

الجمهورية الجزائرية الديمقراطية الشعبية
République algérienne démocratique et populaire
وزارة التعليم العالي والبحث العلمي
Ministère de l'enseignement supérieur et de la recherche scientifique
جامعة عين تموشنت بلحاج بوشعيب
Université –Ain Temouchent- Belhadj Bouchaib
Faculté Des Sciences et Technologie
Département Des Mathématiques et Informatique



Projet de Fin d'étude
Dans le cadre de l'arrêté ministériel 1275
« Un diplôme, une startup / micro entreprise ou brevet d'invention »
Pour l'obtention du diplôme de Master
Filière : Informatique
Spécialité : Cyber Sécurité & Intelligence Artificielle

Détection et Reconnaissance d'objets dans des Images
Sous-Marines Basée sur le Deep Learning pour Application
En Robotique – NeptuneNet -

Présenté Par :

1/ M. El hadj Mimoune Mourad
2/ M. Ghitri hamza

M2 Département Des Mathématiques et Informatique
M2 Département Des Mathématiques et Informatique

Devant le jury composé de :

Dr. BENOSMAN Mourad Mohammed	MCA	U.Ain Témouchent	Président
Mme SAIDI Samira	MAA	U.Ain Témouchent	Examinatrice
Dr. BELGRANA Fatima Zohra	MCA	U.Ain Témouchent	Encadrante
Dr. BEMMOUSSAT Chemseddine	MCA	U.Ain Témouchent	co-Encadrant
Dr GHERBI Sabah	MCA	U.Ain Témouchent	Représentant de l'incubateur
Mme FATMI Siham		Maison de l'environnement	Partenaire socioéconomique

Année Universitaire 2024/2025

Remerciement

Nous souhaitons avant tout exprimer notre profonde gratitude à **ALLAH**, le Tout-Puissant, pour Sa bienveillance, Sa grâce et Son soutien constant qui nous ont accompagnés et guidés tout au long de ce parcours.

Nous adressons nos remerciements les plus sincères à notre encadrante, **Dr F.Z.**

Belgrana, pour sa précieuse disponibilité, ses conseils avisés et son accompagnement tout au long de ce travail. Son expertise et son engagement ont largement contribué à la réalisation de ce mémoire.

Nous tenons à remercier notre **encadrant**, **Dr C. Bemmoussat**, pour son appui, ses encouragements et ses remarques constructives qui ont contribué à enrichir la qualité de notre étude.

Nos remerciements vont également à l'ensemble des membres du jury :

Dr. Benosman Mourad Mohammed, président du jury,

Mme Saidi Samira, examinatrice,

Dr Gherbi Sabah, représentant de l'incubateur,

Mme Fatmi Siham, partenaire socioéconomique.

Nos remerciements vont également à nos parents et à nos frères et sœurs, qui nous ont soutenus et encouragés tout au long de cette aventure.

Leur amour, leur soutien indéfectible et leurs encouragements constants ont été une source d'inspiration et de motivation.

Enfin, nous tenons à exprimer notre gratitude à tous ceux qui, de près ou de loin, ont contribué à notre projet et à notre réussite.

Qu'Allah vous bénisse tous.

Résumé

Dans le contexte de l'inspection sous-marine et de la surveillance environnementale, cette thèse présente notre projet de start-up « NeptuNet », un système basé sur l'apprentissage profond conçu pour l'identification automatique des fuites de gaz sous-marines par détection d'objets marqueurs.

Le système proposé offre deux solutions complémentaires : un modèle léger, YOLOv5n, adapté au déploiement en temps réel sur matériel embarqué, et un modèle de haute précision, Faster R-CNN avec la dorsale ResNet-50, destiné à l'analyse hors ligne.

Notre approche s'appuie sur l'utilisation de techniques de vision par ordinateur pour relever les défis posés par les images sous-marines, tels que le faible contraste et la turbidité. Les expériences ont porté sur la détection de conduites de gaz (pour l'aide à la navigation), de panaches de bulles pour l'identification de fuites actives et de bulles considérées comme un indicateur potentiel de fuite.

Enfin, le système a été déployé sous forme de plateforme web, permettant aux utilisateurs de tester les modèles de détection sur leurs propres images ou vidéos.

Mots-clés:

Vision par ordinateur, Traitement et analyse d'images sous-marines, Apprentissage profond(AP), YOLOv5n, Faster R-CNN, Détection de fuites de gaz, Détection d'objets sous-marins, Panaches de bulles, Tuyaux de gaz, Systèmes embarqués.

Abstract

In the context of underwater inspection and environmental monitoring, this thesis presents our start-up project “NeptuNet,” a deep learning-based system designed for the automatic identification of underwater gas leaks through marker object detection.

The proposed system offers two complementary solutions: a lightweight model, YOLOv5n, suitable for real-time deployment on embedded hardware, and a high-precision model, Faster R-CNN with ResNet-50 backbone, intended for offline analysis.

Our approach relies on using computer vision techniques to address the challenges posed by underwater images, such as low contrast and turbidity. The experiments focused on the detection of gas pipes (for navigation assistance), bubble plumes for identifying active leaks, and bubbles considered as a potential leak indicator.

Finally, the system was deployed as a web platform, allowing users to test the detection models on their own images or videos.

Keywords:

Computer Vision, Underwater Image Processing and Analysis, Deep Learning (DL), YOLOv5n, Faster R-CNN, Gas Leak Detection, Underwater Object Detection, Bubble Plumes, Gas Pipes, Embedded Systems.

ملخص

في سياق الكشف تحت الماء والرصد البيئي، تقدم هذه الأطروحة مشروعنا الناشئ "NeptuNet" وهو نظام قائم على التعلم العميق مصمم لتحديد تسربات الغاز تحت الماء تلقائياً من أجل الكشف عن الأجسام المعلقة. يقدم النظام المقترح حلين متكاملين : نموذج خفيف الوزن "YOLOv5n"، ونموذج "FASTER R-CNN" مع شبكة "ResNet-50" الأساسية.

يعتمد نهجنا على استخدام تقنيات الرؤية الحاسوبية لمواجهة التحديات التي تُشكلها الصور تحت الماء، مثل انخفاض التباين والعكارة. ركّزت التجارب على كشف أنابيب الغاز (للمساعدة في الملاحقة)، وأعمدة الفقاعات لتحديد التسربات النشطة، والفقاعات التي تُعتبر مؤشراً مُحتملاً للتسرب.

وأخيراً، تم نشر النظام كمنصة ويب، مما يسمح للمستخدمين لاختبار نماذج الكشف على صورهم ومقاطع الفيديو الخاصة بهم.

الكلمات المفتاحية:

رؤية الكمبيوتر، ومعالجة الصور تحت الماء وتحليلها، والتعلم العميق، FASTER R-CNN, YOLOv5n, كشف تسرب الغاز، كشف الأجسام تحت الماء، أعمدة الفقاعات، أنابيب الغاز، الأنظمة المدمجة.

Table des Matières

Table des Matières.....	8
Liste des figures.....	10
Introduction Générale.....	11
1. Contexte et Motivation.....	12
2. Objectifs du Projet "NeptuNet".....	12
3. Organisation du Mémoire.....	13
Chapitre I : Contexte Général et Fondements Technologiques.....	14
1.1. Introduction.....	15
1.2. Enjeux du secteur gazier algérien et de la surveillance des pipelines sous-marins.....	15
1.2.1 Importance stratégique et économique du gaz pour l'Algérie.....	15
1.2.2 Le réseau de pipelines sous-marins algérien : un atout critique.....	15
1.2.3 Intégrité et risques de défaillance des pipelines sous-marins.....	16
1.2.4 Surveillance et maintenance pour l'intégrité des pipelines.....	17
1.3. Technologies sous-marines pour l'inspection et la surveillance.....	18
1.3.1 Véhicules sous-marins.....	18
1.3.2 Capteurs embarqués pour l'inspection.....	18
1.4. Imagerie et traitement d'images en milieu sous-marin.....	20
1.4.1 Défis de l'imagerie sous-marine.....	20
1.4.2 Traitement d'images pour l'amélioration et l'analyse.....	20
1.5. Conclusion.....	21
Chapitre II : État de l'art sur l'Analyse d'images sous-marines.....	22
2.1. Introduction.....	23
2.2. Analyse d'images sous-marines : Approches traditionnelles.....	23
2.2.1 Restauration et amélioration d'images sous-marines.....	23
2.2.2 Extraction des caractéristiques et segmentation en milieu sous-marin.....	24
2.3. Apprentissage Profond pour l'analyse d'images sous-marines.....	25
2.3.1 Concepts clés et atouts.....	25
2.3.2 Applications en imagerie sous-marine.....	25
2.3.3 Défis spécifiques au Deep Learning en milieu sous-marin.....	29
2.4. Simulation robotique pour l'inspection sous-marine.....	29

2.4.1 Importance et avantages.....	30
2.4.2 Outils de simulation.....	30
2.4.3 Données synthétiques et "Sim-to-Real Gap"	30
2.4.4 Défis de la simulation.....	30
2.5. Conclusion.....	31
Chapitre III : Approches proposées et présentation du prototype.....	32
3.1 Introduction.....	33
3.2 Architecture Globale du Système "NeptuNet.....	33
3.2.1 Premier objectif : détection de fuite de gaz en temps réel(en ligne).....	33
3.2.2 Deuxième objectif : détection de fuite de gaz hors ligne.....	34
3.3 Approche proposée pour le processus de détection de fuites.....	34
3.3.1 Principe général.....	34
3.4 Modèles d'apprentissage profond adoptés.....	36
3.4.1 Première Approche adoptée via YOLO.....	36
3.4.2 Deuxième approche adoptée via Faster R-CNN.....	40
3.5 Simulation de NeptuNet.....	42
3.5.1 Outils et matériel utilisés.....	42
3.5.2 Présentation de notre prototype.....	45
3.7 Conclusion.....	51
Conclusion Générale et Perspectives.....	52
Références.....	54

Liste des figures

Figure 2.1 – Exemple de détection d'objets (pipeline, point de fuite) par le modèle YOLOv4[Gašparović et al., 2022].	27
Figure 2.2 – Exemple de détection d'objets (panaches de bulles, point de fuite) par le modèle YOLOv4[Zhu et al., 2021].	28
Figure 3. 1 – L'architecture globale du système NeptuNet.	34
Figure 3. 2 – Organigramme du système de surveillance sous-marin pour la détection de fuites de gaz basée sur l'analyse d'images par l'apprentissage profond	36
Figure 3. 3 – Architecture du modèle YOLOv5 [Jocher et al., 2020].	38
Figure 3. 4 – Architecture et principe de fonctionnement du modèle Faster R-CNN adopté dans Neptunet.	42
Figure 3. 5 – La page d'accueil publicitaire 1 de notre plate-forme Neptunet.	46
Figure 3. 6 – La page d'accueil publicitaire 2 de notre plate-forme Neptunet.	46
Figure 3. 7 – La page d'accueil publicitaire 3 de notre de notre plate-forme Neptunet.	47
Figure 3. 8 – La page d'accueil publicitaire 4 de notre plate-forme Neptunet.	47
Figure 3. 9 – La page de connexion de la plate-forme Neptunet.	48
Figure 3. 10 – Page d'inscription à la plate-forme Neptunet.	48
Figure 3. 11 – Interface du choix du modèle d'IA selon l'objectif souhaité, via notre plate-forme Neptunet.	49
Figure 3. 12 – Interface de test de nos modèles d'IA via Netpunet : sélection des paramètres	50
Figure 3. 13 – Interface de test de nos modèles d'IA via Netpunet : Affichage des résultats.	50

Introduction Générale

1. Contexte et Motivation

Le secteur des hydrocarbures, et en particulier celui du gaz naturel, revêt une importance économique et stratégique capitale pour l'Algérie. En tant que pilier de l'économie nationale, l'exploitation et le transport sécurisés de cette ressource sont primordiaux. Une part significative de cette infrastructure repose sur un réseau complexe de pipelines sous-marins, exposés à un environnement hostile et à des risques de défaillance. Les conséquences d'une fuite peuvent être graves : pertes économiques, risques sécuritaires et impacts environnementaux dévastateurs.

