



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE IBN KHALDOUN - TIARET

MEMOIRE

Présenté à :

FACULTÉ DES MATHÉMATIQUES ET D'INFORMATIQUE
DÉPARTEMENT D'INFORMATIQUE

Pour l'obtention du diplôme de :

MASTER

Spécialité : Génie informatique

Par :

BELBLIDIA Ridha EL Mouiz
KEITA Bakary

Sur le thème

**Utilisation Des Drones Pour La Détection Automatique
Des Feux de Forêt**

Soutenu publiquement le 11 / 06 / 2024 à Tiaret devant le jury composé de :

Mr BELARBI Mostefa	Professeur Dépt Informatique	Président
Mr ZIOUAL Tahar	MAA Dépt Informatique	Encadrant
Mr CHENINE Abdelkader	MAA Dépt Informatique	Examineur

2023-2024

Dédicaces

Nous dédions cet ouvrage

A nos parents, nos frères et nos sœurs qui nous ont soutenu et
encouragé durant ces années d'études.

Qu'ils trouvent ici le témoignage de notre profonde reconnaissance.

A notre encadreur, nos collègues et ceux qui ont partagé avec nous tous
les moments d'émotion lors de la réalisation de ce travail. Ils nous ont
chaleureusement supporté et encouragé tout au long de mon parcours.

A nos familles, nos proches et à ceux qui nous donnent de
l'encouragement et de la vivacité.

A tous les agents de sécurité et femmes de ménage de la faculté
Mathématique et Informatique.

A tous nos amis qui nous ont toujours encouragé, et à qui nous
souhaitons plus de succès.

Remerciements

Au-delà d'une aventure scientifique, le PFE est également une aventure humaine, avec ses contentements intenses mais aussi ses périodes de doute.

Nous ne manquons pas de dire un grand merci aux membres du jury qui ont accepté d'évaluer ce mémoire et de nous faire part de leurs remarques pertinentes qui contribueront au perfectionnement de ce modeste travail.

Nous tenons également à remercier vivement les enseignants de Techno Foster Incubator ainsi que toute personne que nous avons l'honneur de rencontrer pendant nos cours formatifs, de leur sympathie et leur gentillesse afin de mener à bien ce travail dans les meilleures conditions et dans une atmosphère harmonieuse.

Nous tenons à exprimer notre profonde gratitude à notre professeur encadreur Mr. ZIOUAL Tahar pour sa disponibilité, ses encouragements et son soutien autant scientifique que moral qui nous ont permis d'aller au bout de notre PFE, ainsi que pour tous ses conseils judicieux quant à nos orientations futures.

Nous remercions vivement tous les professeurs et enseignants de l'Université d'Ibn Khaldoun Tiaret, plus particulièrement ceux du département d'informatique, qui ont contribué à notre formation.

Nous aimerons remercier l'ensemble des personnes qui ont participé, de près ou de loin, à la réalisation de ce PFE.

Table des matières

<i>Dédicaces</i>	
<i>Remerciements</i>	
<i>Liste des figures</i>	
<i>Liste des tableaux</i>	
<i>Mots-clés</i>	
Introduction Générale	
CHAPITRE I : Détections de feux de forêt	1
I.1 Introduction	1
I.2 Détection de feux de forêt	1
I.2.1 Qu'es ce que la détection d'objets (feux de forêt)	1
a) Classificateur d'images	1
b) Localisation d'objet	1
I.3 L'image	3
I.3.1 Définition :	3
I.3.2 Traitement des images	3
I.3.3 Type des images	3
I.3.4 Acquisition d'une image :	3
I.3.5 Formats de fichiers image :	4
I.3.6 Applications	5
I.4 Intelligence artificielle	5
I.4.1 Apprentissage Automatique (Machine Learning)	5
A. Comment fonctionne l'apprentissage automatique ?	6
I.4.2 Apprentissage Profond (Deep Learning)	7
A. À quoi sert le Deep Learning ?	8
B. Réseaux de neurones	9
I.5 Conclusion	17
CHAPITRE II : Etat de l'art des algorithmes de détection d'objets	18
II.1 Introduction :	18
II.2 État de l'art sur les differents algorithmes de détection d'objets	18
II.2.1 R-CNN	18
A) R-CNN ou les CNN basé sur des Régions	19
B) Fast R-CNN	21

C) Faster R-CNN.....	23
II.2.2 YOLO détection (On ne Regarde qu'Une Fois)	26
A. YOLOv8	27
G. Récapitulation.....	35
II.2.3 SSD (Détecteur Single Shot).....	35
A) Architecture du modèle SSD.....	35
B) Comment fonctionne le SSD.....	37
C) Récapitulation.....	39
II.3 Comparaison entre les modèles de détection d'objets : R-CNN, YOLO et SSD	39
A) Comparaison des différents modèles	40
B) Comparaison en termes de performances.	40
II.4 Conclusion.....	41
<i>CHAPITRE III : Drones de surveillances</i>	42
III.1 Introduction	42
III.2 Les drones de surveillance.....	42
A) Caractéristiques de drone de surveillance (UAVs)	42
B) Les différents types de drone (UAVs).....	43
B.1 Drones à rotor unique	43
B.2 Drones multi rotors.....	44
B.3 Grands drones de combat	44
B.4 Grand drones de reconnaissance.....	45
B.5 Typhoon H480	45
III.3 Conclusion	48
<i>CHAPITRE IV : Simulation de drone pour la détection automatique des feux de forêt</i>	49
IV.1 Introduction.....	49
IV.2 Utilisation de drone pour la détection de feux de forêt.....	49
A) Système d'exploitation.....	49
B) Conception de drone	49
a) PX4 Autopilot	50
b) ROS.....	50
c) Gazebo	52
d) MAVSDK.....	52
C) Contrôle et pilotage de drone	52
a) QGROUNDCONTROL.....	53
D) Procédure de détection de feux de forêt :.....	53

a) Choix des algorithmes de détection	53
b) Détection des feux de forêt à travers l’algorithme YOLO	56
IV.3 Simulation complète	60
IV.4 Conclusion	60
V. Conclusion Générale	64
VI. L’Entreprenariat	65
VI.1 L’entrepreneur	65
VI.1.1 Le Business Model Canvas.....	65
A) Définition	65
B) Pourquoi l'utilisons-nous ?	66
C) Business Model	66
D) Outils indispensables pour BMC.....	67
BIBLIOGRAPHIE	70

Liste des figures

Figure I-1 : Feu de forêt	2
Figure I-2 : Détection de feux	2
Figure I-3 : Présentation des tâches liées à la reconnaissance d'objets [2]	2
Figure I-4 : Image [3]	3
Figure I-5 : Image numérique [3]	4
Figure I-6 : Numérisation [3]	4
Figure I-7 : Intelligence artificielle [4]	5
Figure I-8 : Apprentissage supervisé [6]	6
Figure I-9 : Apprentissage non supervisé [6]	7
Figure I-10 : Réseau multicouche [7]	8
Figure I-11 : Modèles linéaire et non-linéaire de neurones	8
Figure I-12 : Mise en correspondance neurone biologique / neurone artificiel [10]	9
Figure I-13 : Réseau multicouche [7]	9
Figure I-14 : Réseau [12]	10
Figure I-15 : Perceptron multicouche [13]	11
Figure I-16 : Apprentissage supervisé [14]	12
Figure I-17 : Perceptron [15]	12
Figure I-18 : Les réseaux de neurones récurrents [12]	13
Figure I-19 : CNN [18]	14
Figure I-20 : Perceptron multicouche [18]	15
Figure I-21 : Filtrage [19]	15
Figure I-22 : Couche Max Pooling [18]	16
Figure II-1 : R-CNN	19
Figure II-2 : Architecture de Fast R-CNN [39]	21
Figure II-3 : Fast R-CNN [40]	23
Figure II-4 : Architecture Faster R-CNN [39]	24
Figure II-5 : Faster R-CNN [43]	25
Figure II-6 : YOLO [22]	26
Figure II-7 : Détection des feux de forêt	27
Figure II-8 : Pose [26]	28
Figure II-9 : Segmentation [27]	28
Figure II-10 : YOLOv8[28]	30
Figure II-11 : Noyau [29]	31
Figure II-12 : Foulée[24]	32
Figure II-13 : Remplissage [24]	32
Figure II-14 : Détecteur Single Shot [45]	35
Figure II-15 : SSD détection [45]	36
Figure II-16 : VGG16 [46]	37
Figure II-17 : Structure du modèle de détecteur multibox à tir unique[47].	38
Figure II-18 : Processus de détection des caractéristiques de la cible du détecteur multibox à tir unique [47].	39
Figure III-1 : Drones à rotor unique [55]	44
Figure III-2 : Typhoon H480 [56]	44

