dessus |** Image issue de la génération de données : déchet détourné et inséré sur un image de berge de rivière, © Surfrider Foundation.

un endroit aléatoire.

— S'assurer du rendu en ajoutant des fonds, en positionnant correctement l'objet sur la berge, et en créant des effets permettant un rendu visuel cohérent.

— En fonction de la zone collée et de l'objet, construire automatiquement l'annotation correspondante.

Cette méthode permet de générer artificiellement des milliers d'images si l'on a suffisamment d'images de fond (berges de rivière vierges) et de déchets à y insérer (objets détournés). Il est très important de bien différencier ces images synthétiques des images réelles annotées : elles ne sont ni réelles ni parfaites, elles doivent servir d'aide à l'entraînement seulement, mais il faudra évaluer la qualité du modèle sur des données réelles uniquement. Nos tests réalisés en 2023 montrent une légère amélioration du modèle, de l'ordre de 5%, en y ajoutant des données synthétiques, cependant l'investissement nécessaire pour avoir un rendu

correct est fort et l'on peut se retrouver à passer plus de temps à bien calibrer le système de génération plutôt que d'annoter simplement de nouvelles images. Cette piste a donc été mise de côté pour le moment. Un exemple se trouve ci-dessus.

**3. Enfin, l'utilisation de modèles de fondation** pour l'aide à l'annotation est un phénomène beaucoup plus récent, qui est rendu possible par l'arrivée de modèles géants et généralistes tels que SAM<sup>8</sup>, OwlVit<sup>9</sup>, Dino<sup>10</sup>. Ces modèles géants (100 à 1000 fois plus gros que les modèles de vision pré-entraînés mentionnés plus haut) sont beaucoup plus agnostiques aux données et à la tâche considérée, et permettent notamment d'améliorer nos données d'entraînement. Dans le cadre du projet Plastic Origins, nous avons notamment utilisé SAM "Segment Anything", un modèle permettant de détourner tout type d'objets. Les annotations de notre base de données étant principalement des boîtes englobant les déchets, elles sont moins précises que ces détournages ; il est alors possible

Lorsqu'on se place dans un contexte faible en ressources (peu de capacités de calcul et jeu de données relativement petit) comme le nôtre, l'utilisation de modèles de vision pré-entraînés, d'augmentation des données et de modèles de fondation sont simples à mettre en place et procurent d'excellents résultats. Cependant la génération de données synthétiques, bien que potentiellement utile, demande un investissement plus conséquent et propre à chaque objectif.

**Notes |** 8. [segment-anything.com](https://segment-anything.com) | 9. [console.cloud.google.com/vertex-ai/publishers/google/model-garden/owlvit-base-patch32?pli=1](https://console.cloud.google.com/vertex-ai/publishers/google/model-garden/owlvit-base-patch32?pli=1) | 10. [ai.meta.com/blog/dino-v2-computer-vision-self-supervised-learning](https://ai.meta.com/blog/dino-v2-computer-vision-self-supervised-learning)

de partir des boîtes et appliquer SAM sur chacune d'entre elles, afin d'obtenir un détournage précis de l'objet. Ce processus fait appel à un large modèle tel que SAM, mais ne doit être fait qu'une seule fois sur chaque image d'entraînement, ainsi la consommation en ressources est négligeable. À noter qu'il ne serait pas envisageable d'utiliser SAM en production (c'est à dire sur chaque nouvelle vidéo) à cause de sa lourdeur en calcul. L'utilisation de données d'entraînement plus précises (segmentation plutôt que boîtes englobantes) permet d'augmenter les performances du modèle léger en détection d'objet d'environ 10% dans notre cas. Un exemple de données annotées en segmentation automatiquement se trouve ci-dessous.

## 4.6. LES MÉTRIQUES ET LES RÉSULTATS DES DÉTECTIONS SUR IMAGES FIXES

### LES MÉTRIQUES : INDICATEURS DE LA PERFORMANCE DE NOTRE MODÈLE

En utilisant le jeu de données et les images annotées, on peut entraîner le modèle de vision par ordinateur. Ainsi celui-ci sera à même de détecter et localiser les déchets sur des images relativement similaires à celles du jeu de données. Cependant les modèles d'intelligence artificielle ne sont pas infaillibles et vont avoir un certain taux de performance. On juge en général selon plusieurs critères, par exemple :

— À quel point le modèle est exhaustif (c'est-à-dire qu'il rate le moins possible de déchets présents sur l'image), on nomme cette métrique le **rappel**.

— À quel point le modèle va produire des bonnes détections ou au contraire produire des erreurs (par exemple il va prendre un caillou pour un déchet), on nomme cette métrique la **précision**.

On évalue souvent la qualité de l'entraînement en combinant ces deux métriques, notamment à l'aide d'une métrique globale qui produit une sorte de moyenne, nommée le **score F1**.

Il existe un grand nombre d'autres métriques, par exemple liées à la précision des coordonnées dans l'image de la boîte prédite par rapport à la vérité-terrain. Il est très important de définir rapidement les métriques qui seront pertinentes pour une application donnée, car chaque application a ses spécificités. Dans notre cas, nous avons séparé deux types de métriques, celles liées à la détection des objets dans les images fixes, puis celles liées au comptage dans les vidéos (métrique métier finale la plus importante). La suite de cette section décrit les métriques de détection, les métriques de comptage seront abordées dans la suivante (*paragraphe 4.5*).