Face à ce constat, les méthodes traditionnelles d'inspection par plongeurs ou véhicules téléopérés (ROV) montrent leurs limites en termes de coût, de sécurité et d'efficacité. Elles restent souvent réactives et dépendantes d'opérateurs humains. Dans ce contexte, les avancées en intelligence artificielle, et plus spécifiquement en apprentissage profond (Deep Learning), ouvrent des perspectives radicalement nouvelles. Couplées à la robotique sous-marine, elles permettent d'envisager des systèmes d'inspection plus autonomes, plus rapides et capables de détecter les anomalies de manière précoce et automatisée. C'est dans cette dynamique que s'inscrit notre projet, visant à exploiter le potentiel du Deep Learning pour répondre au défi de la surveillance des pipelines sous-marins.

2. Objectifs du Projet "NeptuNet"

Ce projet vise à démontrer la faisabilité et la pertinence d'une solution d'inspection assistée par IA. Pour ce faire, notre démarche s'est articulée autour d'un double objectif stratégique :

1. **Valider une approche de haute précision pour l'analyse hors ligne** : Il s'agissait de développer et d'évaluer des modèles de détection performants, comme **Faster R-CNN**, capables d'analyser avec une fiabilité maximale les données visuelles collectées lors des inspections pour identifier le pipeline, les fuites de gaz (bulles) et d'autres anomalies.
2. **Explorer une approche légère pour un potentiel déploiement temps réel** : En parallèle, nous avons cherché à mettre en œuvre et à évaluer un modèle léger et rapide, en l'occurrence **YOLOv5-nano**, afin de mesurer son adéquation pour une future intégration sur des plateformes robotiques embarquées (AUV/ROV) aux ressources limitées.

Pour atteindre et démontrer ces objectifs, des sous-objectifs concrets ont été définis : la **conception d'une plateforme web interactive** (<https://neptunet.online/>) pour tester et visualiser les performances des modèles, ainsi qu'une **analyse conceptuelle de l'intégration** de ces modèles dans un environnement de simulation robotique (ROS2).

3. Organisation du Mémoire

Afin de présenter de manière claire et structurée notre démarche, ce mémoire s'articule autour des trois chapitres suivants :

- **Le premier chapitre** établira le contexte général de notre étude. Il abordera les enjeux liés au secteur gazier en Algérie et à la surveillance des pipelines, présentera les technologies sous-marines pertinentes et introduira les défis fondamentaux de l'imagerie en milieu aquatique.
- **Le deuxième chapitre** sera consacré à une revue de l'état de l'art. Il explorera les travaux existants en matière de vision par ordinateur et d'apprentissage profond pour l'analyse d'images sous-marines, tout en situant l'utilité de la simulation robotique dans ce domaine.
- **Le troisième chapitre** constituera le cœur de nos travaux pratiques. Il détaillera notre méthodologie, depuis la sélection des modèles (Faster R-CNN et YOLOv5-nano) jusqu'à la présentation de l'architecture et de la mise en œuvre de la plateforme « NeptuNet ».

Enfin, une **conclusion générale** synthétisera les contributions du projet, rappellera les résultats clés au regard des objectifs fixés, et ouvrira sur les perspectives de développement futur de notre solution.

Chapitre I : Contexte Général et Fondements Technologiques

1.1. Introduction

Ce premier chapitre a pour objectif de poser le cadre général de notre projet de fin d'étude, qui consiste en la détection de fuites de gaz dans les pipelines sous-marins. Nous commencerons par souligner l'importance du secteur gazier pour l'Algérie et les défis inhérents à la surveillance de ses infrastructures critiques, notamment les pipelines sous-marins. Par la suite, nous présenterons un panorama des technologies sous-marines actuellement employées ou en développement pour l'inspection de ces ouvrages. Enfin, nous présenterons quelques éléments clés de l'imagerie en milieu sous-marin et les principaux défis associés au traitement de ces images, dans le contexte de la détection d'objets révélateurs d'anomalies en lien avec notre objectif de détection de fuites de gaz.

1.2. Enjeux du secteur gazier algérien et de la surveillance des pipelines sous-marins

1.2.1 Importance stratégique et économique du gaz pour l'Algérie

L'Algérie figure parmi les principaux producteurs et exportateurs de gaz naturel à l'échelle mondiale, et cette ressource énergétique joue un rôle prépondérant dans son économie. Les revenus issus de l'exportation du gaz naturel contribuent de manière significative au budget de l'État et à la balance commerciale du pays [Benahmed, 2023; Observ'Algérie, 2025]. En 2025, l'Algérie maintient sa position de fournisseur clé pour 2023 les marchés européens, notamment grâce à son réseau de gazoducs transcontinentaux [Observ'Algérie, 2025]. Cette position confère à l'Algérie une influence notable sur le marché énergétique régional et international, mais implique également une grande responsabilité en termes de fiabilité et de sécurité d'approvisionnement. La pérennité de cette manne économique et de ce levier stratégique repose en grande partie sur l'intégrité et l'efficacité de ses infrastructures de production et de transport.

1.2.2 Le réseau de pipelines sous-marins algérien : un atout critique

Une part substantielle du gaz naturel algérien destiné à l'exportation, ainsi qu'une partie de sa production offshore, transite par un réseau complexe de pipelines. Plusieurs de ces conduites sont immergées en mer Méditerranée, reliant les champs de production algériens aux côtes européennes (Espagne et Italie principalement) ou aux terminaux de liquéfaction. Ces gazoducs sous-marins, tels que le Medgaz reliant Beni Saf à Almería ou le Trans-Mediterranean Pipeline

(Enrico Mattei) via la Tunisie vers l'Italie, représentent des artères vitales pour l'acheminement de l'énergie. Leur bon fonctionnement est donc crucial non seulement pour l'Algérie mais aussi pour la sécurité énergétique des pays importateurs. La profondeur à laquelle certains de ces pipelines sont posés (parfois plus de 2000 mètres pour le Medgaz) et leur longueur considérable en font des ouvrages d'art techniquement complexes et coûteux à installer et à maintenir [Benahmed, 2023].

1.2.3 Intégrité et risques de défaillance des pipelines sous-marins

Les pipelines sous-marins sont installés dans un environnement particulièrement agressif et sont sujets à divers types de risques pouvant compromettre leur intégrité [Express ShrinkWrapping, 2023].

a. Types de risques :

- **Corrosion** : L'eau de mer, par sa salinité, est un agent corrosif majeur pour les structures métalliques. La corrosion externe, et parfois interne (due à la composition du gaz transporté), peut entraîner une réduction de l'épaisseur de la paroi du pipeline et, à terme, des fuites ou des ruptures [Express ShrinkWrapping, 2023].
- **Dommages par des tiers** : Les activités humaines en mer, telles que la pêche (accrochage par des chaluts), le mouillage des navires (ancres traînantes), ou plus rarement des actes de malveillance, peuvent causer des dommages mécaniques directs aux pipelines (entailles, déformations, déplacements) [Express ShrinkWrapping, 2023].
- **Mouvements des fonds marins et instabilité géotechnique** : Les courants marins, l'activité sismique (particulièrement en Méditerranée), les glissements de terrain sous-marins ou la liquéfaction des sédiments peuvent exercer des contraintes importantes sur les pipelines, provoquer leur enfouissement excessif, leur déchaussement (free spans), ou leur rupture.
- **Défauts de fabrication ou d'installation** : Des imperfections dans les matériaux, les soudures, ou des erreurs lors de la pose peuvent constituer des points de faiblesse initiant des dégradations.

- **Usure naturelle** : Les cycles de pression et de température, les vibrations induites par le flux de gaz, et les contraintes hydrodynamiques contribuent à la fatigue des matériaux sur le long terme.

b. Conséquences des défaillances :

- **Pertes économiques** : Une fuite représente une perte directe de la ressource gazière. De plus, l'arrêt de l'exploitation pour réparation engendre des pertes de revenus considérables et peut entraîner des pénalités contractuelles. Les coûts de réparation eux-mêmes sont souvent très élevés en milieu sous-marin.
- **Risques sécuritaires** : Bien que le gaz naturel soit plus léger que l'air et tende à se dissiper rapidement, une fuite massive peut, dans certaines conditions (proximité d'installations de surface, zones confinées), présenter des risques d'inflammation ou d'explosion, menaçant la sécurité du personnel et des navires.
- **Impacts environnementaux** : Le gaz naturel est principalement composé de méthane (CH_4), un puissant gaz à effet de serre, bien plus réchauffant que le CO_2 à court et moyen terme. Les fuites contribuent donc directement au changement climatique [Greenly, 2022]. De plus, bien que le gaz naturel soit moins toxique que le pétrole en cas de déversement, une fuite importante peut perturber localement les écosystèmes marins. Les opérations de réparation peuvent également avoir un impact sur l'environnement [Parlement Européen, 2007].

1.2.4 Surveillance et maintenance pour l'intégrité des pipelines

Face à ces enjeux et ces risques, la surveillance continue et la maintenance préventive et corrective des pipelines sous-marins sont impératives. L'objectif est de garantir leur intégrité structurelle, d'assurer la sécurité des opérations, de minimiser les pertes économiques et de protéger l'environnement marin. Les méthodes d'inspection traditionnelles, bien qu'ayant évolué, présentent des limites en termes de coût, de fréquence, de sécurité et de capacité à fournir une image exhaustive et en temps réel de l'état des infrastructures [Benahmed, 2023]. Les défis sont d'autant plus grands pour les pipelines situés à grande profondeur ou sur de longues distances, comme c'est le cas pour une partie du réseau algérien. Cela justifie la recherche et le

développement de solutions d'inspection plus autonomes, plus efficaces et basées sur des technologies avancées telles que l'intelligence artificielle.

1.3. Technologies sous-marines pour l'inspection et la surveillance

L'inspection des pipelines sous-marins fait appel à un éventail de technologies, allant des interventions humaines directes (aujourd'hui limitées) à l'utilisation de systèmes robotisés sophistiqués équipés de divers capteurs.

1.3.1 Véhicules sous-marins

- **Plongeurs humaines** : Historiquement, les plongeurs ont joué un rôle dans l'inspection et la maintenance des structures sous-marines peu profondes. Cependant, leurs interventions sont limitées par la profondeur, la durée, les conditions environnementales et les risques inhérents. Pour les pipelines profonds, leur utilisation est prohibitive et dangereuse.

- **Véhicules Téléopérés (ROV - Remotely Operated Vehicles)** : Les ROVs sont des robots sous-marins non habités, pilotés depuis un navire de support via un câble ombilical qui fournit l'énergie et transmet les commandes et les données [Escadrone, s.d.-b]. Ils peuvent opérer à de grandes profondeurs et effectuer des travaux complexes, mais leur coût d'opération est élevé et ils dépendent du navire support.

- **Véhicules Autonomes Sous-marins (AUV - Autonomous Underwater Vehicles)** :

Les AUVs sont des robots capables d'opérer sans lien physique avec la surface, en suivant une mission préprogrammée [Chanthe, s.d.]. Ils sont particulièrement adaptés pour les tâches d'inspection sur de longues distances, offrant un coût d'opération potentiellement plus faible, mais leur autonomie est limitée et ils n'offrent généralement pas de capacité d'intervention en temps réel.

1.3.2 Capteurs embarqués pour l'inspection

Les véhicules sous-marins (ROV ou AUV) sont les porteurs d'une panoplie de capteurs destinés à recueillir des informations sur l'état du pipeline et de son environnement immédiat. Le choix et

la combinaison de ces capteurs dépendent des objectifs spécifiques de l'inspection, du type de pipeline, de l'environnement et des capacités du véhicule porteur.