Figure III-3 : Grands drones de combat[54].....	45
Figure III-4 : Grands Drones de reconnaissance [54]	45
Figure III-5 : Typhoon H480 [57]	45
Figure III-6 : Typhoon H480 [59]	47
Figure IV-1 : PX4 Autopilot.....	50
Figure IV-2 : ROS2 Humble.....	51
Figure IV-3 : Gazebo	52
Figure IV-4 : Gestion des véhicule.....	52
Figure IV-5 : QGROUNDCONTROL	53
Figure IV-6 : Graphe Précision.....	54
Figure IV-7 : Pourcentages.....	54
Figure IV-8 : Graphe de Précision.....	54
Figure IV-9 : SSD Détection de feux	55
Figure IV-10 : YOLO Détection de feux.....	55
Figure IV-11 : Environnement de travail.....	56
Figure IV-12 : Datasets à annoter.....	57
Figure IV-13 : Annotations.....	57
Figure IV-14 : Dataset	58
Figure IV-15 : Génération de Dataset.....	58
Figure IV-16 : Fichier YOLO.....	58
Figure IV-17 : Modèle de détection de feux.....	59
Figure IV-18 : Détection de feux.....	59
Figure IV-19 : Détection de feux de forêt	59
Figure IV-20 : Détection de feux de forêt	59
Figure IV-21 : Détection de feux de forêt	59
Figure IV-22 : Création de drone.....	60
Figure IV-23 : Déploiement de drone.....	60
Figure IV-24 : Contrôleur de vole	61
Figure IV-25 : Contrôleur de vole	61
Figure IV-26 : Simulation de drone.....	62
Figure IV-27 : Simulation de drone.....	62
Figure IV-28 : Simulation de drone.....	63
Figure V-1 : Start up	65

Liste des tableaux

Tableau I : Comparaison entre les algorithmes de détection.....	40
Tableau II : Etude comparative en terme temps d'exécution	40
Tableau III : Business Model Canvas.....	69

Résumé

Dans le cadre de ce travail, nous allons utiliser un drone pour la détection précoce de feux de forêt. Le drone est configuré pour réaliser une mission de reconnaissance d'incendie. Équipé de Caméra, le drone se chargera de collecter des données sur les feux de forêt. A travers une application implémentée, les données ainsi recueillies seront traitées et examinées grâce à des algorithmes d'intelligence artificielle (plus précisément grâce à un algorithmes de détections d'objets comme YOLO, SSD, RCNN) dans le but de repérer les flammes.

Mots-clés : Détection Automatique de Feux de Forêt, Drone, YOLO, SSD, R-CNN, Apprentissage Automatique

Abstract

As part of this work, we will use a drone for early detection of forest fires. The drone is configured to perform a fire reconnaissance mission. Equipped with Camera, the drone will collect data on forest fires. Through an application implemented the data thus collected will be processed and examined thanks to Artificial Intelligence (more precisely thanks to algorithms of detection of objects like YOLO, SSD, R-CNN) in order to locate the flames.

Keywords: Automatic Forest Fire Detection, Drone, YOLO, SSD, R-CNN, Machine Learning

ملخص

كجزء من هذا العمل، سوف نستخدم طائرة بدون طيار للكشف المبكر عن حرائق الغابات. تم تكوين الطائرة بدون طيار للقيام بمهمة استطلاع الحرائق. ستقوم الطائرة بدون طيار المجهزة بالكاميرا بجمع البيانات حول حرائق الغابات. من خلال تطبيق تم تنفيذه، ستتم معالجة البيانات التي تم جمعها وفحصها بفضل الذكاء الاصطناعي (بشكل أكثر دقة بفضل خوارزميات الكشف عن الكائنات مثل: YOLO ، SSD ، R-CNN) من أجل تحديد موقع النيران.

الكلمات الرئيسية: الكشف التلقائي عن حرائق الغابات، الطائرة بدون طيار، التعلم الآلي، YOLO ، SSD ، R-CNN

Introduction Générale

Au cours des dix dernières années, l'Algérie a été confrontée à une série de feux de forêt qui ont eu d'énormes conséquences. L'un des événements les plus récents s'est produit en juillet 2023, lorsque des incendies se sont déclarés dans le nord-est du pays, touchant 17 wilayas, ce qui a eu un impact dramatique sur la région et causant des dégâts considérables en pertes humaines et matérielles importantes, les incendies ont également contribué à l'aggravation de la sécheresse et de la désertification dans la région.

De ce fait la détection des incendies de forêt est un enjeu important pour assurer la sécurité de la population et lutter contre la sécheresse. Elle a pour but d'utiliser des technologies de pointe en apprentissage automatique et en apprentissage profond pour identifier et localiser les feux de forêt dans un flux d'image ou vidéo en temps réel.

En effet, les outils de technologie aéronautique jouent un rôle crucial dans la détection et la prévention des incendies, en particulier dans les vastes zones difficiles d'accès où les moyens terrestres peuvent être limités.

Chaque outil présente des avantages et des inconvénients en termes de coût, de fiabilité, de performance de couverture spatiale et de réactivité.

Les drones ont d'énormes particularités ce qui les rend spéciaux pour la détection de feux de forêt, équipés de Caméra et des capteurs ou des caméras thermiques infrarouge, les drones sont là pour collecter des données sur les incendies qui seront analysées et traitées grâce à l'intelligence artificielle et plus précisément grâce aux algorithmes de détections d'objets tel que YOLO, SSD et R-CNN pour identifier et localiser automatiquement les incendies, accélérant considérablement la détection.

Cette thèse est organisée en cinq chapitres principaux, chacun abordant différents aspects de l'utilisation des drones pour la détection automatique des feux de forêt. Voici un bref aperçu du contenu et de la structure de chaque chapitre :

- I. Détection des feux de forêt : Ce chapitre présente la détection des feux de forêt comme un aspect pratique du domaine de détection d'objets qui combine le domaine de traitement des images numériques avec certains domaines de l'intelligence artificielle.
- II. Etat de l'art des algorithmes de détection d'objets : Ce chapitre présente l'architecture de quelques fameux algorithmes de détection des objets (Famille des R-CNN, YOLO et SSD) et la comparaison entre leurs performances.

- III. Drones de surveillances : Ce chapitre donne un aperçu général du monde des drones, et présente le drone sur lequel on mènera des expériences expérimentales de détection d'incendies de forêt.
- IV. Simulation de drone pour la détection automatique des feux de forêt : Ce chapitre est un guide pour préparer l'environnement virtuel sur lequel on va faire la simulation du drone Typhoon H480 dans ça mission de faire des détections sur un terrain forestier, ainsi que montrer comment créer un Dataset pour entraîner YOLO et les procédures suivies pour faire l'entraînement.
- V. L'Entreprenariat : Ce chapitre additionnel est rédigé pour clarifier que notre projet remplit les conditions nécessaires pour qu'il soit un projet d'une entreprise innovante.

En plus de ces chapitres principaux, la thèse comprend des sections préliminaires telles que les dédicaces, les remerciements, la tables des matières, liste des figures, liste des tableaux, résumé, introduction générale et conclusion générale, ainsi que la bibliographie qui englobe les ouvrages que nous avons consulté ou référencé dans nos recherches.

CHAPITRE I : Détection des feux de forêt

I.1 Introduction

L'humanité tout entière fait face à des fléaux dévastateurs sous diverses formes : inondations, incendies de forêts, séismes et bien d'autres.

Les feux de forêts constituent l'un des principaux risques naturels des forêts dans le monde. Ils se déclenchent sans avertissement et se propagent avec une vitesse étonnante sur une étendue boisée causant d'énormes conséquences (perte des vies humaines, la dégradation de la faune et la flore, sécheresse). Pouvoir détecter les feux de forêts à l'avance grâce à l'intelligence artificielle est une étape cruciale pour limiter les dégâts atroces dont nous faisons face auparavant, et informer les personnes compétentes (comme les pompiers) pour contrôler les incendies aussitôt que possible.