Dans notre cadre de comptage d'objets, l'important est principalement de ne pas rater les objets (donc avoir un fort rappel) et de ne pas produire d'erreur (d'avoir une bonne précision), mais assez peu d'avoir une localisation très précise des objets (on autorise les erreurs sur les coordonnées des boîtes prédites).

De plus, nous nous intéressons autant à un comptage global des déchets qu'à un comptage par catégorie, nous reportons donc deux scores : l'un, nommé **multiclasse** prend en compte la catégorie de l'objet détecté (compté comme bon seulement s'il est conforme à l'annotation), et l'autre nommé **monoclasse**, ne s'intéresse qu'au fait de bien repérer un objet indépendamment de son type.

### LES RÉSULTATS

Étant donné notre volonté de modèle léger, nous avons opté pour des modèles de taille réduite yolov8-s (small), avec 11 millions de paramètres, nous offrant le bon compromis de performance / vitesse d'exécution.

Voici ci-dessous les résultats finaux obtenus sur yolov8-s après plusieurs itérations.

Il est important d'interpréter ces résultats, car les scores en dehors du contexte n'apportent que peu d'informations.

| TYPE        | SCORE F1 | RAPPEL | PRÉCISION |
|-------------|----------|--------|-----------|
| monoclasse  | 0.63     | 60%    | 69%       |
| multiclasse | 0.42     | 39%    | 46%       |

Figure 22 | Ci-dessus | Résultats obtenus sur yolov8-s après plusieurs itérations. Score F1, rappel et précision.



**Figure 23 | Ci-dessus | Exemple d'image avec erreur : le plus gros morceau de plastique est détecté mais le petit à sa gauche ne l'est pas.**

Sur les images de notre jeu de données, le modèle détecte en moyenne 60% des déchets. Une analyse poussée nous montre que les plus petits objets sont souvent ratés principalement à cause de la résolution d'entrée de l'image limitée et la prise de vue lointaine par rapport à la berge. Le modèle prédit également assez régulièrement des faux-positifs (précision à 69%, ce qui implique que 31% des prédictions sont des fausses). Les analyses nous montrent que ça correspond souvent à un doublement d'une prédiction sur un objet amorphe (par exemple une bâche plastique est détectée en deux morceaux alors que l'annotation ne comprenait qu'un seul morceau. Également, des cas où il y a un grand nombre de cailloux blancs en berge de rivière sont parfois interprétés comme des morceaux de plastique.

Enfin, la performance multiclasse est significativement plus faible que celle en monoclasse. Un objet détecté dans la mauvaise catégorie va faire baisser la précision mais également correspondre à un raté (car l'objet original n'est plus considéré comme trouvé), ce qui fait baisser le rappel. Cela indique une confusion entre certaines catégories, typiquement la catégorie « Emballage alimentaire » est logiquement source de confusion avec d'autres catégories telles que « Bâche, sac en plastique, fragments ». Il en va de même pour la catégorie « Divers objets facilement identifiables » et « Divers objets non identifiables ». Cela montre que les trois catégories les moins bien définies d'un point de vue des annotations sont également celles qui génèrent le plus de confusion pour le modèle, ce qui est attendu. Une mise à jour des catégories ou une meilleure labellisation permettrait d'éviter ce problème.

Ces résultats peuvent sembler décevants d'un point de vue intuitif. Ainsi, la communication avec les équipes métier est souvent délicate car ils s'attendent à une précision de 99% pour avoir confiance dans le système. Cependant, ces performances sont souvent suffisantes car la détection sur une image fixe n'est qu'une partie du système et le suivi des objets permet de rattraper un grand nombre d'erreurs et d'arriver à un compte bien meilleur.

**Notes | 8.** [segment-anything.com](https://segment-anything.com) | **9.** [console.cloud.google.com/vertex-ai/publishers/google/model-garden/owlvit-base-patch32?pli=1](https://console.cloud.google.com/vertex-ai/publishers/google/model-garden/owlvit-base-patch32?pli=1) | **10.** [ai.meta.com/blog/dino-v2-computer-vision-self-supervised-learning](https://ai.meta.com/blog/dino-v2-computer-vision-self-supervised-learning)

## 4.7. LE SUIVI DES DÉCHETS DANS UNE VIDÉO

Après avoir détaillé notre module IA capable de reconnaître des objets sur des images fixes, nous ajoutons la complexité de suivre les objets à travers les images successives d'une vidéo, c'est ce que nous appelons le "Tracking". Surfnet doit alors non seulement détecter les objets dans chaque image mais aussi suivre leur mouvement au fil du temps pour maintenir une continuité dans le suivi des objets et éviter le comptage répété du même objet. Ce n'est pas une tâche facile lorsqu'on peut avoir des faux positifs et faux négatifs et que la caméra (et donc tous les objets présents) bouge entre chaque image.

Le suivi d'objets, en environnement complexe, avec une caméra mouvante est une problématique difficile qui nécessite un effort substantiel de R&D. Nous avons fait appel à un laboratoire de recherche et monté une thèse en CIFRE afin d'avancer sur ce sujet. Une publication dans un journal scientifique (Chagneux 2023) et un moteur de suivi open source<sup>11</sup> ont été des résultats de cette thèse.