- Capteurs acoustiques : Ils utilisent les ondes sonores pour "voir" dans l'eau. On y trouve les sonars à balayage latéral (SSS), les sondeurs multifaisceaux (MBES), les profileurs de sous-sol (SBP), les sonars à ouverture synthétique (SAS) et les sonars avant (FLS). Ils sont essentiels pour cartographier le fond marin, mesurer l'enfouissement ou les portées libres (free spans) et détecter des objets.
- Capteurs optiques : Fournissent une inspection visuelle directe, essentielle pour évaluer l'état de surface du pipeline.
 - Caméras vidéo (HD, 4K) : Elles fournissent des images en couleurs ou monochromes du pipeline, ce qui en fait l'outil principal pour l'inspection visuelle. L'analyse de ces images permet de détecter la corrosion, les fissures, les dommages mécaniques, l'état du revêtement, les anodes sacrificielles, les fuites (panaches de bulles), et les organismes marins encroûtants (biofouling)[1] [Escadrone, s.d.-a]. La qualité de la détection dépend bien sûr de la résolution du capteur, qu'il s'agisse de caméras HD/4K ou d'autres systèmes d'imagerie optique.
 - Caméras stéréoscopiques : Permettent des mesures dimensionnelles grâce à une perception de la profondeur.
 - Systèmes d'imagerie laser ligne (LSL) : Reconstituent un profil 3D très précis de la surface pour la métrologie fine des défauts.
- Autres capteurs spécialisés : Incluent les magnétomètres (localisation de pipelines enterrés), les capteurs de protection cathodique (mesure de la corrosion), les capteurs de détection de fuites (hydrophones, capteurs chimiques) et les capteurs de mesure d'épaisseur par ultrasons.

Notre projet se situe précisément à l'intersection de ces technologies. Dans un premier temps, nous nous basons sur les données acquises par les capteurs optiques (caméras vidéo HD), qui sont typiquement embarqués sur des Véhicules Téléopérés (ROV) lors des campagnes d'inspection du réseau gazier. L'objectif est de proposer une solution logicielle pour automatiser l'étape d'analyse des milliers d'heures de vidéo générées, qui se concentrera sur le traitement des images sous-marines afin d'y appliquer des modèles d'apprentissage profond pour la détection automatique d'anomalies. Dans un second temps, il sera question d'embarquer le programme sur le ROV pour un traitement en temps réel.

1.4. Imagerie et traitement d'images en milieu sous-marin

L'acquisition et l'interprétation d'images de qualité en milieu sous-marin représentent un défi majeur en raison des propriétés optiques de l'eau.

1.4.1 Défis de l'imagerie sous-marine

L'eau affecte profondément la propagation de la lumière, ce qui dégrade la qualité des images. Les principaux phénomènes sont l'absorption sélective de la lumière (créant une dominante bleu-vert), la diffusion de la lumière par les particules en suspension (provoquant flou et voile lumineux), la turbidité, la distorsion des couleurs et la perte de contraste [Lovibond, s.d.]. À cela s'ajoutent l'illumination non uniforme due à l'éclairage artificiel et le bruit des capteurs.

1.4.2 Traitement d'images pour l'amélioration et l'analyse

Face à ces dégradations, le traitement d'images joue un rôle crucial. Il comprend une chaîne d'opérations, allant de la phase d'acquisition, en passant par le prétraitement, puis la segmentation et la détection, jusqu'à l'interprétation.

- Prétraitement
 - ➔ Restauration et amélioration : vise à corriger les dégradations induites par le milieu aquatique. Cela inclut la correction colorimétrique, l'amélioration du contraste (par ex. CLAHE), la réduction du bruit (filtres médian, Gaussien), et des techniques de dévoilage (dehazing) pour réduire l'effet de brouillard.

- Rehaussement des contours : Cette étape vise à accentuer les bords et les détails fins dans une image, ce qui peut être particulièrement utile pour identifier les fissures ou les limites d'une zone de corrosion. Plusieurs filtres basés sur des opérateurs de dérivation peuvent être utilisés. Le filtre de Sobel et le filtre de Prewitt calculent une approximation du gradient de l'image pour détecter les contours. Le filtre Laplacien, un opérateur du second ordre, est très efficace pour trouver les zones de changement rapide d'intensité lumineuse mais est aussi plus sensible au bruit.
- Segmentation d'images : Consiste à partitionner une image en plusieurs régions ou segments, où chaque segment correspond à une entité d'intérêt (le pipeline, une anode, une zone de corrosion) [Seo & Kim, 2025]. C'est une étape clé avant la reconnaissance d'objets.
- Détection et reconnaissance d'objet : Cette phase vise à identifier et à localiser des objets spécifiques ou des zones présentant des anomalies (fuites, fissures, corrosion) [Seo & Kim, 2025]. Aujourd'hui, les réseaux de neurones convolutifs (CNN) et les architectures comme YOLO ou Faster R-CNN sont de plus en plus employés pour leur performance.

1.5. Conclusion

La surveillance des pipelines sous-marins est un enjeu stratégique majeur pour l'Algérie, confrontée à des risques économiques, sécuritaires et environnementaux importants. Les technologies d'inspection, bien que sophistiquées, s'appuient massivement sur des véhicules (ROV/AUV) et une panoplie de capteurs dont les données, notamment visuelles, nécessitent une analyse longue et coûteuse. Les défis inhérents au milieu aquatique dégradent la qualité des images, rendant l'automatisation de leur analyse complexe mais nécessaire. La maîtrise de ces aspects technologiques est donc fondamentale pour concevoir des systèmes d'inspection efficaces et fiables. Ce constat justifie notre orientation vers l'intelligence artificielle pour l'automatisation de l'analyse d'images. Cependant le chapitre suivant présente un état de l'art des méthodes de traitement d'image et d'apprentissage profond appliquées à la détection d'anomalies, qui constituent le cœur de notre approche.

Chapitre II : État de l'art sur l'Analyse d'images sous-marines

2.1. Introduction

Ce chapitre dresse un état de l'art des approches scientifiques et technologiques pour l'analyse d'images dans le contexte de l'inspection des pipelines sous-marins. Nous débuterons par un examen des méthodes dites "traditionnelles" de traitement d'image, développées pour la restauration visuelle et l'extraction de caractéristiques. Par la suite, nous aborderons le paradigme de l'Apprentissage Profond (AP ou DP pour *Deep Learning* en anglais), qui domine actuellement le domaine, en discutant de ses applications à l'amélioration d'image, la détection d'objets et la segmentation en milieu sous-marin. Enfin, nous analyserons le rôle crucial de la simulation robotique comme outil de développement, de validation et de génération de données pour l'entraînement de ces modèles d'intelligence artificielle, un aspect fondamental pour surmonter les défis du milieu sous-marin.

2.2. Analyse d'images sous-marines : Approches traditionnelles

Avant l'avènement massif des techniques d'apprentissage profond, de nombreuses méthodes d'analyse d'image "classiques" ont été développées pour surmonter les défis posés par l'environnement sous-marin. Ces approches se concentrent sur l'amélioration de la qualité visuelle et sur l'extraction de caractéristiques pour la détection et la segmentation d'objets.

2.2.1 Restauration et amélioration d'images sous-marines

Comme abordé dans le chapitre précédent, les images sous-marines souffrent de dégradations notables telles que l'absorption et la diffusion de la lumière, entraînant une distorsion des couleurs, une perte de contraste et un manque de netteté [Alsebai& Al-qaraawi, 2023;Alawode et al., 2024]. Les approches traditionnelles peuvent être classées en méthodes basées sur un modèle physique et méthodes indépendantes du modèle [Varghese& P, 2025].

Méthodes basées sur le modèle (physique) : Ces techniques tentent de modéliser le processus de formation de l'image sous-marine et d'inverser les effets de dégradation.

- Des adaptations du *Dark Channel Prior* (DCP), initialement conçu pour le désembuage des images terrestres, ont été proposées en exploitant le fait que la lumière rouge est plus atténuée pour estimer la profondeur de la scène [Drews et al., 2013].

- D'autres approches s'appuient sur des *a priori* statistiques, comme l'*Underwater Light Attenuation Prior* (ULAP) qui utilise l'analyse de l'intensité à travers les canaux de couleur pour estimer des cartes de profondeur [Varghese& P, 2025].
- Bien que efficaces, ces méthodes peinent souvent face à la complexité des scènes réelles où les *a priori* ne sont pas toujours vérifiés [Varghese& P, 2025].

Méthodes indépendantes du modèle (agnostic) : Ces approches opèrent directement sur les valeurs des pixels en utilisant des techniques de traitement d'image générales.

- Des techniques comme l'égalisation d'histogramme, notamment sa version adaptative **CLAHE** (*Contrast Limited Adaptive Histogram Equalization*), et des méthodes de correction des couleurs comme UCM (*Unsupervised Color Correction Method*) ont été largement utilisées [Varghese& P, 2025].
- Des variantes de l'algorithme Retinex, qui vise à séparer la réflectance de l'objet de l'illumination de la scène, ont également été explorées pour l'amélioration des images sous-marines [Zhang et al., 2017].
- Cependant, ces méthodes peuvent produire des résultats inconsistants, conduisant parfois à une sur-amélioration ou à l'introduction d'artefacts [Varghese& P, 2025].

2.2.2 Extraction des caractéristiques et segmentation en milieu sous-marin

L'extraction de caractéristiques pertinentes (contours, textures) et la segmentation (isoler le pipeline du fond marin) sont des étapes cruciales.

- Les méthodes traditionnelles comme le seuillage, la détection de contours (par ex., avec les opérateurs de Sobel, Canny) ou la transformée de Hough pour la détection de lignes ont été appliquées aux images sous-marines.
- Des algorithmes plus sophistiqués comme les "*level sets*" (ensembles de niveaux) ont été utilisés, intégrant des informations de région et de contour pour une segmentation plus robuste [Sun et al., 2020].

- Toutefois, la faible qualité des images et la complexité des scènes (occlusion, biofouling¹) rendent souvent ces méthodes peu robustes et nécessitent un ajustement manuel fastidieux des paramètres [Zhang et al., 2025].

2.3. Apprentissage Profond pour l'analyse d'images sous-marines

L'apprentissage profond (*Deep Learning*), et en particulier les réseaux de neurones convolutifs (CNN), a révolutionné la vision par ordinateur. Son application à l'analyse d'images sous-marines a ouvert de nouvelles perspectives prometteuses.

2.3.1 Concepts clés et atouts

Contrairement aux approches traditionnelles qui requièrent une conception manuelle de descripteurs de caractéristiques, les modèles d'apprentissage profond apprennent ces caractéristiques directement à partir des données brutes. Les travaux pionniers de chercheurs comme *Yann Le Cun* ont été fondamentaux dans l'établissement des bases théoriques et pratiques des réseaux de neurones convolutifs.

Les **Réseaux de Neurones Convolutifs (CNN)** sont l'architecture de choix pour le traitement d'image. Ils appliquent une série de filtres (convolutions) pour apprendre des caractéristiques hiérarchiques, des contours simples dans les premières couches aux formes complexes dans les couches profondes. Des architectures historiques comme LeNet, AlexNet, VGG, et plus récentes comme ResNet (qui a introduit les connexions résiduelles pour faciliter l'entraînement de réseaux très profonds) et Inception (GoogleNet), ont posé les bases des modèles actuels.

D'autres architectures existent, comme les **Réseaux de Neurones Récurrents (RNN)** et leurs variantes (LSTM, GRU), qui sont conçus pour traiter des données séquentielles. Bien que moins courants pour l'analyse d'image fixe, ils ont un potentiel pour l'analyse de séquences vidéo d'inspection, où la mémoire des trames précédentes peut aider à suivre un objet ou à confirmer une détection.

2.3.2 Applications en imagerie sous-marine

L'apprentissage profond est appliqué à diverses tâches essentielles pour l'inspection sous-marine.