I.2 Détection des feux de forêt

I.2.1 Qu'est-ce que la détection d'objets (feux de forêt)

Un détecteur d'objets est un dispositif ou un algorithme capable d'identifier la présence et l'emplacement d'un objet (feux de forêts) ou d'une classe d'objets dans une image ou un environnement. [1]

Les algorithmes de détection d'objets fonctionnent comme une combinaison de catégorisation d'images (classification) et de localisation d'objets. Il prend une image en entrée et génère une ou plusieurs cadres délimités dans l'image, avec l'étiquette de classe attachée à chaque cadre. Les algorithmes sont suffisamment puissants pour gérer la classification et la localisation multi-classes. [2]

a) Classificateur d'images

Dans le processus de classification d'images, une image est utilisée comme entrée et une étiquette de classification est générée en utilisant des métriques spécifiques telles que la probabilité, la perte, la précision, etc. [2]

Par exemple, il est probable qu'une photo de feux de forêt soit classée comme une étiquette de classe « Fire » ou qu'une photo de barbecue soit classée comme une étiquette de classe « Barbecue ». [2]

b) Localisation d'objet

Cet algorithme détecte la présence d'un objet dans une image et utilise un cadre de délimitation pour le représenter. Il reçoit une image et affiche l'emplacement du cadre de délimitation sous la forme de (position, hauteur et largeur). [2]

La combinaison de catégorisation (classification) d'images et de localisation d'objets (feux de forêt) conduit donc à la détection d'objet.



Figure I-1 : Feu de forêt



Figure I-2 : Détection de feux

Il existe de nombreux types de détecteurs d'objets :

- **La détection d'objet de vision par ordinateur :**

Elle utilise des réseaux de neurones profonds pour analyser des images numériques et identifier les objets qu'elles contiennent. Par exemple, on peut détecter des visages, des personnes, des animaux, des véhicules, etc.

- **La détection d'objet par capteurs :**

Elle utilise des dispositifs électroniques qui réagissent à des stimuli physiques, comme le son, la lumière, le champ magnétique, ...etc. Par exemple, on peut détecter des objets métalliques, transparents, liquides, solides, etc.

Remarque : La détection d'objets est un sous-ensemble de la reconnaissance d'objets, où l'objet est non seulement identifié mais également situé dans l'image.

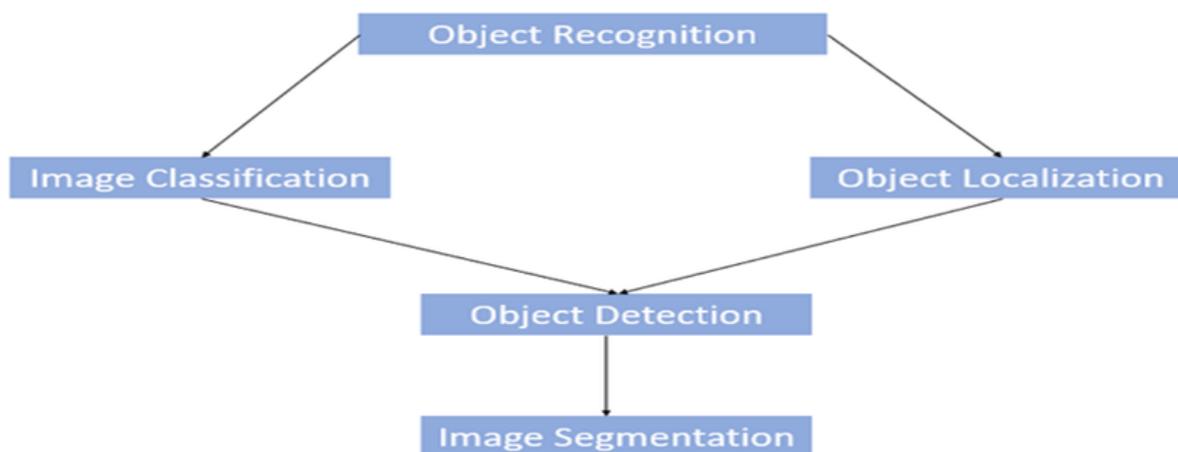


Figure I-3 : Présentation des tâches liées à la reconnaissance d'objets

I.3 L'image numérique

I.3.1 Définition :

Elle peut être décrite sous différents points de vue

- D'un point de vue mathématique : Une image est une matrice de nombres.
- D'un point de vue humain : Une image contient des informations sémantiques. Il faut interpréter le contenu au-delà de la valeur numérique. [3]

I.3.2 Traitement des images

Le traitement et l'analyse des images numériques est un domaine de l'informatique et des mathématiques appliquées qui étudie les images numériques et leurs transformations dans le but d'améliorer leur qualité ou d'en extraire des informations.

Le terme image numérique, dans son sens le plus général, fait référence à une image qui est capturée, traitée et stockée sous une forme codée qui peut être représentée par un nombre (matrice). [3]

I.3.3 Type des images

En réalité il existe, (03) trois principaux types d'images



Images en niveaux de gris
 $I(x,y) \in [0..255]$



Images binaires
 $I(x,y) \in \{0, 1\}$



Images couleurs
 $I_R(x,y) ; I_G(x,y) ; I_B(x,y)$

Figure I-4 : Image [3]

I.3.4 Acquisition d'une image :

La figure suivante montre une capture d'image numérique :

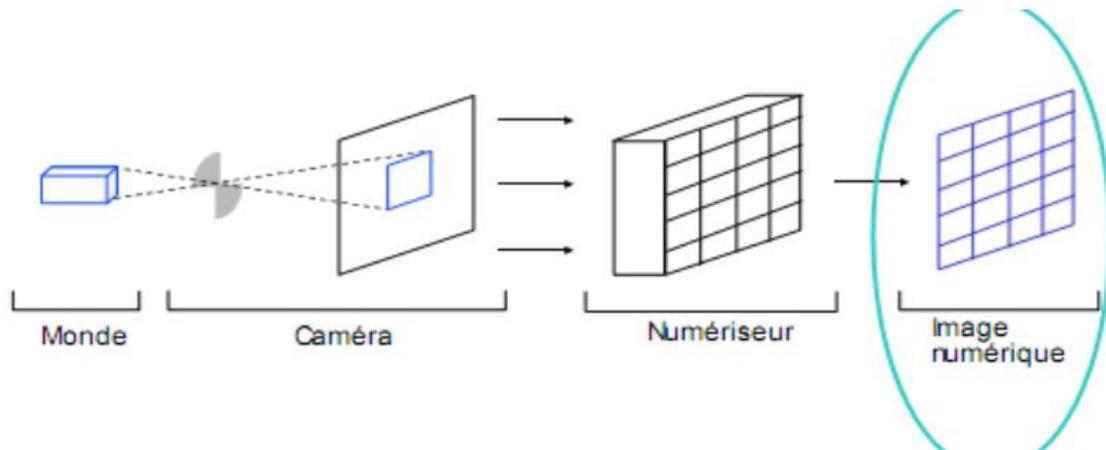


Figure I-5 : Image numérique [3]

Le Numérateur est constitué de Deux procédés essentiels qui sont : L'Échantillonnage et la Quantification. [3]

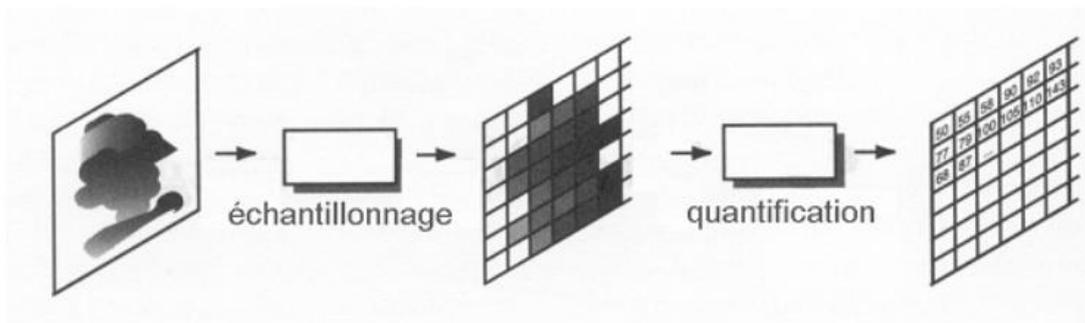


Figure I-6 : Numérisation [3]

a) Échantillonnage :

Il s'agit là de prélever sur un signal continu des valeurs à des instants donnés, c'est-à-dire lorsque travailler avec des images, il faut les convertir du format continu (analogique) au format discret (numérique).

b) Quantification :

La quantification attribue une valeur numérique à chaque échantillon prélevé.