Voici une version simplifiée des étapes de tracking :

### 1. Détection initiale

Les déchets sont d'abord repérés sur une image par notre IA Surfnet.

### 2. Prédiction du mouvement

L'enjeu est ensuite de suivre ces déchets dans le temps. Autrement dit, si l'on a détecté un déchet dans une image, il faut l'associer à une détection dans l'image suivante. Pour chaque déchet détecté, un algorithme statistique essaie de deviner

où il sera dans l'image suivante. C'est comme si on dessinait un cercle autour de chaque déchet pour dire « *il devrait être quelque part par ici* ».

### 3. Recherche et association

Dans l'image suivante, l'algorithme cherche ainsi un déchet dans chacune des zones de prédiction :

- Si un déchet est trouvé dans la zone, c'est probablement le même que dans l'image précédente.
- Si rien n'est trouvé, le cercle de recherche s'agrandit.
- Si un nouveau déchet apparaît ailleurs, un nouveau tracking commence.

### 4. Gestion de l'incertitude

L'algorithme utilise aussi des probabilités pour gérer les cas incertains, comme quand un déchet disparaît temporairement ou quand plusieurs déchets sont proches.

Ci-dessous un exemple où des déchets sont détectés puis recherchés dans les images successives :

- Le premier déchet détecté est tracké par le cercle rouge. Le cercle rouge se déplace mais garde la même taille. Le tracking est réussi d'une image à l'autre.
- Pour le second déchet, représenté en marron, le cercle marron s'agrandit pour illustrer la recherche élargie car le déchet n'est pas retrouvé dans la deuxième et la troisième image.
- Un cercle rose apparaît dans la troisième image avec la détection d'un troisième déchet.

Il existe plusieurs métriques d'évaluation des systèmes de tracking, décrites dans la publication. Dans notre cas, nous nous focalisons sur le comptage final des déchets, c'est-à-dire le nombre de déchets qui ont été suivis sur plus de 5 images



Figure 24 | Ci-dessus | Méthode de tracking sur des images successives, © Chagneux 2023.

Notes | 11. [github.com/surfriderfoundationeurope/surfnet](https://github.com/surfriderfoundationeurope/surfnet)

consécutives (meilleur compromis après différents tests).

Pour cela, reprenons notre zone d'expérimentation à 3 tronçons sur le Gave d'Oloron, où nous avons déjà comparé les comptages humains versus ceux de l'IA (voir paragraphe 3.1.). Sur ces mêmes tronçons, nous allons à présent comparer les comptages de l'IA à ceux d'une personne qui visionne la même vidéo. L'IA actuelle compte environ 2/3 des déchets par rapport à un humain expert qui visionne

la même vidéo. Cette performance varie significativement d'un tronçon à l'autre, et est particulièrement faible sur le tronçon T2, là où le courant est le plus fort et la végétation la plus basse, gênant la prise de vue. Ces résultats sont encore améliorables, non seulement par l'entraînement d'un meilleur modèle, mais également par un meilleur protocole d'acquisition (pour que les bénévoles fournissent des données plus stables).

| TYPE                                 | TRONÇON 1 | TRONÇON 2 | TRONÇON 3 |
|--------------------------------------|-----------|-----------|-----------|
| Comptage humain par visionnage vidéo | 133       | 26        | 28        |
| Comptage IA sur la même vidéo        | 86        | 11        | 25        |
| % de détection de l'IA               | 65%       | 42%       | 89%       |



**Figure 25 | Ci-dessus |** Déchet flottant juste sous la surface de l'eau, © Surfrider Foundation. **Figure 26 | En haut |** Comparaison des comptages de l'IA à ceux d'une personne qui visionne la même vidéo sur 3 tronçons de rivière différents.



# 5 Discussions

**L'utilisation croissante de l'intelligence artificielle dans les projets de sciences participatives redéfinit les stratégies de lutte contre la pollution plastique. Nous nous penchons ici sur les opportunités et les limites de cette approche dans le contexte de Plastic Origins.**

## 5.1 SCIENCES PARTICIPATIVES ET INTELLIGENCE ARTIFICIELLE : UN DUO COMPLÉMENTAIRE SUR LE TERRAIN ?

Étudier une pollution plastique dans un environnement comme la rivière n'est pas une tâche facile. L'inaccessibilité des berges, la végétation dense, les variations de débits ou encore la fragmentation des plastiques rendent la tâche particulièrement complexe. Les technologies récentes comme la télédétection sont souvent inaccessibles en raison de leur coût ou de leur manque d'applicabilité

dans ces environnements. C'est ici que les sciences participatives proposent des alternatives innovantes. Les citoyens peuvent contribuer à collecter des données pendant une activité de loisirs comme la randonnée ou le canoë-kayak. Ce travail collaboratif s'adresse de fait à des personnes qui sont déjà sensibilisées à la protection de l'environnement mais il peut impliquer les citoyens plus concrètement dans la lutte contre la pollution plastique.