¹ Biofouling (ou biosalissure) : Accumulation d'organismes marins (algues, coquillages, etc.) sur les surfaces immergées, ce qui peut masquer les caractéristiques d'un pipeline.

a. Amélioration et Restauration d'Images (UIE/UIR) :

L'**UIE** (*Underwater Image Enhancement*) vise l'amélioration subjective de la qualité visuelle, tandis que l'**UIR** (*Underwater Image Restoration*) tente de retrouver l'image "propre" en inversant un modèle de dégradation physique. Des architectures CNN, incluant des auto-encodeurs, des réseaux antagonistes génératifs (GAN), et des transformateurs de vision, sont utilisées pour traduire une image dégradée en une version améliorée [Varghese & P, 2025; Liu et al., 2024]. Par exemple, Uplavikar et al. [2019] ont proposé une méthode d'amélioration d'image sous-marine basée sur l'apprentissage par domaine-adversaire, cherchant à corriger simultanément les problèmes de couleur et de netteté.

b. Détection d'Objets Sous-marins :

La localisation et l'identification d'objets (pipelines, anodes, défauts) sont des tâches cruciales. Des architectures comme **Faster R-CNN** (en deux étapes) et surtout la famille **YOLO** (*You Only Look Once*) (en une étape) sont largement adaptées pour leur bon compromis vitesse/précision [Wang et al., 2025].

- **Travaux de Gašparović et al. [2022] sur la détection de pipelines :** Ce travail explore l'application de plusieurs architectures de *Deep Learning* pour la détection d'objets dans des images de pipelines sous-marins. Les auteurs ont comparé six détecteurs basés sur les CNN, incluant différentes versions de la famille **YOLO** (YOLOv4, YOLOv4-Tiny, CSP-YOLOv4, YOLOv4@Resnet, YOLOv4@DenseNet) et **Faster R-CNN**. Les modèles ont été entraînés et testés sur un jeu de données personnalisé comprenant 3021 images de pipelines sous-marins, annotées pour cinq catégories d'objets : pipeline, point de fuite (*leakage point*), poids en béton (*concreteweight*), matelas en béton (*concrete mat*), et raccord de tuyau (*pipe coupling*). Les résultats ont démontré la supériorité de **YOLOv4**, qui a atteint une mAP de 94.21% pour la détection d'objets sous-marins avec une capacité de détection en temps réel (25 FPS). YOLOv4-Tiny a également montré des performances élevées (mAP de 92.43%) avec une vitesse de traitement encore plus rapide (38 FPS), ce qui le rend adapté aux applications embarquées.




Figure 2.1 – Exemple de détection d'objets (pipeline, point de fuite) par le modèle YOLOv4[Gašparović et al., 2022].

- travaux de Zhu et al. [2023] Subsea Gas Leaks Monitoring: A Comparison of Two Approaches :** Zhu et al. (2023) ont proposé un cadre comparatif pour la détection des fuites de gaz sous-marines à l'aide de deux modèles de détection d'objets basés sur l'apprentissage profond : YOLOv4 et Faster R-CNN. Leur étude s'est concentrée sur des expériences en cuve contrôlée où des panaches de gaz sous-marins ont été simulés à différentes intensités de fuite (0,2 MPa, 0,4 MPa et 0,6 MPa). Les auteurs ont entraîné les deux modèles à classer et localiser les panaches de fuite, puis ont comparé leurs performances à l'aide de courbes ROC et de mesures d'aire sous la courbe (AUC). Leur travail s'est notamment caractérisé par une analyse détaillée du comportement du modèle sur plusieurs seuils de confiance, allant de 0,5 à 0,000001. Ils ont observé que Faster R-CNN obtient les meilleures performances de classification avec une AUC de 0,99368, tandis que YOLOv4 obtient une AUC plus faible de 0,95863, souvent sujette à de nombreuses fausses alarmes ou à des détections manquées selon le seuil. Cependant, leurs résultats ont montré qu'une détection de fuite significative avec un rappel élevé ne

pouvait être obtenue qu'à des seuils de confiance extrêmement bas (par exemple, 0,0001), ce qui peut poser des difficultés lors d'un déploiement en temps réel en raison du bruit élevé et de l'incertitude du modèle.




Figure 2.2 – Exemple de détection d'objets (panaches de bulles, point de fuite) par le modèle YOLOv4[Zhu et al., 2021].

- **Autres travaux sur la détection d'objets sous-marins :** De nombreux autres chercheurs ont appliqué et adapté les détecteurs basés sur le *Deep Learning* à divers problèmes sous-marins. Par exemple, Zhao, Wang, et Du [2020] ont utilisé YOLOv3 spécifiquement pour la détection de points de fuite et de pipelines sous-marins, atteignant 77.5% de précision pour les fuites et 93.67% pour les pipelines. Des variantes de YOLOv3 ont été utilisées pour la détection de poissons [Xu & Matzner, 2018; Sung et al., 2017; Raza & Hong, 2020; Asyraf et al., 2021], tandis que YOLOv4 a été appliqué à la détection d'animaux marins [Rosli et al., 2021], de cibles du concours URPC [Chen et al., 2021; Zhang et al., 2021], de déchets sous-marins [Tian et al., 2021], ou de granulés d'aliments non consommés en aquaculture [Hu et al., 2021]. Ces études illustrent la polyvalence et l'efficacité des architectures YOLO pour des tâches de détection en temps réel dans des environnements sous-marins complexes. Faster R-CNN a également été utilisé, par exemple pour la détection d'herbiers marins [Moniruzzaman et al., 2019].

c. Segmentation d'Images Sous-marines :

La segmentation sémantique (attribuer une classe à chaque pixel) et d'instance (distinguer chaque objet) sont vitales pour une compréhension fine de la scène. Des architectures comme **U-Net** (très populaire en imagerie médicale et au-delà) et ses variantes sont couramment utilisées pour

la segmentation sémantique. **Mask R-CNN** est une référence pour la segmentation d'instance, capable de détecter un objet et de générer son masque précis [Boillet et al., 2024 ; Wöllhaf et al., 2023].

- **Exemple de travail : Segmentation sémantique basée sur SegFormer amélioré [Zhang et al., 2025]** Ce travail se concentre sur l'amélioration de la segmentation sémantique des images sous-marines en utilisant une version modifiée de l'architecture SegFormer. La segmentation sémantique est essentielle pour délimiter précisément les objets d'intérêt (par exemple, le pipeline, les zones de corrosion ou de *biofouling*) du reste de l'environnement marin. Les auteurs ont adapté SegFormer pour mieux gérer les défis spécifiques du milieu sous-marin, tels que la dégradation de la qualité de l'image (faible contraste, distorsion des couleurs, diffusion). Ils ont mis en œuvre des mécanismes pour améliorer l'extraction de caractéristiques pertinentes et la fusion d'informations multimodales afin d'obtenir des masques de segmentation plus précis. Le modèle amélioré a démontré une robustesse accrue face aux variations d'éclairage et à la turbidité, permettant une meilleure identification des contours et des régions. Ces avancées sont cruciales pour les tâches d'inspection où la précision de la localisation des défauts est primordiale.

2.3.3 Défis spécifiques au Deep Learning en milieu sous-marin

L'application du *Deep Learning* est confrontée à plusieurs défis majeurs : la disponibilité limitée de grands jeux de données annotées (le principal frein), la dégradation inhérente des images, la grande variabilité des environnements qui complique la généralisation des modèles, et les exigences computationnelles pour un déploiement embarqué [Li et al., 2024 ; S-Logix, s.d.].

2.4. Simulation robotique pour l'inspection sous-marine

La simulation est un outil central pour développer et valider des systèmes robotiques sous-marins, où les opérations en mer sont coûteuses et risquées [Maia et al., 2025].

2.4.1 Importance et avantages

La simulation permet la réduction des coûts, la répétabilité des expériences, le développement accéléré, et surtout la génération de données synthétiques. C'est un avantage crucial pour l'IA, car elle peut produire de grandes quantités d'images avec des annotations parfaites (*groundtruth*), aidant à surmonter le manque de données réelles [Kim et al., 2024; Kim & Lee, 2024].

2.4.2 Outils de simulation

ROS (*Robot Operating System*) et **ROS2** sont les frameworks (*middleware*) incontournables qui lient les algorithmes au simulateur [Costanzi, 2025]. **Gazebo** est un simulateur 3D *open-source* très populaire dans la communauté ROS. Associé à des plugins comme UUV Simulator, il permet une simulation physique et hydrodynamique détaillée des véhicules sous-marins [Manhães et al., 2016]. Des simulateurs plus récents comme **Stonefish** [Cieślak, 2019] ou basés sur des moteurs de jeu comme **Unreal Engine** (par ex. UNav-Sim) offrent un rendu photoréaliste de plus en plus avancé, essentiel pour réduire le "*sim-to-real gap*".

2.4.3 Données synthétiques et "Sim-to-Real Gap"

Malgré les progrès, le transfert de modèles entraînés en simulation vers le monde réel reste un défi. Le "*sim-to-real gap*" (fossé entre le simulé et le réel) est dû aux inévitables différences de rendu des capteurs et de la physique. Des techniques comme la **randomisation de domaine** (varier les paramètres de la simulation) sont utilisées pour rendre les modèles plus robustes et améliorer ce transfert [Maia et al., 2025].

2.4.4 Défis de la simulation

Les principaux défis restent la fidélité de la simulation, notamment pour le rendu des capteurs acoustiques (avec des artefacts comme le speckle²) et optiques, et la complexité de modélisation de l'hydrodynamique [Lee et al., 2025].

²**Speckle (ou chatoiement)** : Artefact visuel granuleux caractéristique des images cohérentes (comme le sonar ou le laser), résultant d'interférences constructives et destructives des ondes réfléchies.

2.5. Conclusion

Cet état de l'art a mis en évidence une claire transition des approches traditionnelles de traitement d'image, souvent limitées par la complexité du milieu sous-marin, vers des solutions basées sur l'apprentissage profond. Les réseaux de neurones convolutifs, en particulier les architectures de type YOLO pour la détection et U-Net ou Mask R-CNN pour la segmentation, représentent l'état de l'art pour l'analyse automatisée des images d'inspection. Cependant, leur performance est intrinsèquement liée à la disponibilité de larges jeux de données annotées, qui fait cruellement défaut. La simulation robotique, grâce à des outils comme Gazebo et des frameworks comme ROS, s'impose comme une solution incontournable pour pallier ce manque via la génération de données synthétiques et pour valider les chaînes d'inspection complètes à moindre coût. Les défis majeurs restent la fidélité de la simulation et le transfert des modèles du monde virtuel au monde réel. En s'appuyant sur ces constats, le chapitre suivant présentera notre approche proposée, qui vise à développer et valider un modèle de détection d'anomalies en vue de localiser d'éventuelles fuites de gaz.

Chapitre III : Approches proposées et présentation du prototype

3.1 Introduction

L'objectif principal de notre projet est la détection d'anomalies dans des images sous-marines. Cependant, dans le cadre de notre startup, nous avons commencé par travailler sur la détection de fuites de gaz. Nous avons donc deux sous-objectifs : le premier consiste à récupérer les images sous-marines et à effectuer les traitements nécessaires afin de détecter les fuites grâce à une plate-forme en ligne que nous avons développée. Le second objectif porte sur le développement de solutions logicielles à embarquer directement sur le robot à savoir la capacité de calcul limitée, la mémoire restreinte, la consommation énergétique, ainsi que les contraintes liées à l'environnement sous-marin, comme la pression, l'étanchéité et l'absence de connectivité continue.

Nos deux principaux sous-objectifs s'inscrivent dans une approche de surveillance avancée basée sur la vision par ordinateur pour la détection de fuites de gaz sous-marins, en mettant l'accent à la fois sur l'analyse en temps réel et l'analyse hors ligne de haute précision. Pour cela, nous avons opté pour l'Apprentissage Profond(AP), une approche qui a largement fait ses preuves dans le traitement d'images. Afin de répondre aux spécificités de chacun de nos sous-objectifs, nous avons développé deux solutions de détection basées sur l'apprentissage profond : YOLOv5n, optimisée pour un déploiement en temps réel sur des systèmes embarqués, et Faster R-CNN, conçue pour une détection hors ligne de haute précision. Pour relever les défis visuels propres aux environnements sous-marins, une phase de prétraitement d'images a été intégrée au processus de détection, améliorant la visibilité des objets ainsi que les performances des modèles dans des conditions de turbidité et de faible contraste. Afin de valider notre approche et prouver son efficacité nous avons utilisé des mesure de performance tel que la précision (mAP), le rappel (Recall), et du temps d'inférence.