I.3.5 Formats de fichiers image :

Il existe de nombreux formats de fichiers pour enregistrer des images numériquement : TIF, GIF, JPEG, PNG, PPM, PGM, BMP. [3]

I.3.6 Applications

Les applications du traitement d'images sont multiples :

- Domaine militaire : guidage de missile ;
- Imagerie médicale : aide au diagnostic, reconstruction 3D ;
- Télédétection : météo, astronomie ;
- Robotique : véhicules autonomes ;
- Sécurité : détection d'objet, d'empreintes digitales. [4]

I.4 Intelligence Artificielle

C'est un domaine qui a complètement révolutionné le monde. L'IA permet à la machine d'imiter certains aspects de l'intelligence humaine comme la perception (objet sur l'image ou vidéo), la résolution de problème (le plus court chemin avec Maps, le traitement des données gigantesque, les calculs poussée), l'interaction linguistique ou même la créativité.

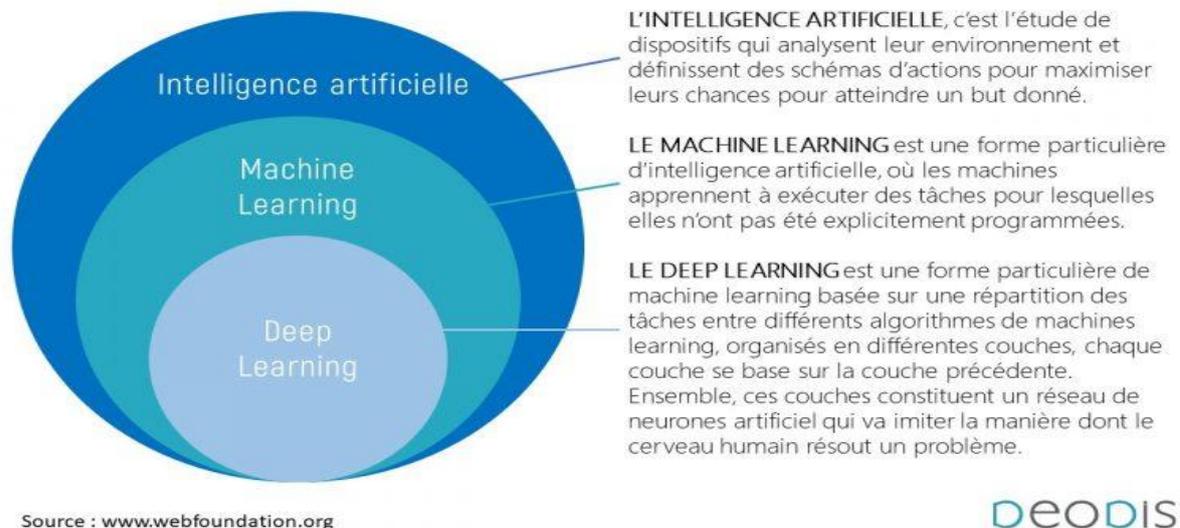


Figure I-7 : Intelligence artificielle [4]

I.4.1 Apprentissage Automatique (Machine Learning)

L'apprentissage automatique est le processus consistant à collecter un grand nombre de données (d'exemples) pour identifier des modèles, puis utiliser ses exemples pour faire des prédictions sur de nouveaux exemples. En termes simples, l'apprentissage automatique est une forme d'intelligence artificielle basée sur des concepts mathématiques et statistiques qui permet aux ordinateurs d'apprendre à partir de données plutôt que d'utiliser une programmation explicite.

A. Comment fonctionne l'apprentissage automatique

En général, l'apprentissage automatique se compose de 2 phases :

- La première phase est la conception du système, qu'on appelle aussi phase d'apprentissage ou d'entraînement. Dans cette phase, nous procédons à l'estimation d'un modèle à partir de l'analyse des données. Cela comprend une estimation d'une densité de probabilité ou la résolution d'une tâche pratique comme la traduction d'un discours.
- La seconde phase est une mise en production. Il est possible que des systèmes continuent leur apprentissage même en étant déjà en production. Après la détermination du modèle, on teste la seconde partie de données utile pour la réalisation de la tâche désirée. [5]

La reconnaissance visuelle est l'exemple le plus commun d'application du Machine Learning.

Le Machine Learning est un ensemble de techniques donnant la capacité aux machines d'apprendre. On distingue toutefois trois méthodes d'apprentissage :

A.1 Dans l'apprentissage supervisé

Ces algorithmes d'apprentissage automatique fonctionnent sur le principe selon lequel la machine dispose des connaissances préalables de ce que devraient être les valeurs de sortie du modèle. L'algorithme pourra donc étudier ces exemples, les comprendre, et ainsi développer des modèles prédictifs capables de gérer de nouvelles données. [5]

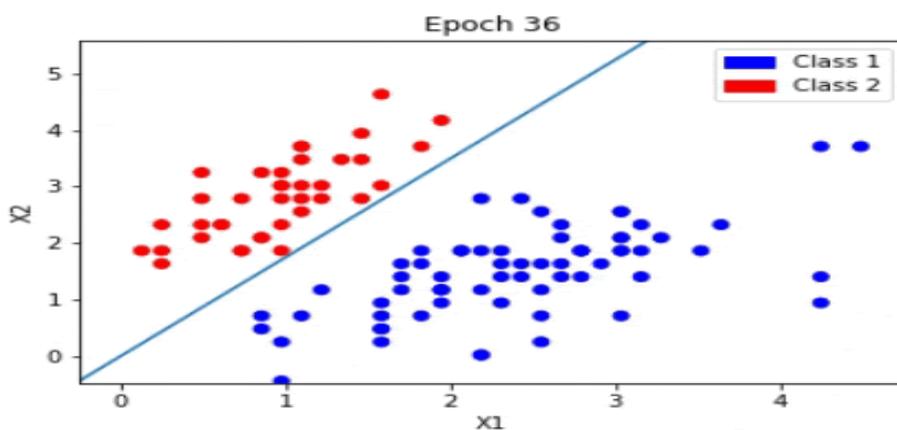


Figure I-8 : Apprentissage supervisé [6]

A.2 L'apprentissage non supervisé :

Le système apprend à partir des données qui ne sont pas étiquetées, c'est-à-dire Il cherche à découvrir la structure ou les points essentiels dans les données, sans savoir à l'avance ce qu'il cherche. Par exemple, si on veut détecter des objets feus dans une image, on ne spécifie pas à la machine que l'image contient du feu ou autre objet, mais on lui fournit juste une quantité importante de données et c'est à lui de classifier ces différents feux et pouvoir tirer une conclusion selon les groupes qui sont similaires.

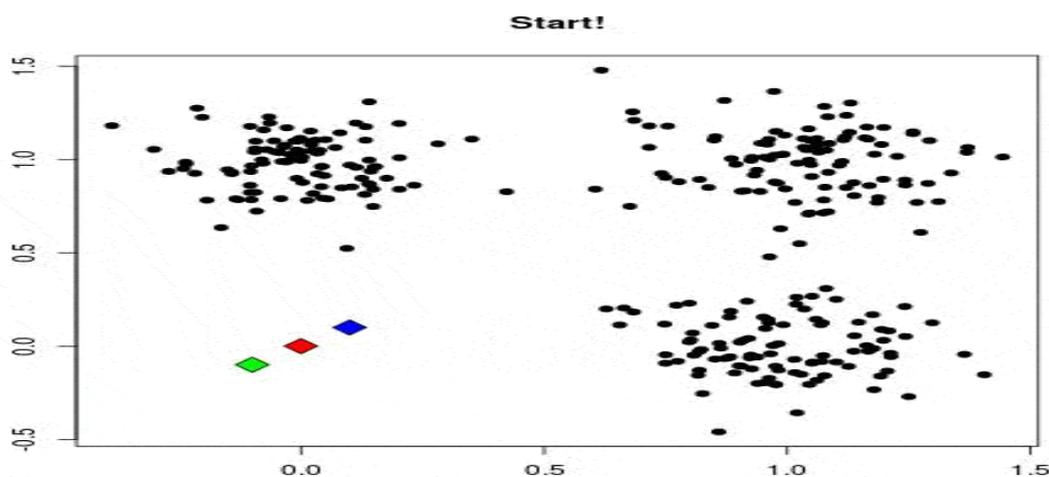


Figure I-9 : Apprentissage non supervisé [6]

A.3 L'apprentissage par renforcement :

Le système apprend à partir de ses propres actions et des récompenses ou des pénalités qu'il reçoit. Il cherche à optimiser son comportement pour maximiser la récompense à long terme. Par exemple, si on veut apprendre à jouer aux échecs, on peut utiliser l'apprentissage par renforcement pour faire jouer le système contre lui-même ou contre d'autres joueurs, et lui donner une récompense s'il gagne ou une pénalité s'il perd. Le système apprend alors à choisir les meilleurs coups possibles. [5]

I.4.2 Deep Learning ou Apprentissage Profond

L'une des technologies clés de l'apprentissage automatique est l'apprentissage profond, parfois appelé Deep Learning, grâce à l'utilisation de réseaux de neurones artificiels, nous pouvons créer des algorithmes avec le Deep Learning qui imitent l'activité cérébrale humaine. Les réseaux sont constitués de dizaine, voire de centaines de « couches » de neurones, dont chacune reçoit et interprète les données de la couche précédente.