Avec la mise à disposition de l'IA, nous souhaitons simplifier et standardiser la collecte de données pour les bénévoles. Néanmoins, l'adoption de ce mode automatique s'est révélée plus lente que prévu. Après 2 années de fonctionnement en routine,

Depuis le début du projet Plastic Origins, 1100 campagnes ont été menées, permettant de signaler près de 35 000 déchets sur plus de 2 000 km de rivières dans 8 pays européens (chiffres de septembre 2024).

Figure 26 | En haut | Tri et quantification de déchets après une collecte, © Surfrider Foundation.

**seulement 10% des campagnes de terrain pour collecter de données ont été opérées avec le mode automatique de l'application.**

Pour rappel, avec le mode manuel l'utilisateur signale lui-même la présence de déchet plastique alors qu'avec le mode automatique, il enregistre une vidéo à partir de l'application puis la transfère sur un serveur où l'IA l'analysera dans un second temps (voir paragraphe 2).

Les citoyens semblent ainsi préférer le caractère ludique du mode manuel, préférence également observée chez les bénévoles les plus expérimentés, formés et habitués à utiliser l'application sur de longues distances. Selon eux, ce mode permet une validation visuelle de chaque déchet et une certitude de contribuer activement à la protection de l'environnement. A l'inverse, le mode automatique, avec son processus déporté et l'absence de retour immédiat, ne parvient pas à engager les bénévoles de la même manière.

En changeant ce système déporté pour intégrer l'IA sur le mobile, nous pourrions visualiser en direct ses résultats de détection. En rendant visible le processus décisionnel de l'algorithme, les utilisateurs comprendraient mieux comment l'IA les assiste et ainsi lui feraient davantage confiance.

## 5.2. QUELS SONT LES BÉNÉFICES ET LES ENJEUX DE L'INTÉGRATION DE L'IA SUR NOS TÉLÉPHONES PORTABLES ?

Les différentes phases de développement ont abouti à une solution d'IA performante et économiquement viable, en combinant la recherche de la performance des détections et un usage technologique raisonné à bas coût.

Hébergée dès le début dans le Cloud, l'impact de l'IA développée pour Plastic Origins a été rapidement discutée au sein de l'équipe projet : d'une part, en raison des coûts élevés liés à l'utilisation de GPU pour un service en temps réel et d'autre part, au regard de l'impact écologique non justifié de ce service. Nous avons donc opté pour une solution plus durable mettant en œuvre une ingénierie innovante (Le Roux 2023). D'abord, les traitements réalisés par l'IA ont été planifiés pour passer d'un mode de service disponible 24h/24 et 7j/7 vers un calcul périodique de quelques heures voire minutes en fin de semaine, selon le nombre de vidéos à analyser. Conjointement, une première étape de

miniaturisation de l'IA a permis d'effectuer les traitements sur des serveurs avec des CPU, moins énergivores que les serveurs avec GPU. Ces premières améliorations ont permis de diminuer les coûts de l'IA Plastic Origins d'un facteur situé entre 10 et 100.

Dans un second temps, grâce aux récentes avancées technologiques, nous avons exploré une nouvelle opportunité d'amélioration de la solution. En effet, si les premières versions d'IA étaient trop volumineuses pour les appareils mobiles, les développements des TinyML offrent à présent la possibilité de "migrer" l'IA depuis le Cloud vers le terminal mobile des utilisateurs réduisant ainsi les coûts (Ollion, C. 2023) En effet, lorsque l'IA est exécutée directement sur un téléphone mobile, cela supprime le besoin de transfert de la vidéo, son stockage et son analyse sur des serveurs puissants mais onéreux dans le Cloud. Le seul coût énergétique à prévoir résulte de l'augmentation de la consommation d'énergie du téléphone.

Ainsi, nous avons entrepris une démarche de recherche et développement innovante, en réalisant des premiers tests d'intégration de l'IA pour que celle-ci soit directement exécutée sur mobile. De nouvelles problématiques d'ingénierie sont apparues afin de rendre cela possible.

**Nous voulions que notre IA Mobile soit efficace, ergonomique, démocratique et économe :**

**Efficace :** l'IA doit fonctionner suffisamment bien pour que le comptage soit utile. Pour cela, nous avons estimé un minimum de 5 détections par seconde afin que le suivi des objets fonctionne normalement. Un effort d'ingénierie considérable est nécessaire afin de miniaturiser le modèle tout en gardant une bonne performance de détection. De plus, la résolution de la vidéo étant limitée à 640x640 pour des raisons de vitesse de calcul, certains petits déchets sont difficiles à détecter. À ce jour, les méthodes de suivi sur téléphone mobile ne sont pas très abouties et nécessitent des développements techniques très spécifiques.

**Ergonomique :** pour embarquer les bénévoles et leur donner confiance sur la détection par l'IA. Pour cela nous avons fait appel à des designers travaillant sur l'expérience utilisateur ainsi que des ateliers pour comprendre comment les utilisateurs percevaient et utilisaient l'application. Nous avons convenu de bien expliquer le fonctionnement et faire un tutoriel permettant d'embarquer les utilisateurs vers une utilisation et une compréhension optimale de l'application.



Figure 27 | En haut | Tutoriel pour embarquer les utilisateurs de l'application prototype | Figure 28 | Au milieu | Ecran principal de détection en temps réel des déchets en rivière via l'application prototype | Figure 29 | En bas | Pop-up de fin d'enregistrement via l'application prototype.