3.2 Architecture Globale du Système "NeptuNet

Dans le cadre de la création de notre startup NeptuNet, nous avons défini deux objectifs : un premier à court terme, qui a abouti à la réalisation d'un prototype, et un second à long terme, inscrit dans notre vision future, pour lequel les premiers tests du modèle de deep learning ont déjà été réalisés. Ces deux objectifs poursuivent un même but : la détection de fuites de gaz sur des objets sous-marins, grâce à l'identification d'objets marqueurs tels que les tuyaux de gaz, les bulles, ainsi que les micro-fissures ou zones de corrosion. Le programme est opérationnel ; la prochaine étape consiste à l'embarquer sur un robot pour une détection autonome et en temps réel.

3.2.1 Premier objectif : détection de fuite de gaz en temps réel(en ligne)

Il s'agit de permettre une détection rapide et embarquée sur un robot à l'aide du modèle YOLOv5n. Ce modèle léger est particulièrement adapté aux dispositifs à faible consommation comme le Jetson Nano, où la priorité est la vitesse d'inférence.

3.2.2 Deuxième objectif : détection de fuite de gaz hors ligne

Il est question ici de fournir une détection à haute précision via un modèle de DL à savoir le Faster R-CNN, utilisé sur des stations de travail puissantes et locales. Ce modèle plus complexe permet une meilleure localisation, au prix d'un temps d'inférence plus élevé.

La Figure 3.1 ci-dessous illustre l'architecture globale du système NeptuNet, montrant les étapes du flux de traitement pour les deux scénarios (en temps réel et hors ligne). Les deux branches partagent une phase commune de prétraitement, après quoi les données sont orientées vers le processus adapté au contexte (en ligne ou hors ligne).




Figure 3. 1 – L'architecture globale du système NeptuNet.

3.3 Approche proposée pour le processus de détection de fuites

3.3.1 Principe général

Notre approche de détection de fuite de gaz sous-marins suit une approche structurée en plusieurs étapes pour parvenir à de bonnes performances. Pour cela il est question de détecter trois catégories de cibles sous-marines : les tuyaux de gaz, les bulles et les panaches de gaz. Le processus de développement comprend quatre étapes principales :

- **Étape 1 : Construction des ensembles de données**

Nous avons d'abord collecté un grand nombre d'images contenant notre objet sous-marin ciblé, que nous avons ensuite réparties en trois ensembles : apprentissage, validation et test. Cette division a été effectuée pour chacun des types d'objets cibles, à savoir les tuyaux de gaz, les fuites de gaz et les bulles.

Les jeux de données d'images ont été extraits de sources en libre accès telles que roboflow universe [Web 1] en encore de base d'image disponible en ligne sur GitHub [Web 2]. En outre, le traitement de ces ensembles images à était réalisé à l'aide de logiciels libres, à savoir Yolo Label [Web 3] et l'outil d'étiquetage roboflow [Web 4], permettant ainsi leur annotation (la présence ou non d'un objet et les positions de localisation de l'objet).

- **Étape 2 : Développement de modèles de DL et transfert d'apprentissage**

Nous avons adopté deux architectures de détection d'objets : YOLOv5n et Faster R-CNN avec ResNet-50. Les deux modèles ont été initialisés à l'aide de poids pré-entraînés (transfer learning) puis affinés via nos ensembles de données. Un mécanisme de validation a été utilisé pour suivre les performances et préserver les poids des modèles les plus performants.

- **Étape 3 : Prétraitement et optimisation des performances**

Diverses opérations de prétraitement (par exemple, filtres, amélioration du contraste) ont été appliquées pour évaluer leur impact sur la précision et la vitesse du modèle. L'objectif était d'améliorer la clarté de l'image et de garantir une détection fiable dans des conditions sous-marines difficiles, notamment en présence de turbidité, de faible contraste et de luminosité réduite.

- **Étape 4 : Évaluation et sélection du modèle**

Après l'entraînement, les deux modèles ont été évalués à l'aide de mesures telles que la précision moyenne (mAP), et la vitesse d'inférence. Une analyse comparative a été réalisée pour évaluer le compromis entre les performances et l'efficacité de calcul, ce qui nous a permis de sélectionner le modèle le plus approprié pour un déploiement sous-marin en temps réel ou hors ligne.




Figure 3. 2 – Organigramme du système de surveillance sous-marin pour la détection de fuites de gaz basée sur l'analyse d'images par l'apprentissage profond

3.4 Modèles d'apprentissage profond adoptés

3.4.1 Première Approche adoptée via YOLO

1. Modèle YOLOv5

YOLOv5 [Jocher et al., 2020] est un framework de détection d'objets en une étape composé de trois composants principaux : la dorsale(Backbone), le col(Neck) et la tête(Head), comme illustré à la Figure 3.13.

La dorsale(Backbone) est responsable de l'extraction initiale des caractéristiques et s'appuie sur CSPDarknet³, conçu pour réduire la complexité de calcul tout en conservant de solides capacités d'apprentissage des caractéristiques. Un élément clé est la couche Focus, qui découpe l'image en zones afin de capturer efficacement les informations spatiales et de réduire la charge de traitement.

le col intègre des caractéristiques multi-échelles grâce à une combinaison de Feature Pyramid Network (FPN) (*réseau pyramidal de caractéristiques*) et d'un Path Aggregation Network (PANet) (*réseau d'agrégation de chemins*) modifié [Liu et al., 2018], améliorant ainsi la représentation des caractéristiques à toutes les échelles. De plus, un module Spatial Pyramid Pooling - Fast (SPPF) (*pooling pyramidal spatial – version rapide*) est utilisé pour élargir le champ réceptif et enrichir les caractéristiques sans compromettre la vitesse de traitement.

La tête effectue la classification des objets et la régression des boîtes englobantes. Elle divise l'image en une grille, où chaque cellule prédit des boîtes englobantes avec des scores de confiance associés. Pour éliminer les sorties redondantes, la suppression non maximale (Non-Maximum Suppression, NMS) est appliquée après la prédiction, garantissant ainsi la conservation des cadres de délimitation les plus précis [Redmon et al., 2016].

YOLOv5 est disponible en cinq variantes évolutives : Nano, Small, Medium, Large et X-Large, permettant aux utilisateurs d'équilibrer précision de détection et efficacité de calcul en fonction de leurs besoins spécifiques.

Parmi celles-ci, YOLOv5n (Nano) est particulièrement adapté aux environnements à ressources limitées, tels que les dispositifs embarqués et périphériques.

³ **CSPDarknet (Cross Stage Partial Darknet)** : variante optimisée du réseau Darknet, qui utilise la technique "Cross Stage Partial". permet de réduire la redondance, accélérer l'entraînement, et limiter les calculs.




Figure 3. 3 – Architecture du modèle YOLOv5 [Jocher et al., 2020].

2. YOLOv5n (Nano)

YOLOv5n [Jocher et al., 2020] est une version ultra-légère de YOLOv5, spécialement optimisée pour les applications temps réel sur des dispositifs basse consommation [Matić et al., 2023]. Tout en conservant la philosophie de conception de YOLO, il réduit la complexité de calcul en minimisant la profondeur et la largeur des couches convolutives et en réduisant le nombre total de paramètres.

Pour optimiser encore son efficacité, YOLOv5n utilise deux têtes de détection YOLO au lieu de trois, ce qui réduit considérablement le temps d'inférence tout en maintenant une précision satisfaisante. Malgré sa taille réduite, YOLOv5n conserve des performances compétitives grâce à des améliorations telles que :

Connexions CSP (Cross Stage Partial) : Cette technique permet de diviser les flux de données dans les blocs résiduels pour améliorer la réutilisation des caractéristiques et réduire les coûts de calcul, tout en conservant une bonne capacité d'extraction des caractéristiques.

Augmentation des données mosaïques (Mosaic Augmentation) : Une méthode d'augmentation qui combine quatre images en une seule pendant l'entraînement, ce qui enrichit

le contexte spatial, améliore la robustesse du modèle et permet de mieux détecter les objets dans différentes positions et échelles.

cette méthode a été appliquée à la fois à la formation du modèle de détection de tuyaux et à la formation à la détection de bulles

Fonctions d'activation améliorées : Utilisation de fonctions comme le SiLU (Sigmoid Linear Unit), qui favorisent une meilleure convergence lors de l'entraînement grâce à une dérivée plus lisse et continue, ce qui améliore la stabilité et la précision du modèle.

YOLOv5n a été sélectionné pour son compromis exceptionnel entre précision et coût de calcul, ce qui le rend parfaitement adapté aux robots sous-marins embarqués effectuant la détection de fuites en temps réel.

3. Fonction de perte

Toutes les versions de YOLOv5 (n, s, m, l, x) utilisent les mêmes fonctions de perte par défaut. YOLOv5 utilise une fonction de perte en plusieurs parties composée de trois éléments : la perte CIOU (Complete Intersection over Union ou ICoU pour Intersection complète sur union en français) pour la régression de la boîte englobante, la perte par entropie croisée binaire pour le score d'objectivité et la perte de classification pour la prédiction d'étiquettes. La perte CIOU améliore la localisation en prenant en compte le chevauchement, la distance et le rapport hauteur/largeur. Les pertes d'objectivité et de classification utilisent l'entropie croisée binaire pour pénaliser les prédictions incorrectes de présence d'objet et d'étiquettes.

La perte totale d'apprentissage est calculée comme la somme pondérée de ces composantes:

$$LOSS = L_{classification} + L_{confidence} + L_{CIOU} \quad (1)$$

$$L_{classification} = \sum_{i=0}^{s^2} l_i^{obj} \sum_{j=0}^B \left[\left(p_i(c) - \hat{p}_i(c) \right)^2 \right] \quad (2)$$

$$L_{confidence} = \sum_{i=0}^{s^2} \sum_{j=0}^B l_i^{obj} \left[\left(C_i - \hat{C}_i \right)^2 \right] + \lambda_{noobj} \sum_{i=0}^{s^2} \sum_{j=0}^B l_i^{noobj} \left[\left(C_i - \hat{C}_i \right)^2 \right] \quad (3)$$

Où $L_{classification}$, $L_{confidence}$, L_{CIOU} sont des hyperparamètres qui équilibrent la contribution de chaque terme de perte. Ces pondérations peuvent être ajustées en fonction des caractéristiques du jeu de données et des priorités de détection.

Pour $L_{classification}$:

- $p_i(c)$: probabilité réelle (vérité terrain) de la classe c dans la cellule i (1 si la classe c est présente, 0 sinon).
- $\hat{p}_i(c)$: probabilité prédite par le modèle de la classe c pour l'objet dans la cellule i .

Pour $L_{\text{confiance}}$:

- C_i : score de confiance réelle pour le cadre englobant de la cellule i (1 si elle contient un objet, 0 s'il s'agit d'un arrière-plan).
- $\hat{C}_i$: score de confiance prédit par le modèle (score d'objectivité) pour le cadre englobant de la cellule i .
- λ_{noobj} : hyperparamètre qui pondère la contribution de la partie « absence d'objet » à la perte de confiance. Ceci est important pour éviter que les nombreuses cases d'arrière-plan ne dominent la perte totale.

3.4.2 Deuxième approche adoptée via Faster R-CNN

1. Modèle Faster R-CNN

Faster R-CNN [Ren et al., 2015] est un framework de détection d'objets en deux étapes largement utilisé. Il allie précision de détection et efficacité de calcul, ce qui le rend adapté aux applications en temps réel. Son architecture se compose de trois composants principaux : un réseau convolutif pour l'extraction de caractéristiques, un Réseau de Propositions de Régions (RPN) pour la génération de régions d'objets candidates, et une tête de détection Fast R-CNN pour la classification finale des objets et la régression par boîte englobante, comme illustré à la Figure 3. 23.

Dans notre cas, nous avons utilisé **ResNet-50** comme réseau de base (*backbone*) pour l'extraction des caractéristiques. Ce backbone a été sélectionné pour son bon compromis entre profondeur, capacité de représentation et coût de calcul.