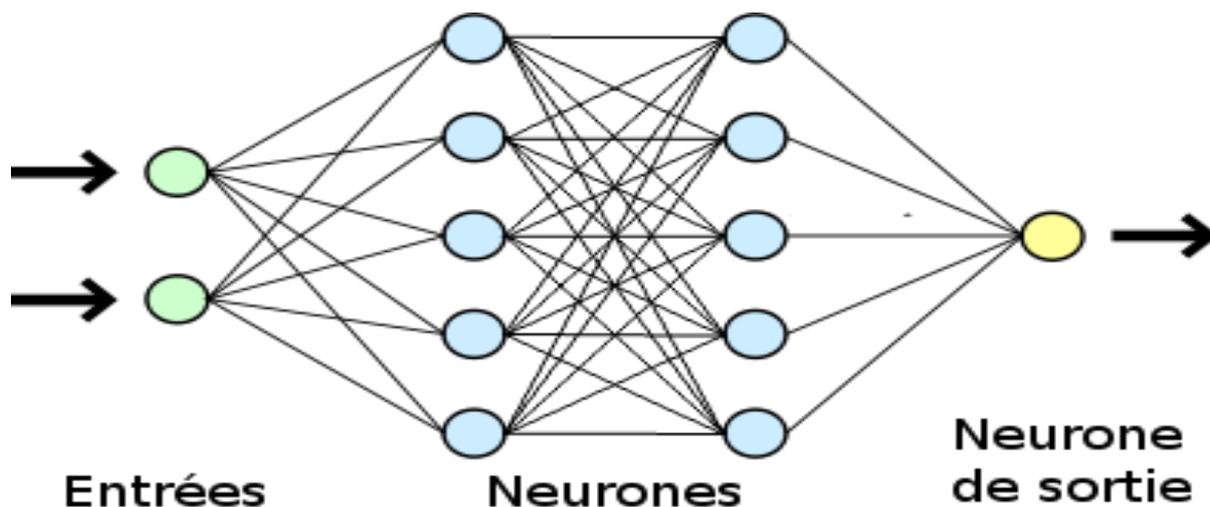


Figure I-10 : Réseau multicouche [7]

Chaque neurone artificiel est représenté par un cercle dans l'image précédente, peut être vu comme un modèle linéaire.

En connectant les neurones sous forme de couches, nous transformons les réseaux de neurones en modèles non linéaires très complexes.

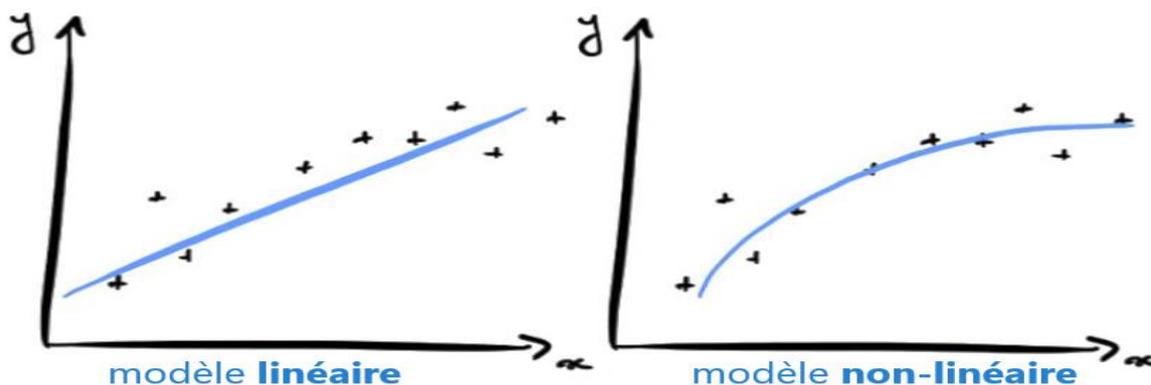


Figure I-11 : Modèles linéaire et non-linéaire de neurones

A. À quoi sert le Deep Learning ?

Les modèles d'apprentissage profonds ont tendance à bien gérer de grandes quantités de données, alors que les modèles d'apprentissage automatique traditionnels cessent de s'améliorer une fois qu'ils atteignent un point de saturation.

Au fil des années, l'avènement du Big Data et des composants informatiques de plus en plus puissants ont conduit à des algorithmes d'apprentissage profond gourmands en énergie et en données, dépassant la plupart des autres techniques.

Ils ont résolu de nombreux problèmes, notamment la reconnaissance de 4 444 visages humains, détection de feux, la possibilité de conduire des voitures autonomes et même la recherche de cellules cancéreuses. [6]

B. Réseaux de neurones

Les réseaux de neurones, également appelés réseaux de neurones artificiels (ANN) ou réseaux de neurones simulés (SNN), sont un sous-ensemble de l'apprentissage automatique et le cœur des algorithmes d'apprentissage profonds. [7]

Leurs noms et leurs structures sont inspirés du cerveau humain, imitant la façon dont les neurones biologiques s'envoient des signaux.

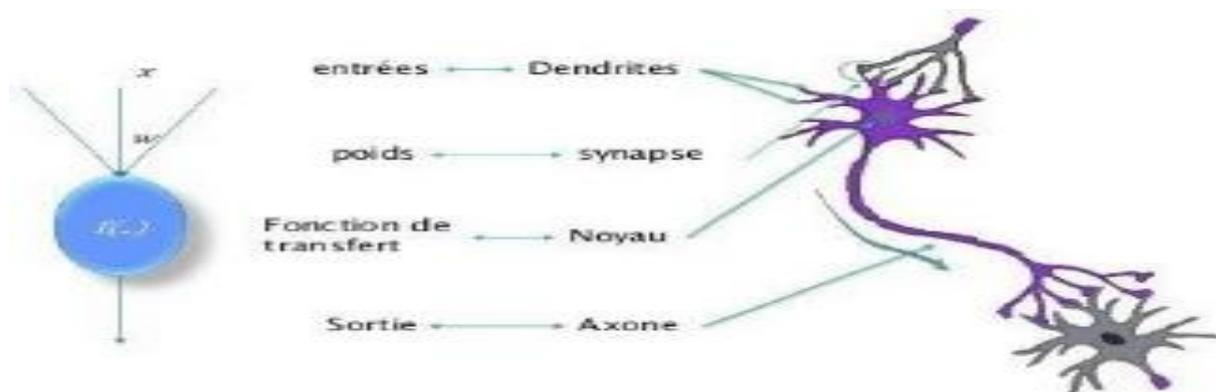


Figure I-12 : Mise en correspondance neurone biologique / neurone artificiel [10]

Un réseau neuronal artificiel (ANN) se compose d'une couche de nœuds, comprenant une couche d'entrée, une ou plusieurs couches cachées et une couche de sortie. Chaque nœud ou neurone artificiel est connecté à un autre nœud et possède un poids. [7]

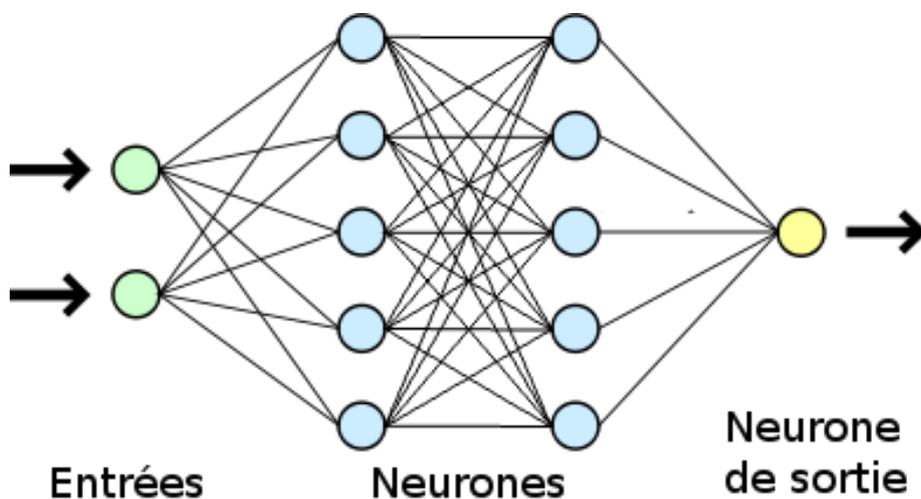


Figure I-13 : Réseau multicouche [7]

L'avantage des réseaux de neurones est qu'ils peuvent apprendre à résoudre des problèmes complexes à partir de la modélisation des exemples complexes [8].