**Démocratique** : l'application doit pouvoir tourner sur tout type de téléphones, pas uniquement les plus récents. Malgré les nombreuses optimisations, il en ressort que de faire de la détection temps réel et fluide sur téléphone nécessite tout de même un appareil plutôt récent. Les tests réalisés avec différents types de téléphones montrent un bon fonctionnement avec un Galaxy s10e (2019) ou équivalent. Cependant plusieurs téléphones, même plus récents, n'ont pas de carte graphique dédiée et ont du mal à faire tourner l'IA à la vitesse nécessaire.

**Économe** : le téléphone doit pouvoir fonctionner suffisamment longtemps pour faire des suivis sur des portions de rivière assez longues. Nos tests ont montré que filmer et faire tourner l'IA sur plusieurs dizaines de minutes fonctionne. Cependant, selon le téléphone, la consommation notamment du module IA varie fortement, ainsi cette problématique reste importante.

L'enjeu d'une application mobile est assez bien compris, cependant la possibilité technique de faire fonctionner efficacement le système avec toutes les contraintes définies ici reste à démontrer. Nos premiers prototypes nous ont appris qu'il est possible de faire tourner des modèles de détection et de suivi des déchets en temps réel, mais qu'un effort d'ingénierie considérable est nécessaire, et que les outils disponibles aujourd'hui ne sont pas encore matures.

### 5.3. LES DÉVELOPPEMENTS DE SURFNET PERMETTENT-ILS DE RÉALISER DES DIAGNOSTICS DE LA POLLUTION EN RIVIÈRE ?

Les résultats attendus du projet Plastic Origins s'articulent autour d'une cartographie précise de la présence de déchets plastiques le long des cours d'eau européens. Cette carte crée une vue d'ensemble de l'étendue et de la distribution de la pollution plastique. Grâce à cet outil, SurfRider a pour objectif de faire prendre conscience de l'ampleur du problème aux décideurs locaux, nationaux et européens.

Initialement, en 2019, Plastic Origins visait à établir des diagnostics détaillés de la pollution des rivières, d'une part en classant les cours d'eau selon leur niveau de contamination grâce à un indicateur du nombre de déchets échoués sur un linéaire de berge de rivière mais aussi de remonter le plus

possible aux sources de cette pollution diffuse en identifiant les types de déchet qui s'y trouvaient. Néanmoins, les incohérences entre les catégories de déchets définies pour l'IA et celles du mode manuel mais aussi les difficultés rencontrées par les citoyens pour classer les déchets nous ont contraints à repenser notre approche. Ainsi, depuis début 2023, seules trois catégories persistent : les encombrants, qui peuvent facilement être signalés aux services locaux compétents, les zones d'accumulation qui pourront faire l'objet d'une attention particulière (quantification, prévention, nettoyage) puis tous les autres déchets regroupés dans une même catégorie sans distinction.

**Si cette simplification permet de rendre les données plus exploitables dans un sens, l'objectif initial de diagnostic s'est progressivement orienté vers un signalement simple des déchets.**

En cela, il devient impossible d'en faire un indicateur intéressant dans la surveillance des cours d'eau. Ainsi, les résultats de ce projet de science participative se cantonnent à de la sensibilisation des citoyens et des décideurs aux enjeux environnementaux, mais ne peuvent pas constituer d'indicateurs pérennes et très fiables scientifiquement (Tramoy 2022).

Concrètement, sur le terrain, l'application Plastic Origins est utilisée par des partenaires comme l'association Découverte et Participation à la Préservation des Milieux (DPPM, 62) et le Parc Naturel Marin du Bassin d'Arcachon (PNMBA, 33) pour géolocaliser les déchets lors de leurs missions de surveillance des cours d'eau. En complément, ils réalisent la collecte des déchets et la quantification selon la classification OSPAR/DCSMM.

Malgré leurs limites, les données collectées par Plastic Origins leur sont précieuses pour identifier des zones d'accumulation et orienter des études plus poussées, comme la mise en œuvre du protocole OSPAR en rivière, qui s'instaure depuis peu comme le cadre de surveillance des réseaux hydrographiques en Europe (UNEP 2023).

### 5.4. COMMENT MESURER L'IMPACT ENVIRONNEMENTAL DE L'IA SURFNET PAR RAPPORT À SA MISSION ÉCOLOGIQUE ?

Bien que la prise de conscience sur les impacts environnementaux des IA se développe, il n'est pas aisé de qualifier ni de quantifier ces derniers. Cependant, le rapide développement des usages IA couplé aux enjeux climatiques largement docu-

mentés oblige à de telles considérations. Si la conception des IA et notamment la phase d'entraînement a longtemps focalisé l'attention, la croissance des usages conduit à observer en parallèle la phase d'inférence de l'IA. Dans la continuité des travaux de l'UE définissant les règles d'éthique pour l'IA (European Commission 2024), la question de la frugalité des IA devient donc un nouveau

sujet d'attention particulièrement important.