Le processus commence par ce réseau principal (ResNet-50), qui extrait des cartes de caractéristiques détaillées de l'image d'entrée. Ces cartes capturent les informations spatiales et sémantiques essentielles à la détection d'objets de tailles et d'apparences variées. Les caractéristiques extraites sont ensuite transmises au réseau de propositions de régions, un sous-réseau entièrement convolutif conçu pour générer efficacement des propositions d'objets. Le RPN glisse sur la carte de caractéristiques et génère un ensemble de cadres de délimitation (appelés ancres), chacun associé à un score d'objectivité et à des coordonnées précises. Cette

méthode remplace les algorithmes de recherche sélective coûteux en calcul utilisés dans les cadres précédents, accélérant considérablement l'étape de proposition de région.

Les régions proposées par le RPN sont ensuite affinées et classées par la tête Fast R-CNN. Une couche de regroupement de Régions d'intérêt extrait d'abord des vecteurs de caractéristiques de taille fixe de chaque région proposée, qui sont ensuite intégrés à des couches entièrement connectées. Ces couches effectuent deux tâches : la classification de l'objet au sein de la région et la régression des coordonnées pour affiner le cadre de délimitation. L'apprentissage du Faster R-CNN se déroule généralement en plusieurs étapes. Dans un premier temps, le RPN est entraîné à l'aide des caractéristiques du backbone pré-entraîné. Ensuite, la tête de détection Fast R-CNN est entraînée à l'aide des propositions générées par le RPN. Enfin, les modules RPN et Fast R-CNN sont fusionnés en une architecture unifiée partageant les couches convolutives, réduisant ainsi la redondance et améliorant la vitesse d'inférence.

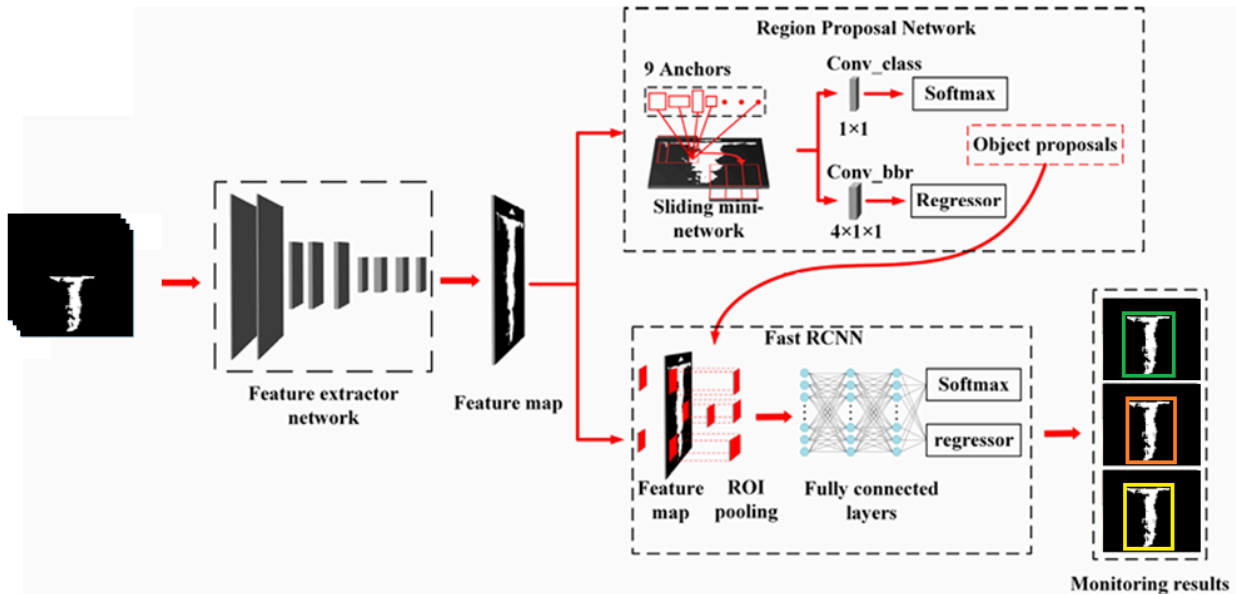


Figure 3. 4 – Architecture et principe de fonctionnement du modèle Faster R-CNN adopté dans Neptunet.

2) Fonction de perte

La fonction de perte du Faster R-CNN combine la perte de classification et la perte de régression de la boîte englobante, appliquée aux composantes RPN et Fast R-CNN. La perte de classification est calculée par entropie croisée softmax, tandis que la perte de régression utilise généralement la perte L1 lisse pour ajuster les coordonnées de la boîte englobante prédites. La perte totale est définie comme suit :

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (4)$$

Où L_{cls} est la perte de classification, L_{reg} la perte de régression et λ un facteur de pondération qui équilibre leurs contributions.

- $\{p_i\}$: Ensemble des probabilités prédites pour chaque boîte d'ancrage i . Ces probabilités indiquent si une ancre correspond à un objet (premier plan) ou à l'arrière-plan.
- $\{t_i\}$: Ensemble des décalages de régression de la boîte englobante prédits pour chaque boîte d'ancrage i . Ces décalages permettent de transformer la boîte d'ancrage par défaut en une boîte englobante d'objet plus précise.
- N_{cls} : Terme de normalisation de la perte de classification, représentant généralement la taille du mini-lot d'ancres utilisées pour la classification (par exemple, 256 pour RPN).
- N_{reg} : Terme de normalisation de la perte de régression, représentant souvent le nombre d'emplacements d'ancre (et non les ancres) sur la carte des caractéristiques, ou le nombre total d'ancres positives.

Cette formulation de perte multitâche permet au modèle d'optimiser conjointement la précision de détection et la précision de localisation.

3.5 Simulation de NeptuNet

3.5.1 Outils et matériel utilisés

1. Matériel utilisé

Le développement du système Neptunet a été réalisé en deux phases principales, chacune utilisant un environnement technique spécifique selon les besoins de calcul.

Nous avons utilisé un ordinateur portable personnel avec les caractéristiques suivantes :

- **Machine** : HP Notebook
- **Processeur** : AMD Ryzen 3 3200U CPU
- **Mémoire vive** : 8 Go de RAM

- **Carte graphique** : AMD Radeon Vega (intégrée)
- **Stockage**: 256 Go SSD + 512 Go HDD

2. La plate-forme Google Colab (Colaboratory)

L'entraînement des modèles YOLOv5n et Faster R-CNN a été effectué sur la plateforme Google Colab [Web 5], un environnement cloud basé sur Jupyter Notebook, proposé par Google. Cette plateforme offre un accès à des ressources de calcul accélérées (GPU/TPU) et comprend de nombreuses bibliothèques préinstallées comme PyTorch, TensorFlow, ou encore Torchvision, ce qui en fait un choix idéal pour les tâches d'apprentissage profond.

Nous avons utilisé la version payante de Google Colab Pro pour avoir accès à un GPU NVIDIA A100 avec 40 Go de mémoire VRAM, permettant un entraînement rapide et efficace. Les frameworks exploités étaient Ultralytics YOLOv5 pour YOLOv5n et Torchvision pour Faster R-CNN. L'environnement a permis de suivre et d'évaluer les performances des modèles en temps réel à l'aide des métriques standards telles que la précision (mAP), le rappel (Recall) et le temps d'inférence.

3. Langage utilisé (Python)

Python [Web 6] est le langage de programmation informatique le plus populaire et le plus utilisé, notamment dans le domaine de la data science et du machine learning. De plus, python est un langage open source, multiplateforme et orienté objet, qui fonctionne sur divers systèmes d'exploitation tels que windows, macOS et linux, ce qui en fait un choix idéal pour les développeurs travaillant sur différents environnements. Il dispose de structures de données de haut niveau interprétées (pas d'étape de compilation). Contrairement à HTML, CSS ou JavaScript, son usage n'est donc pas limité qu'au développement web. Il peut être utilisé pour tout type de programmation et de développement logiciel.

4. Les bibliothèques

Nous avons également eu recours à plusieurs bibliothèques afin de faciliter le développement, l'entraînement et l'évaluation de nos modèles à savoir :

- ➔ **PyTorch** : Ce cadre d'apprentissage profond open source a été le pilier de notre implémentation. Il a servi de base pour la construction, l'entraînement et l'évaluation de nos architectures YOLOv5n et Faster R-CNN, grâce à sa flexibilité et ses capacités de calcul tensoriel optimisées pour le GPU.
- ➔ **Ultralytics YOLOv5** : Pour l'implémentation du modèle **YOLOv5n**, nous nous sommes basés sur la référentielle open source d'Ultralytics. Ce référentiel fournit une architecture

pré-entraînée efficace et des scripts pour l'entraînement et l'inférence, facilitant l'optimisation pour les déploiements en temps réel.

- OpenCV (cv2) : La bibliothèque OpenCV était essentielle au traitement d'images et aux opérations d'augmentation de données. Elle était utilisée pour le chargement, le redimensionnement, le recadrage et la normalisation des images et, comme mentionné précédemment, pour les rotations appliquées aux images du jeu de données, ainsi que pour l'ajustement des coordonnées du cadre de délimitation.
- Numerical Python (Numpy)[] : Est une bibliothèque open source liée au langage python. Elle met à disposition des utilisateurs des tableaux multidimensionnels (ndarray), ainsi qu'une grande multitude de fonctions à effectuer des opérations mathématiques et statistiques. Numpy est principalement utilisé dans des domaines où des calculs numériques efficaces sont nécessaires tels que la science des données, l'apprentissage automatique, l'ingénierie ...etc.
- Matplotlib : Est une bibliothèque de Data Visualization en python, inspirée de Matlab et développée par John Hunter dans les années 2000. Le neurobiologiste cherchait un moyen de visualiser les signaux électriques du cerveau de patients épileptiques. Elle offre une grande flexibilité et permet de créer une variété de graphiques tels que des diagrammes en barres, des graphiques linéaires, des diagrammes circulaires, des nuages de points, etc.

5.Outil de développement de la plate- forme en ligne

Pour rendre notre système de détection accessible, nous avons développé une plateforme web interactive. Contrairement à la phase d'entraînement qui reposait sur des outils de science des données, le développement de cette plateforme a nécessité un ensemble de technologies web distinctes, capables de gérer les requêtes des utilisateurs, d'interagir avec les modèles d'IA et de présenter les résultats de manière claire.

L'architecture est scindée en deux services principaux : une application web construite avec le framework **Laravel (PHP)** qui gère l'interface utilisateur, et une API (Interface de Programmation Applicative) haute performance développée avec **FastAPI (Python)** qui sert les modèles de détection.

- ❖ **Framework Laravel** : Le cœur de notre application web a été développé avec Laravel 11, un framework utilisant le langage PHP. Il a été choisi comme socle principal pour sa robustesse et son écosystème complet. Son rôle a été de gérer l'authentification des utilisateurs, la gestion des sessions, le routage des pages, ainsi que de servir d'intermédiaire pour téléverser les fichiers vers notre service d'IA. Son moteur de template natif, **Blade**, a permis de construire les interfaces HTML de manière dynamique, et son ORM **Eloquent** a simplifié toutes les interactions avec la base de

données MySQL, rendant le développement rapide et structuré.

- ❖ **Framework FastAPI** : Pour le service d'intelligence artificielle, nous avons utilisé FastAPI. Ce micro-framework Python a été spécifiquement choisi pour ses **hautes performances** et sa capacité à gérer des requêtes de manière asynchrone, ce qui est crucial pour les tâches de calcul intensif. Il expose les modèles YOLOv5 via des points d'accès (endpoints) RESTful, reçoit les images et vidéos, et retourne les résultats après traitement. Pour son exécution, il s'appuie sur le serveur **Uvicorn**, un serveur ASGI (Asynchronous Server Gateway Interface) ultra-rapide qui exploite pleinement ses capacités de performance.
- ❖ **Technologies Frontend** : L'interface utilisateur a été conçue avec **Tailwind CSS**, un framework CSS de type "utility-first". Cette approche nous a offert une grande flexibilité pour créer rapidement une interface utilisateur moderne, personnalisée et entièrement responsive, sans être limité par un style prédéfini. La compilation et l'optimisation des fichiers CSS et JavaScript ont été gérées par **Vite.js**, un outil de build moderne intégré par défaut dans Laravel, garantissant une expérience de développement fluide et des temps de chargement rapides pour l'utilisateur final.
- ❖ **MySQL** : Un système de gestion de base de données relationnelle, choisi pour sa fiabilité et sa parfaite intégration avec Laravel. Il est utilisé pour stocker les informations des utilisateurs.
- ❖ **Visual Studio Code** : Un éditeur de code polyvalent et léger, qui, grâce à ses nombreuses extensions, a facilité le développement simultané des parties en PHP, Python et JavaScript.
- ❖ **Git & GitHub** : Ces outils ont été essentiels pour le suivi des modifications du code source, la collaboration et la sauvegarde du projet dans un dépôt distant.