B.1 Comment le réseau de neurones artificiels apprend

Les réseaux de neurones artificiels permettent aux ordinateurs d'apprendre de nouvelles données. L'ordinateur doté du réseau de neurones apprend à effectuer une tâche en analysant des exemples pour s'entraîner. Ces exemples ont préalablement été étiquetés afin que le réseau puisse savoir ce dont il s'agit.

Par exemple, un réseau de neurones peut être utilisé pour apprendre à l'ordinateur à reconnaître des objets. Un grand nombre d'objets d'une même catégorie est présenté au réseau de neurones et l'ordinateur apprend à reconnaître ces objets sur de nouvelles images en analysant les modèles récurrents au sein des images d'exemples. Ainsi, en analysant des milliers de photos de feux de forêt, le Neural Network apprendra à reconnaître un feu de forêt sur n'importe quelle photo.

Contrairement à d'autres types d'algorithmes, les réseaux de neurones ne peuvent pas être programmés directement pour effectuer une tâche, mais de la manière du cerveau d'un enfant en développement ou la seule instruction qu'il on est d'apprendre.

Or, cependant On distingue toutefois trois méthodes d'apprentissage distinctes :

- L'apprentissage supervisé ;
- L'apprentissage non-supervisé ;
- L'apprentissage renforcé [6]

B.2 Les types de réseaux de neurones

Il existe de nombreux types différents de réseaux de neurones. On peut classer les RNA en deux grandes catégories :

- Réseaux non-bouclés
- Réseaux bouclés

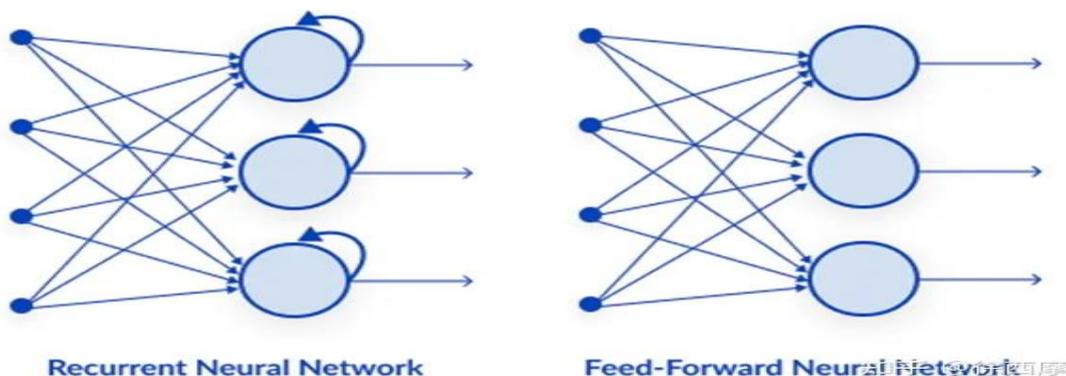


Figure I-14 : Réseau [12]

Les réseaux de neurones sont généralement classés selon le nombre de couches qui séparent l'entrée des données et la génération des résultats, le nombre de nœuds cachés dans le modèle et même le nombre d'entrées et de sorties pour chaque nœud selon le type de réseau.

Les informations transmises entre les différentes couches de neurones peuvent être différentes :

B.2.a) Les réseaux de neurones FeedForward

Dans la variante la plus simple, le réseau neuronal dit " FeedForward ". Les réseaux de neurones FeedForward, également appelés réseaux de neurones à action directe, sont un type particulier de réseaux de neurones artificiels, Contrairement aux réseaux de neurones récurrents, ils sont aperiodiques (acycliques). [6]

Le plus connu est le perceptron multicouche, qui est une extension du premier réseau de neurones artificiels, le perceptron, inventé par Frank Rosenblatt en 1957.

Dans un réseau de neurones à action directe, l'information se déplace uniquement dans une seule direction, de l'entrée vers les couches cachées (le cas échéant) et vers les nœuds de sortie. [6]

En apprentissage automatique, le perceptron multicouche (multi layer perceptron MLP en anglais) est un type de réseau neuronal artificiel organisé en plusieurs couches. Un perceptron multicouche possède au moins trois couches : Une couche d'entrée, au moins une couche cachée et une couche de sortie. Chaque couche est constituée d'un nombre (potentiellement différent) de neurones. L'information circule de la couche d'entrée vers la couche de sortie uniquement.

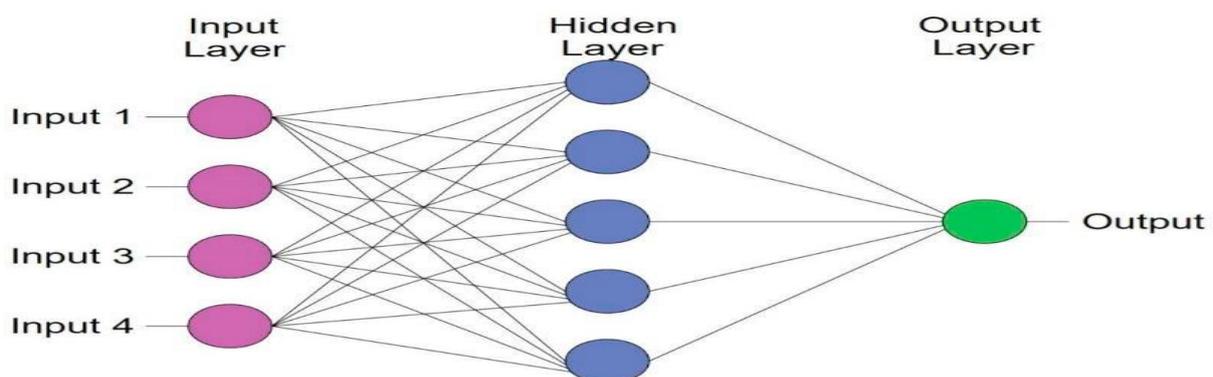


Figure I-15 : Perceptron multicouche [13]

Remarque : le perceptron a couche unique est l'unité de base des réseaux de neurone. Il s'agit d'un modèle de classification binaire capable de séparer linéairement 2 classes de pointe.

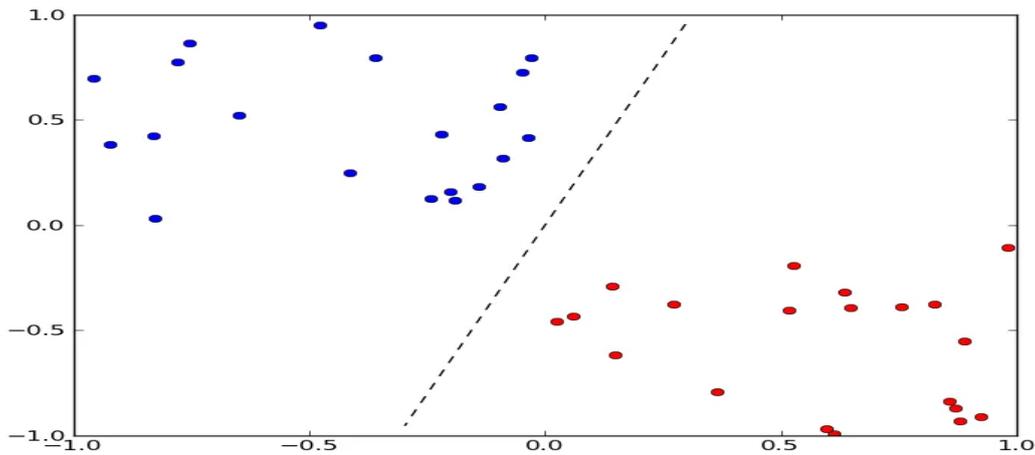


Figure I-16 : Apprentissage supervisé [14]

En outre, il est utilisé dans l'apprentissage supervisé. [9]

Soit deux objets de feu dans une image, alors en sélectionnant les zones feux de forêt et feux de barbecue le perceptron va donc nous permettre de distinguer les deux types de feux en séparant linéairement les deux grâce à leur longueur et leur largeur.