En effet, les phases de conception et d'utilisation d'un système d'IA nécessitent une grande consommation d'électricité et d'eau et participent aux émissions de CO<sub>2</sub> planétaire. Malgré l'absence d'indicateurs précis définissant cette frugalité des IA, des initiatives comme le référentiel général pour

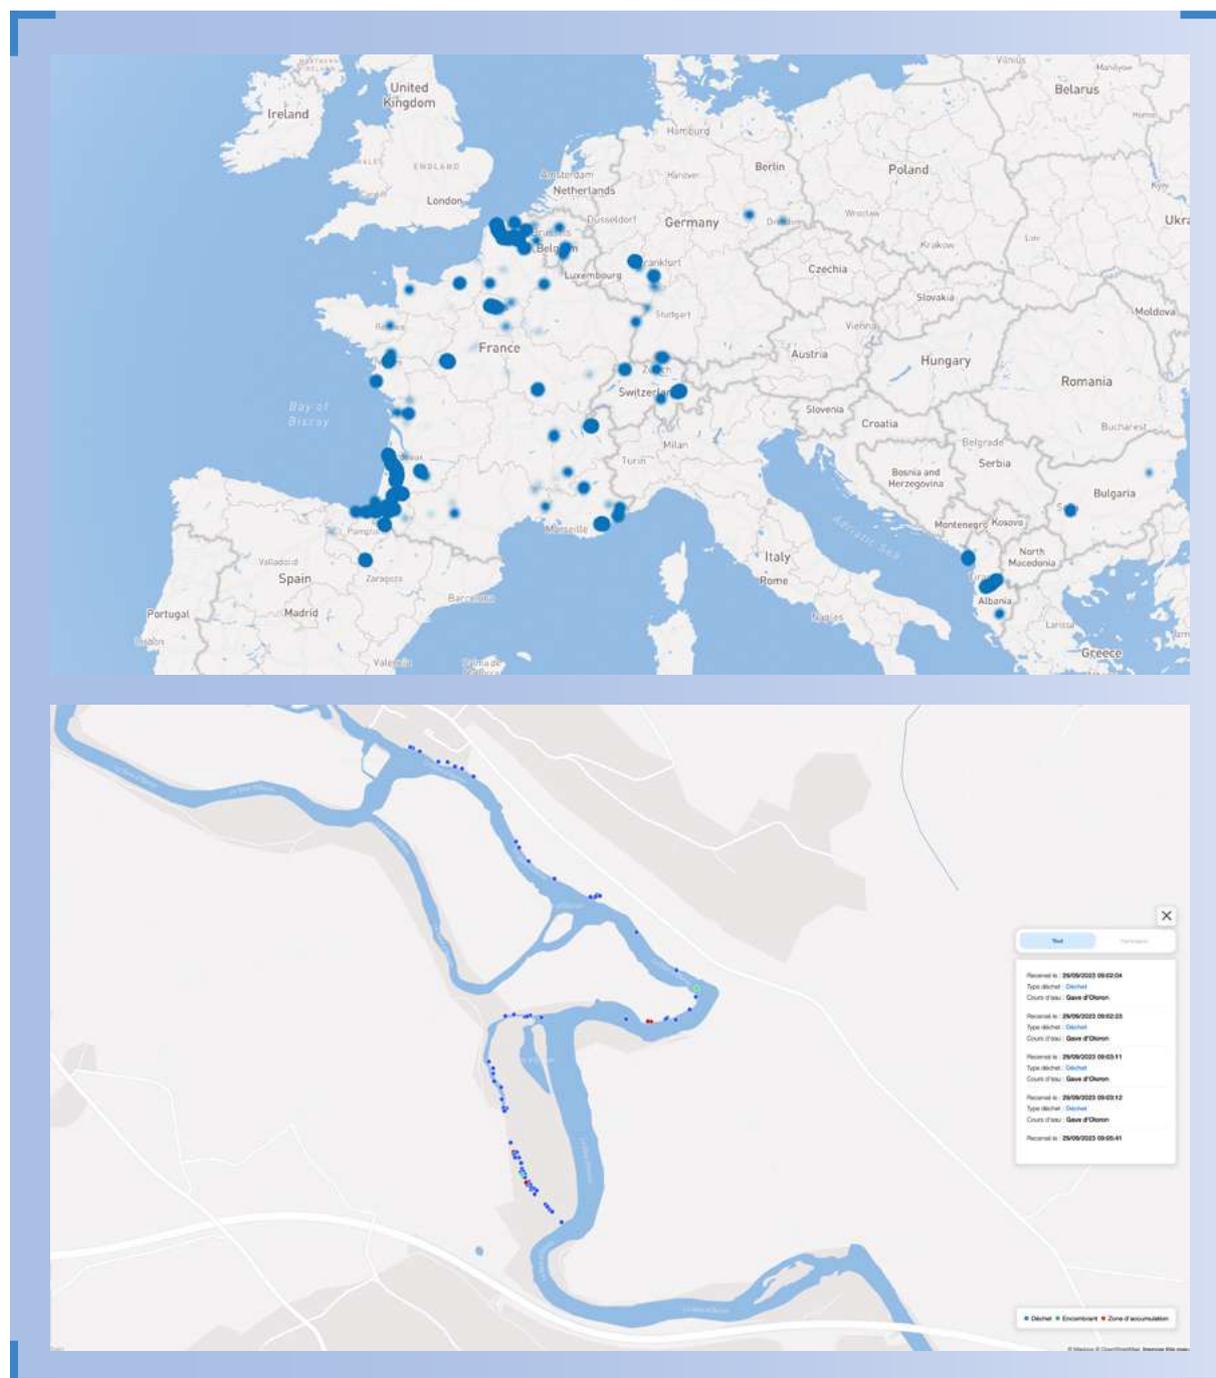


Figure 30 | En haut | Cartographie de chaleur des déchets signalés via l'application Plastic Origins | Figure 31 | Au milieu | Zoom sur le secteur de Sorde-l'Abbaye (40) qui montre la répartition des déchets le long du cours d'eau.