3.5.2 Présentation de notre prototype

Dans le cadre de ce projet, nous avons développé un prototype fonctionnel sous la forme d'une plateforme ergonomique et simple d'usage qui permet aux utilisateurs de tester nos modèles d'IA spécialisés dans la détection d'objets sous-marins, que ce soit sur des images ou des vidéos. Nous allons présenter ci-dessous les différentes interfaces de notre plateforme.

a) La page d'accueil publicitaire : La page d'accueil de la plateforme **Neptunet** présente notre projet et nos objectifs. Elle met en avant les principales fonctionnalités et services proposés : détection d'objets sous-marins sur images et vidéos, amélioration des images par intelligence artificielle et vision d'avenir vers le développement de solutions robotiques autonomes. Elle offre un aperçu général des capacités de la plateforme, avec un menu pour naviguer entre les sections : *Services, Modèles IA, Vision, Contact, Connexion* et *Inscription*.




Figure 3. 5 – La page d'accueil publicitaire 1 de notre plate-forme NeptuneT.




Figure 3. 6 – La page d'accueil publicitaire 2 de notre plate-forme NeptuneT.




Figure 3. 7 – La page d'accueil publicitaire 3 de notre de notre plate-forme NeptuneT.




Figure 3. 8 – La page d'accueil publicitaire 4 de notre plate-forme NeptuneT.

b) Interface d'accès utilisateur : Cette section permet aux utilisateurs de créer un compte ou de se connecter pour accéder aux fonctionnalités de test des modèles. L'inscription peut se faire via un formulaire classique ou en utilisant un compte Google (Gmail). L'accès est sécurisé et obligatoire pour pouvoir charger des données et utiliser les modèles IA de la plateforme.


The image shows a login form titled "Log in to your account" for the Neptunet platform. At the top is the Neptunet logo. Below the title are two input fields: "Email" with the placeholder "your@email.com" and "Password" with a masked password "*****". There is a "Remember me" checkbox and a link "Forgot your password?". A dark blue "LOG IN" button is centered below these fields. Below the button is a separator line with the text "Or continue with". Underneath is a "Sign in with Google" button featuring the Google logo. At the bottom, there is a link "Don't have an account? Sign up".

Figure 3. 9 – La page de connexion de la plate-forme Neptunet.


The image shows a registration form titled "Create your account" for the Neptunet platform. At the top is the Neptunet logo. Below the title are four input fields: "Name" with the placeholder "Your full name", "Email" with the placeholder "your@email.com", "Password" with the placeholder "Choose a strong password", and "Confirm Password" with the placeholder "Confirm your password". There is a link "Already registered?" and a dark blue "REGISTER" button. Below these is a separator line with the text "Or register with". At the bottom is a "Sign up with Google" button featuring the Google logo.

Figure 3. 10 – Page d'inscription à la plate-forme Neptunet.

c) **Interface du choix du modèle :** Une fois connecté, l'utilisateur accède à un tableau de bord qui lui permet de sélectionner le modèle d'IA qu'il souhaite utiliser et tester. Plusieurs modèles sont proposés, chacun optimisé pour un type de détection spécifique.




Figure 3. 11 – Interface du choix du modèle d'IA selon l'objectif souhaité, via notre plate-forme Neptune.

d) **Espace de test des modèles :** Sur cette interface, l'utilisateur charge une image ou une vidéo et peut ajuster un seuil de confiance pour la détection (paramètre du DL). Après avoir lancé l'analyse, le système affiche les résultats sous forme de prévisualisation, avec les objets détectés et leurs localisations. L'interface reste simple et accessible pour permettre à tous de tester les performances des modèles sans connaissances techniques particulières.

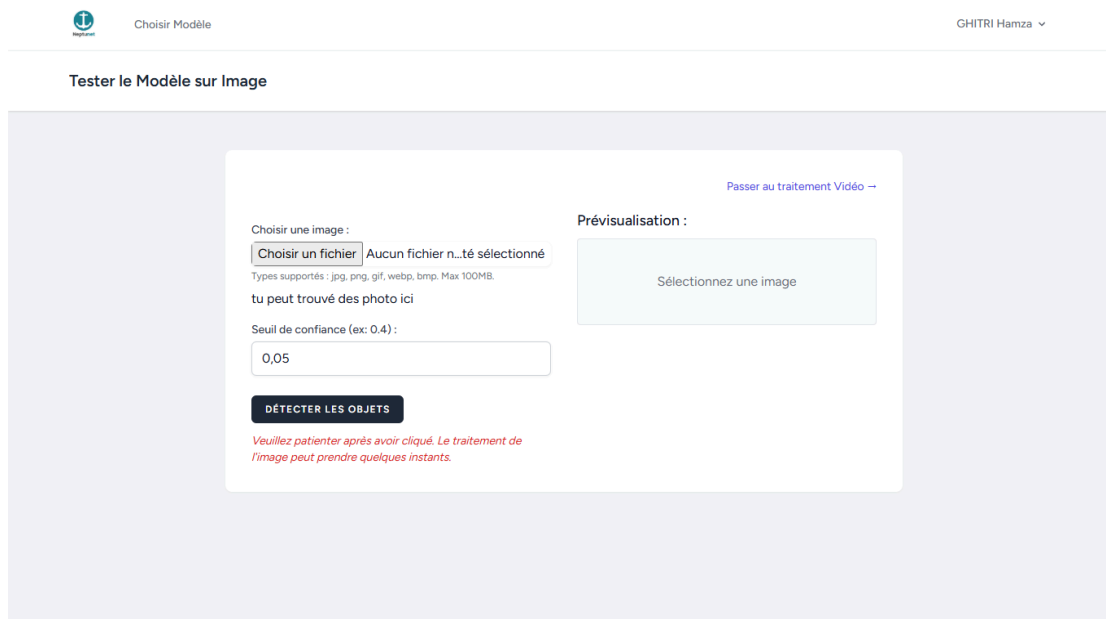


Figure 3. 12 – Interface de test de nos modèles d’IA via Netpunet : sélection des paramètres




Figure 3. 13 – Interface de test de nos modèles d’IA via Netpunet : Affichage des résultats.

3.7 Conclusion

Dans ce chapitre, nous avons présenté l'architecture du système NeptuNet et exposé ses deux principaux objectifs : un système de détection temps réel basé sur YOLOv5n, optimisé pour le déploiement sur plateformes embarquées, et un système hors ligne de haute précision basé sur Faster R-CNN avec ResNet-50, adapté aux analyses détaillées.

Nous avons également détaillé l'approche méthodologique proposée, utilisée tout au long du processus de développement du modèle, de la préparation des données aux stratégies d'apprentissage. Enfin, nous avons présenté la conception et le déploiement de notre prototype web, permettant aux utilisateurs finaux d'interagir directement avec les modèles de détection via une interface intuitive.

Conclusion Générale et Perspectives

Cette thèse, centrée sur la solution « NeptuNet », a démontré la pertinence et l'efficacité de l'apprentissage profond pour moderniser l'inspection des gazoducs sous-marins, une infrastructure critique pour l'Algérie. Les résultats obtenus posent les bases technologiques de notre projet de startup, qui vise à fournir des outils d'analyse d'images précis et rapides aux acteurs du secteur de l'énergie.

Notre approche a suivi un double objectif stratégique : d'une part, valider une solution de détection hors ligne garantissant une grande précision pour la post-analyse ; d'autre part, explorer le potentiel d'un modèle léger et performant, adapté à un futur déploiement temps réel sur des systèmes robotiques embarqués (AUV/ROV).

Pour y parvenir, nous avons développé et comparé deux approches distinctes : le modèle Faster R-CNN pour sa grande précision et YOLOv5-nano pour son excellent rapport vitesse/performance. Ces modèles ont démontré leur capacité à analyser des scènes complexes avec une grande fiabilité.

La mise en œuvre de ces travaux, via la plateforme de démonstration fonctionnelle NeptuNet, a permis de valider concrètement la viabilité de notre approche.

Ces résultats représentent une étape clé dans la feuille de route technologique de notre projet. Les perspectives de développement se concentrent désormais sur des axes clairs et stratégiques :

1. La mise en œuvre d'un banc de simulation (ROS 2/Gazebo) afin de préparer et de minimiser les risques liés au transfert de nos algorithmes vers des plateformes réelles (« sim-to-real »).
2. L'enrichissement continu de nos jeux de données en collaboration avec de futurs partenaires industriels afin d'améliorer encore la robustesse de nos modèles.
3. L'optimisation de nos algorithmes pour un déploiement efficace sur des plateformes matérielles embarquées à ressources limitées.

4. L'élargissement du spectre d'applications à d'autres problématiques sous-marines, telles que la détection de la corrosion, l'analyse des structures immergées et la surveillance de la biodiversité.

En conclusion, le projet NeptuNet a non seulement atteint ses objectifs académiques en apportant une contribution validée au domaine de l'inspection assistée par intelligence artificielle (IA) utilisant le traitement d'images et l'apprentissage profond, mais a également posé les bases d'une solution industrielle innovante conçue pour améliorer significativement la sécurité et la durabilité des infrastructures énergétiques critiques.

Comme pour tout projet de startup, une étude économique a été réalisée, incluant le Business Model Canvas (BMC), présenté en annexe.

Références

- **[Alsebai& Al-qaraawi, 2023]**Alsebai, M., & Al-qaraawi, A. (2023). Underwater Image Enhancement: A Review of Modern Utilized Concepts. *International Journal of Signal and Image Processing (IJSIP)*.
- **[Asyraf et al., 2021]**Asyraf, M. S., Isa, I. S., Marzuki, M. I. F., Sulaiman, S. N., & Hung, C. C. (2021). CNN-based YOLOv3 comparison for underwater object detection. *Journal of Electrical and Electronic Systems Research (JEESR)*, 18(APR2021), 30–37.
- **[Benahmed, 2023]**Benahmed, F. Z. (2023). *Contribution à la protection des installations industrielles par la mise en place d'un système de protection HIPPS*. Mémoire de Master, Université de Biskra. Archives Université de Biskra. Disponible sur [:http://archives.univ-biskra.dz/bitstream/123456789/12527/1/systeme_de_protection_HIPPS.pdf](http://archives.univ-biskra.dz/bitstream/123456789/12527/1/systeme_de_protection_HIPPS.pdf)
- **[Boillet et al., 2024]**Boillet, M., Goutal, T., & Vinson, S. (2024). Historical Text Line Segmentation Using Deep Learning Algorithms: Mask-RCNN against U-Net Networks. *Journal of Imaging*, 10(3), 65.
- **[Chanthe, s.d.]**Chanthe, E. (s.d.). *Les Sous-Marins Autonomes*. Rapport de recherche, LAAS-CNRS. Consulté le 11 juin 2025. Disponible sur [:https://homepages.laas.fr/echanthe/doc/TIPE_sousmarins_autonomes.pdf](https://homepages.laas.fr/echanthe/doc/TIPE_sousmarins_autonomes.pdf)
- **[Chen et al., 2021]** Chen, L., Zheng, M., Duan, S., Luo, W., & Yao, L. (2021). Underwater target recognition based on improved YOLOv4 neural network. *Electronics*, 10(14), 1634.
- **[Cieślak, 2019]**Cieślak, P. (2019). *Stonefish: An Advanced Open-Source Simulation Tool Designed for Marine Robotics, With a ROS Interface*. Proceedings of MTS/IEEE OCEANS 2019, Marseille, France.
- **[Costanzi, 2025]** Costanzi, D. (2025, Janvier). ROS middleware for underwater networks. *ROS Discourse*.
- **[Drews et al., 2013]** Drews, P., do Nascimento, E., Moraes, F., Botelho, S., & Campos, M. (2013). *Transmission estimation in underwater single images*. Proceedings of the IEEE International Conference on Computer Vision Workshops.
- **[Escadrone, s.d.-a]** Escadrone. (s.d.). *Comment optimiser les inspections sous-marines avec Deep Trekker*. Consulté le 11 juin 2025. Disponible sur [:https://escadrone.com/publication/comment_camera-4k-amelioree-optimise_les-inspections-sous-marines/](https://escadrone.com/publication/comment_camera-4k-amelioree-optimise_les-inspections-sous-marines/)
- **[Escadrone, s.d.-b]**Escadrone. (s.d.). *Inspections et réparations de pipelines avec un ROV*. Consulté le 11 juin 2025. Disponible sur [:https://escadrone.com/publication/inspections-reparations-pipelines-rov/](https://escadrone.com/publication/inspections-reparations-pipelines-rov/)