Donc pour développer ce modèle il est donc nécessaire de savoir quelle est l'équation de cette droite, pour ça on va développer ce qu'on appelle un modèle linéaire et il faut savoir qu'il existe différents modèles comme (modèles non-linéaires, tangente, sigmoïde etc.)

Avec : w le poids ;

Les variables x1, x2 et x3 ;

Sans oublier, le coefficient complémentaire appelé le biais b ;

Les résultats donnent une fonction Z.

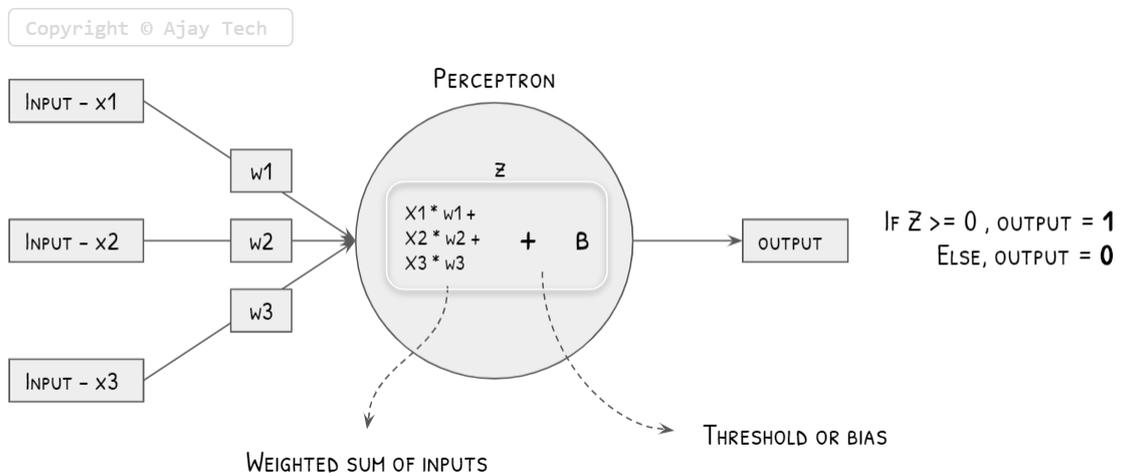


Figure I-17 : Perceptron [15]

En bref, par FeedForward il faut comprendre que l'information (la donnée d'entrée) passe une fois dans chaque couche. [10]

Le problème avec ce type de Réseau, c'est qu'ils traitent les données les unes après les autres sans se soucier des relations entre elles. [9]

B.2.b) Les réseaux de neurones récurrents :

Ce type d'apprentissage est un peu plus compliqué. Un réseau neuronal récurrent (RNN) est un type de réseau neuronal artificiel qui utilise des données séquentielles.

Ces algorithmes d'apprentissage profonds sont largement utilisés pour des problèmes séquentiels ou temporels tels que la traduction linguistique, le traitement du langage naturel, la reconnaissance vocale et le sous-titrage d'images.

Ceux-ci sont intégrés dans des applications populaires telles que Siri, la recherche vocale et Google Translate.

Les réseaux de neurones récurrents utilisent également des données de formation pour l'apprentissage.

Ils se caractérisent par leur " puissance de mémoire " car ils utilisent les informations des entrées précédentes pour influencer les entrées et sorties actuelles.

Les réseaux de neurones profonds traditionnels supposent que les entrées et les sorties sont indépendantes les unes des autres, alors que les sorties des réseaux de neurones récurrents dépendent des éléments précédents de la séquence. [7]

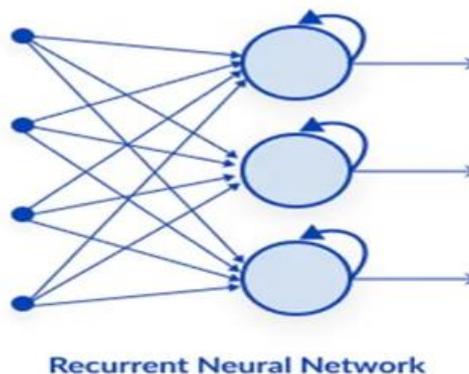


Figure I-18 : Les réseaux de neurones récurrents [12]

B.2.c) Les réseaux de neurones convolutifs :

Enfin, les réseaux de neurones convolutifs. Elles sont de plus en plus utilisées dans divers domaines, notamment la reconnaissance faciale, l'analyse de textes et le traitement du langage naturel. [6]

Les réseaux de neurones convolutifs sont des réseaux de neurones artificiels (ANN) qui utilisent des algorithmes d'apprentissage en profondeur pour analyser des images, classer des éléments visuels et effectuer des tâches de vision par ordinateur. [10]

a. Quels sont les principales applications des CNN ?

Les réseaux de neurones convolutifs s'inspirent de la nature, car les connexions entre neurones artificiels ressemblent à l'organisation du cortex visuel d'un animal.

Les réseaux convolutifs apprennent plus rapidement et ont un meilleur taux d'erreur. Dans une moindre mesure, il est également utilisé pour l'analyse vidéo. Ce type de réseau est également utilisé dans le traitement du langage naturel.[11]

b. Fonctionnement d'un Convolutional Neural Network (CNN) :

L'architecture d'un réseau de neurones convolutifs comporte une partie convolution en amont, elle se compose donc de deux parties : Partie Convolution et partie Classification.

b.1 Partie Convolution :

Son but ultime est d'extraire certaines caractéristiques de chaque image en compressant l'image pour réduire sa taille d'origine.

Pour résumer, une image fournit en entrée passe à travers une série de filtres tout en créant une nouvelle image appelée carte de convolution.

Enfin, la carte convolutive obtenue est concaténée dans un vecteur de caractéristiques appelé code CNN. [11]

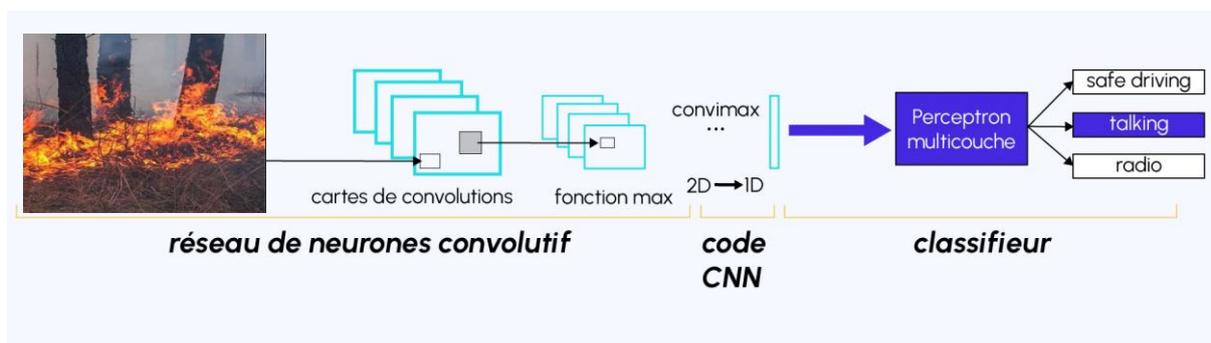


Figure I-19 : CNN [18]

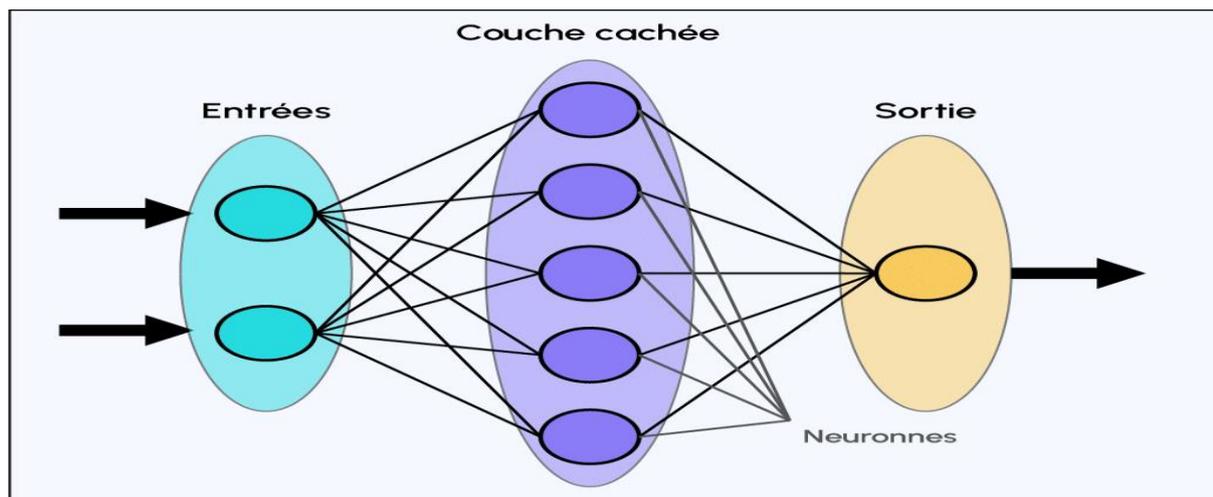


Figure I-20 : Perceptron multicouche [18]

À quoi sert la convolution ?