l'IA Frugale de l'AFNOR (AFNOR 2024) proposent déjà des bonnes pratiques pour prendre en considération ces problématiques. Dans le cadre du projet Plastic Origins, un certain nombre d'entre elles ont été appliquées à priori, 5 ans auparavant. Nous pouvons prendre pour exemple :

**L'acculturation des équipes à la frugalité de l'IA (BP14, dans le référentiel AFNOR) :** pour cela, nous avons d'abord échangé au sein de l'équipe projet sur la question de l'impact environnemental de la solution d'IA. Nous avons constaté que nous pouvions diminuer significativement la puissance de calcul en phase d'utilisation (inférence) de l'IA, pour les adapter à la réalité des besoins. Nous avons ensuite mis en place des évolutions de la plateforme pour mettre en œuvre des optimisations.

**La réutilisation d'algorithmes déjà entraînés (BP29) :** tous les algorithmes ou modèles d'IA que nous avons utilisés ont systématiquement déjà été entraînés au préalable, en général sur le jeu de données de référence de vision par ordinateur « Imagenet ». En conséquence, l'entraînement de nos modèles ne nécessitait que du "fine-tuning", qui permet d'obtenir de bonnes performances de détection plus rapidement, c'est à dire en diminuant le temps d'entraînement.

**L'optimisation de l'usage du matériel (BP20) :** dans un premier temps, nous avons basculé d'une IA opérant 24/7, à un mode asynchrone exécuté au maximum quelques heures le week end. Dans un second temps, nous avons démarré de la R&D pour

le déploiement de l'IA directement embarquée sur mobile afin d'étudier les possibilités de suppression des serveurs dédiés à l'IA dans le Cloud.

**L'anticipation de la fin de vie du projet IA (BP11) :** le caractère expérimental et de science participative du projet Plastic Origins nous a permis de nombreuses réalisations inscrites dans une réalité et un pragmatisme budgétaire. Afin de rendre le projet viable, nous avons également anticipé la question de sa durabilité et de son intérêt dans le temps. En conséquence, une fois la démonstration de nombreux résultats établis, nous sommes convenus d'une feuille de route permettant la réduction ou l'extinction de la plateforme numérique.

Au-delà des bonnes pratiques, ces efforts de normalisation permettent aussi d'identifier des outils pouvant fournir des indicateurs de frugalité des IA. Il existe maintenant, par exemple, le calculateur [www.green-algorithms.org](http://www.green-algorithms.org) ou le logiciel open source [codecarbon.io](http://codecarbon.io) pouvant estimer avant et pendant la conception, la consommation d'électricité et les émissions de CO<sub>2</sub> nécessaire à l'IA. Ainsi, de nouvelles approches pilotées par la frugalité pourraient voir le jour, où les concepteurs définissent par exemple la quantité d'énergie, les émissions de CO<sub>2</sub> et les quantités d'eau qu'ils sont prêts à utiliser au regard de la pertinence des problèmes résolus par l'IA.

A minima, une voie s'ouvre pour des IA plus respectueuses de l'environnement et pouvant s'inscrire dans un modèle sociétal de plus grande sobriété technologique.



Figure 32 | En haut | Déchets échoués sur les berges d'un cours d'eau, © Surfrider Foundation.

# 6 Perspectives et recommandations

**Les développements technologiques du projet Plastic Origins ont permis d'explorer la valeur de l'Intelligence Artificielle dans la collecte de données sur la pollution plastique dans les rivières.**

Parmi les réussites, le projet a permis la constitution d'un jeu de données unique sur les déchets plastiques dans les cours d'eau, ainsi qu'à la création de Surfnet, un modèle d'IA sur mesure. De plus, en adoptant des technologies TinyML, nous avons démontré qu'il est possible de développer une IA légère et frugale, réduisant ainsi les coûts d'infrastructure et l'impact environnemental. C'est pour nous une avancée importante dans l'optimisation des technologies IA pour des usages mobiles de plus en plus accessibles.

L'application mobile qui intègre cette IA a également démontré un bon potentiel pour transformer une activité comme le kayak en une action de science participative. La démarche a aidé à engager les citoyens dans la lutte contre la pollution plastique, tout en renforçant l'idée que des outils technologiques comme l'IA peuvent jouer un rôle dans l'écologie participative.

Cependant, le projet a aussi rencontré certaines limites, à la fois technologiques et humaines. Bien que l'IA ait permis d'automatiser la détection des déchets, ses performances restent perfectibles. La qualité des vidéos fournies par les bénévoles est importante, mais l'adoption du mode automatique par les bénévoles reste un défi. Les discussions avec les participants ont révélé une certaine réticence à déléguer entièrement l'observation à l'IA, notamment en raison de l'absence de retour en temps réel sur les résultats produits. La solution d'IA mobile pourrait potentiellement lever ce frein, mais elle nécessite des smartphones très récents pour fonctionner correctement, ce qui limite son accessibilité et la démocratisation du protocole de

science participative.