- **[Express Shrink Wrapping, 2023]** Express Shrink Wrapping. (2023, 3 mai). *L'étanchéité des pipelines sous-marins, un véritable défi*. Disponible sur <https://www.shrink-wrapping.express/letancheite-des-pipelines-en-quoi-les-gammes-pipeline-express-shrink-wrapping-aident-les-operateurs/>
- **[Gašparović et al., 2022]** Gašparović, B., Lerga, J., Mauša, G., & Ivašić-Kos, M. (2022). Deep Learning Approach For Objects Detection in Underwater Pipeline Images. *Applied Artificial Intelligence*, 36(1), 2146853. <https://doi.org/10.1080/08839514.2022.2146853>
- **[Greenly, 2022]** Greenly. (2022, 7 octobre). *Nord Stream : que faut-il savoir des fuites sur ces gazoducs ?* Disponible sur <https://greenly.earth/fr/blog/actualites-ecologie/nord-stream-que-faut-il-savoir-des-fuites-sur-les-gazoducs>
- **[Hu et al., 2021]** Hu, X., Liu, Y., Zhao, Z., Liu, J., Yang, X., Sun, C., Chen, S., Li, B., & Zhou, C. (2021). Real-time detection of uneaten feed pellets in underwater images for aquaculture using an improved YOLO-V4 network. *Computers and Electronics in Agriculture*, 185, 106135.
- **[Jocher et al., 2020]** Jocher, G., Chaurasia, A., Qiu, J., & Stoken, A. (2020). *YOLOv5 by Ultralytics* [Computer software]. GitHub. <https://github.com/ultralytics/yolov5> (Consulté le : 02 mars 2025)
- **[Kim & Lee, 2024]** Kim, J., & Lee, S. (2024). *Cycle-GAN-based synthetic sonar image generation for improved underwater classification*. Proc. SPIE 13061, Defense + Commercial Sensing 2024, 130610B.
- **[Kim et al., 2024]** Kim, J., Jang, G., & Kim, A. (2024). *Physics-Inspired Synthesized Underwater Image Dataset*. arXiv preprint arXiv:2404.03998.
- **[Lee et al., 2025]** Lee, J., Park, J., Kim, K., Shim, H., & Myung, H. (2025). Ray-Based Physical Modeling and Simulation of Multibeam Sonar for Underwater Robotics in ROS-Gazebo Framework. *Sensors*, 25(5), 1516.
- **[Li et al., 2024]** Li, J., Tang, S., & Li, L. (2024). Underwater object detection and datasets: a survey. *Intelligent Marine Technology and Systems*.
- **[Liu et al., 2018]** Liu, S., Qi, L., Qin, H., Shi, J., & Jia, J. (2018). *Path Aggregation Network for Instance Segmentation*. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 8759–8768). <https://doi.org/10.1109/CVPR.2018.00913>
- **[Liu et al., 2024]** Liu, Y., Lai, Y., Wu, Y., & Chen, Y. (2024). A review: underwater image enhancement based on deep learning. *Proc. SPIE 13257, International Conference on Advanced Image Processing Technology (AIPT 2024)*, 1325704.
- **[Lovibond, s.d.]** Lovibond. (s.d.). *Analyse de turbidité*. Consulté le 11 juin 2025. Disponible sur https://www.lovibond.com/usa-en/file-download/f146539_usa-en
- **[Maia et al., 2025]** Maia, M. M., Ferreira, H., Nogueira, B., Campos, M. F., & De Paula, M. (2025). *Underwater Robotic Simulators Review for Autonomous System Development*. arXiv preprint arXiv:2504.06245.
- **[Manhães et al., 2016]** Manhães, M. M. M., Scherer, S. A., Voss, M., Douat, L. R., & Rauschenbach, T. (2016). *UUV Simulator: A Gazebo-based package for underwater intervention and multi-robot simulation*. Proceedings of the OCEANS 2016 MTS/IEEE Monterey.

- **[Matić et al., 2023]** Matić, D., Kraguljac, M., & Anđelić, A. (2023). *Performance evaluation of YOLOv5 models for real-time object detection on embedded systems*. Journal of Computer and Communications, 11(4), 45–56. <https://doi.org/10.4236/jcc.2023.114004>
- **[Moniruzzaman et al., 2019]** Moniruzzaman, M., Islam, S. M. S., Lavery, P., & Bennamoun, M. (2019). *Faster r-cnn based deep learning for seagrass detection from underwater digital images*. 2019 Digital Image Computing: Techniques and Applications (DICTA), Perth, Australia, 1–7.
- **[Observ'Algérie, 2025]** Observ'Algérie. (2025, 22 avril). *Production de gaz naturel : voici le classement de l'Algérie en 2025*. Disponible sur : <https://observalgerie.com/2025/04/22/economie/production-de-gaz-naturel-voici-le-classement-d-e-lalgerie-en-2025/>
- **[Parlement Européen, 2007]** Parlement Européen. (2007). *Le projet de gazoduc Nord Stream: Questions d'environnement*. Disponible sur : [https://www.europarl.europa.eu/RegData/etudes/note/join/2007/393273/IPOL-PETI_NT\(2007\)3_93273_FR.pdf](https://www.europarl.europa.eu/RegData/etudes/note/join/2007/393273/IPOL-PETI_NT(2007)3_93273_FR.pdf)
- **[Qin et al., 2025]** Qin, J., Wang, R., Li, Y., Gao, Z., & Fan, S. (2025). Enhancing YOLOv8n with Multiple Attention and MRV Module for Efficient Deep-Sea Pipeline Target Detection. *Journal of Marine Science and Engineering*, 13(2), 267.
- **[Raza & Hong, 2020]** Raza, K., & Hong, S. (2020). Fast and accurate fish detection design with improved YOLO-v3 model and transfer learning. *International Journal of Advanced Computer Science and Applications*, 11(2), 7–16.
- **[Redmon et al., 2016]** Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once: Unified, Real-Time Object Detection*. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 779–788). <https://doi.org/10.1109/CVPR.2016.91>
- **[Ren et al., 2015]** Ren, S., He, K., Girshick, R., & Sun, J. (2015). *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*. In *Advances in Neural Information Processing Systems (NeurIPS)*, 28, 91–99. https://papers.nips.cc/paper_files/paper/2015/file/14bfa6bb14875e45bba028a21ed38046-Paper.pdf
- **[Rosli et al., 2021]** Rosli, M. S. A. B., Isa, I. S., Maruzuki, M. I. F., Sulaiman, S. N., & Ahmad, I. (2021). *Underwater animal detection using YOLOV4*. 2021 11th IEEE International Conference on Control System, Computing and Engineering (ICCSCE), Penang, Malaysia, 158–163.
- **[Seo & Kim, 2025]** Seo, J., & Kim, J. (2025). Effect of seabed type on image segmentation of an underwater object obtained from a side scan sonar using a deep learning approach. *Journal of Marine Science and Engineering*, 13(2), 242. <https://doi.org/10.3390/jmse13020242>
- **[S-Logix, s.d.]** S-Logix. (s.d.). *Research Topics in Underwater Image Processing using Deep Learning*. Consulté le 12 juin 2025. Disponible sur : [lien à vérifier]
- **[Song et al., 2020]** Song, H., Song, J., & Ren, P. (2020). Underwater Pipeline Oil Spill Detection Based on Structure of Root and Branch Cells. *Journal of Marine Science and Engineering*, 8(12), 1016. <https://doi.org/10.3390/jmse8121016>
- **[Sun et al., 2020]** Sun, Y., Chen, Z., Wang, H., Zhang, Z., & Shen, J. (2020). Level Set Underwater Image Segmentation Based on Region and Edge Features. *Journal of Image and Graphics*, 25(4), 824–835.

- **[Sung et al., 2017]** Sung, M., Yu, S.-C., & Girdhar, Y. (2017). *Vision based real-time fish detection using convolutional neural network*. OCEANS 2017-Aberdeen, 1–6.
- **[Tian et al., 2021]** Tian, M., Li, X., Kong, S., & Yu, J. (2021). *Pruning-Based YOLOv4 algorithm for underwater garbage detection*. 2021 40th Chinese Control Conference (CCC), Shanghai, China, 4008–4013.
- **[Uplavikar et al., 2019]** Uplavikar, P. M., Wu, Z., & Wang, Z. (2019). *All-in-One underwater image enhancement using domain-adversarial learning*. CVPR Workshops, Long Beach, USA, 1–8.
- **[Varghese & P, 2025]** Varghese, S. S., & P, M. A. (2025). *Underwater Image Restoration Through a Prior Guided Hybrid Sense Approach and Extensive Benchmark Analysis*. arXiv preprint arXiv:2501.02701.
- **[Wang et al., 2025]** Wang, Z., Sun, Z., Zhuang, Z., & Xu, D. (2025). Underwater object detection in sonar imagery with detection transformer and Zero-shot neural architecture search. *arXiv preprint arXiv:2505.06694*.
- [Web 1] <https://universe.roboflow.com/>
- [Web 2] <https://github.com>
- [Web 3] <https://github.com/heartexlabs/labelImg>
- [Web 4] <https://roboflow.com/annotate>
- [Web 5] <https://colab.research.google.com/>
- [Web 6] <https://www.python.org/>
- **[Wöllhaf et al., 2023]** Wöllhaf, M., O'Byrne, M., & O'Connor, N. E. (2023). *Using Mask R-CNN for Underwater Fish Instance Segmentation as Novel Objects: A Proof of Concept*. Conference Paper.
- **[Xu & Matzner, 2018]** Xu, W., & Matzner, S. (2018). *Underwater fish detection using deep learning for water power applications*. 2018 International conference on computational science and computational intelligence (CSCI), Las Vegas, USA, 313–318.
- **[Zhang et al., 2017]** Zhang, S., Wang, T., Dong, J., & Yu, H. (2017). *Underwater image enhancement via extended multi-scaleRetinex*. 2017 IEEE International Conference on Image Processing (ICIP).
- **[Zhang et al., 2021]** Zhang, M., Xu, S., Song, W., He, Q., & Wei, Q. (2021). Lightweight underwater object detection based on YOLO v4 and multi-scale attentional feature fusion. *RemoteSensing*, 13(22), 4706.
- **[Zhang et al., 2025]** Zhang, Y., Li, Y., Wu, X., & Zhu, Z. (2025). Semantic segmentation of underwater images based on the improved SegFormer. *Frontiers in Marine Science*.
- **[Zhao et al., 2020]** Zhao, X., Wang, X., & Du, Z. (2020). *Research on detection method for the leakage of underwater pipeline by YOLOv3*. 2020 IEEE International Conference on Mechatronics and Automation (ICMA), Beijing, China, 637–642.
- **[Zhu et al., 2021]** H. Zhu, W. Xie, J. Li, K. Wang, and G. Chen, "Advanced Computer Vision-Based Subsea Gas Leaks Monitoring: A Comparison of Two Approaches," in *2021 IEEE International Conference on Real-time Computing and Robotics (RCAR)*, Xining, China, 2021, pp. 995-1000. DOI: 10.1109/RCAR52367.2021.9517599.