Le projet Plastic Origins devrait ainsi prendre fin en décembre 2025. Malgré ses bonnes performances, l'IA développée ne répond pas entièrement aux objectifs initiaux de diagnostic des cours d'eau. Le coût écologique de cette technologie, conjugué à des résultats mitigés, nous a conduit à nous interroger sur la pertinence de poursuivre dans cette direction, surtout lorsqu'un autre protocole s'installe peu à peu comme le cadre de surveillance des réseaux hydrographiques en Europe.

Nous sommes confiants que notre démarche nourrira des réflexions futures, et plusieurs enseignements peuvent être tirés pour inspirer d'autres initiatives :

→ [Encourager la science participative](#) en simplifiant les protocoles et en rendant les résultats en temps réel plus transparents, afin de favoriser une plus grande adhésion et d'améliorer la qualité des données collectées.

→ [Continuer à explorer les IA frugales](#) afin de réduire l'empreinte écologique des modèles tout en optimisant leur efficacité sur des appareils mobiles accessibles.

→ Enfin, [tout notre projet est mis à disposition en open data](#), ce qui permet à chacun de le tester et de l'adapter à ses propres objectifs. Cette approche ouverte et collaborative, rare dans les projets d'IA, favorise la transparence et encourage une réappropriation des outils pour une innovation plus durable.

# 7 Bibliographie

## AFNOR

«Référentiel général pour l'IA frugale - Mesurer et réduire l'impact environnemental de l'IA.» 2024.

## BRUGE, A., BARREAU, C., CARLOT, J., COLLIN, H., MORENO, C., MAISON, P

«Monitoring Litter Inputs from the Adour River (Southwest France) to the Marine Environment. » J. Mar. Sci. Eng., 2018.

## CHAGNEUX, M., LE CORFF, S., GLOAGUEN, P., OLLION, C., LEPÂTRE, O., AND BRUGE, A.

«Macrolitter Video Counting on Riverbanks Using State Space Models and Moving Cameras.» *Computo*, 2023.

## CRAWFORD, K.

«Generative AI's environmental costs are soaring - and mostly secret.» *Nature*, 2024.

## EMMERIK, T. AND SCHWARZ, A.

«Plastic Debris in Rivers.» *WIREs WATER*, 2020.

## EUROPEAN COMMISSION.

«IA Act : Regulatory framework proposal on artificial intelligence.» 2024.

## GALGANI, F.

«Les déchets marins.» 2016.

## GESAMP, JOINT GROUP OF EXPERTS ON THE SCIENTIFIC ASPECTS OF MARINE POLLUTION.

«Report of the 20th Session of GESAMP.» 1990.

## GONZÁLEZ, D. ET AL.

«Riverine Litter Monitoring – Options and Recommendations.» 2017.

## HANKE, G. ET AL.

«Guidance on Monitoring of Marine Litter in

European Seas - JRC.» Publications Office of the European Union, 2013.

## LE ROUX, C.

«Optimizing and running AI & Data: why Plastic Origins choose Azure Kubernetes Service and Airflow for sustainable operations.» *Médium*, 2023.

## LEPÂTRE, O.

«How can tech help address the issue of plastic pollution in rivers ?» *Medium*, 2023.

## META.

«Building Meta's GenAI Infrastructure.» *Meta Engineering Blog*, 2024.

## OFFICE FRANÇAIS POUR LA BIODIVERSITÉ.

Les rivières. s.d. [www.eaufrance.fr/les-rivieres](http://www.eaufrance.fr/les-rivieres)

## OLLION, C.

«Balancing Performance and Sustainability: How Plastic Origins chooses its AI solution for mobile devices.» *Medium*, 2023.

## OLLION, C.

«Small Scale Computer Vision in 2024.» *Medium*, 2023.

## TRAMOY, R., GASPERI, J., ET TASSIN, B.

«Plastoc : Indicateurs de la pollution en macrodéchets dans l'environnement et estimation des flux issus des eaux urbaines.» 2022.

## UNEP, MED WG.550/14.

«Guidelines for Monitoring Riverine inputs of Marine Litter.» 2023

# 8 Annexe

Exemples d'images selon les différentes catégories du jeu de données

## MATÉRIAU ISOLANT, POLYSTYRÈNE



## CONTENANT DE LIQUIDE TYPE BOUTEILLE



## CONTENANT DE LIQUIDE TYPE CANETTE



## BIDONS EN PLASTIQUE



**EMBALLAGE ALIMENTAIRE AUTRE QUE BOUTEILLE OU CANETTE**



**PNEUS**



**FILETS DE PÊCHE ET CORDES**



**DIVERS OBJETS FACILEMENT IDENTIFIABLES**



**DIVERS OBJETS NON IDENTIFIABLES**



**BÂCHE, SAC EN PLASTIQUE, FRAGMENTS**



[WWW.SURFRIDER.EU](http://WWW.SURFRIDER.EU)