La convolution est une opération mathématique simple couramment utilisée dans le traitement et la reconnaissance d'images.

b.1.1) Couche avec filtre de convolution :

Crée un produit entre le filtre (un tableau bidimensionnel dont les poids sont ajustés lors de l'entraînement) et une couche de l'image.

La taille de ce filtre est généralement de 3×3 ou 5×5 .

Au fur et à mesure que vous augmentez le nombre de ces couches dans votre réseau, vous pourrez extraire des fonctionnalités de plus en plus complexes et à terme, pouvoir prédire les classes d'appartenance des éléments présents dans une image.

C'est pourquoi on parle de « Deep Learning ». C'est à dire apprentissage profond. [11]

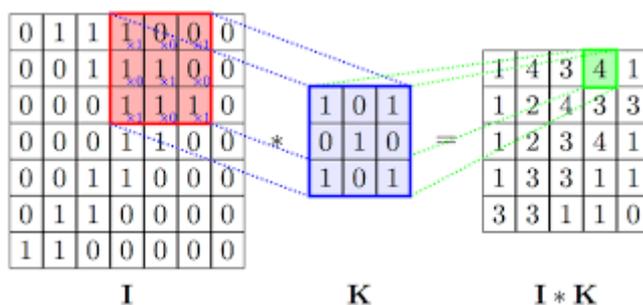


Figure I-21 : Filtrage [19]

b.1.2 Couches avec Pooling :

Il peut être utilisé pour compresser la taille des images et réduire le coût de calcul des couches tout en gardant des infos principales. Il utilise généralement une fonction maximum ou moyenne. [13]

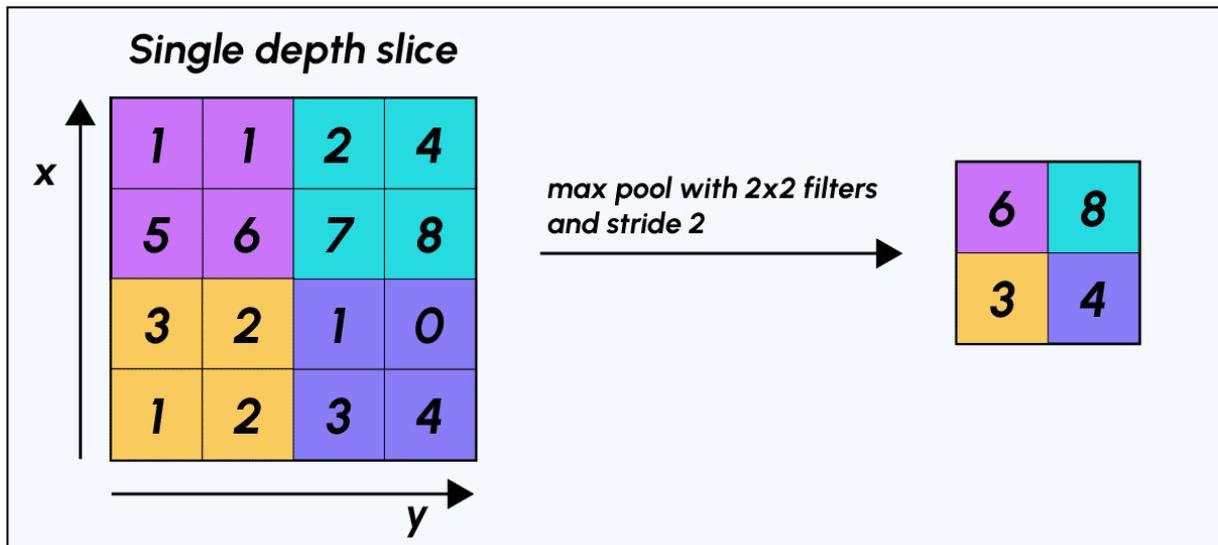


Figure I-22 : Couche Max Pooling [18]

Enfin, la sortie de cette couche de Pooling contient le même nombre de cartes de caractéristiques que l'entrée, mais est considérablement compressée.

b.2 Partie classification :

Le code CNN obtenu en sortie de la partie convolution est fourni en entrée de la deuxième partie, qui consiste en une couche entièrement connectée appelée perceptron multicouche (MLP). La tâche de cette partie est de combiner les fonctionnalités du code CNN pour classer l'image. [11]

b.2.1 Couche d'activation relu (unités linéaires rectifiées) :

Cette couche remplace toutes les valeurs négatives reçues en entrée par des zéros. L'avantage de ces couches d'activation est qu'elles rendent le modèle non linéaire et donc plus complexe.

b.2.2 Couches entièrement connectées (FC) :

Ces couches sont placées à la fin de l'architecture CNN (elle désigne la dernière couche cachée d'un réseau neuronal profond) et sont entièrement connectées à tous les neurones de sortie (d'où le terme « entièrement connecté »). [11]

Après avoir reçu un vecteur en entrée, la couche FC applique séquentiellement une combinaison linéaire puis une fonction d'activation, dans le but ultime est de classer l'image en entrée. [11]

I.5 Conclusion :

La détection d'objet est un domaine hautement intéressant de l'intelligence artificielle (IA). Elle a révolutionné le domaine de vision par ordinateur en apportant une précision exceptionnelle et des performances en temps réel. Dans le prochain chapitre on va discuter l'état de l'art des algorithmes de détection d'objets, et faire une étude comparative entre 3 fameux algorithmes.

CHAPITRE II : Etat de l'art des algorithmes de détection d'objets

II.1 Introduction :

Les algorithmes de détection d'objets sont des outils très puissants pour la vision par ordinateur.

Ceux-ci permettent la détection et la localisation d'objets dans des images et des vidéos, permettant ainsi un large éventail d'applications telles que la surveillance, la reconnaissance faciale, la détection des incendies de forêt et le traitement d'images médicales.

Il existe plusieurs familles d'algorithmes de détection d'objets, notamment la famille R-CNN, la famille YOLO et la famille SSD.

Ces algorithmes sont basés sur l'apprentissage profond, qui utilise des réseaux de neurones artificiels pour s'entraîner sur les données et faire des prédictions.

Notre objectif est d'explorer plus en profondeur l'état de l'art des différents algorithmes de détection d'objets et faire une étude comparative entre ces différentes méthodes.

II.2 Etat de l'art sur les différents algorithmes de Détection d'objets

La détection d'objets est une tâche fondamentale en vision par ordinateur (et une technologie d'intelligence artificielle permettant aux ordinateurs de 'voir' de la même façon que les êtres humains). Il s'agit de localiser et d'identifier des objets présents dans une image ou une séquence vidéo.

C'est sur cela que reposent de nombreuses innovations actuelles, notamment la reconnaissance faciale, la réalité augmentée, la surveillance automatisée ou encore la conduite autonome. [14]

Pour une meilleure détection Il existe plusieurs familles d'algorithmes de détection d'objets, notamment la famille R-CNN, la famille YOLO et la famille SSD.

II.2.1 R-CNN

La classification CNN (réseaux neuronaux convolutifs (CNN)) étaient initialement limités dans leur capacité à classifier uniquement un seul objet dans une image. [23]

Par conséquent, en 2014, Ross Girshick a proposé un algorithme de détection d'objets plus avancé, R-CNN (Region-based CNN). [12]

A) R-CNN ou les CNN basé sur des Régions

Le modèle R-CNN ou les CNN basé sur des Régions a contribué de manière significative aux progrès dans le domaine de la reconnaissance d'objets.

L'architecture R-CNN extrait les régions candidates de l'image d'entrée et calcule leurs propriétés CNN pour tenter une classification. [12]

En d'autres termes, le R-CNN permet de détecter et classifier plusieurs objets distincts dans une seule image.

A.1 Architecture et fonctionnement de R-CNN ?

Pour mieux comprendre son fonctionnement nous lustrons ainsi :

1. Proposition de régions

R-CNN commence par diviser l'image d'entrée en plusieurs régions potentielles. Des méthodes telles que la recherche sélective sont utilisées pour déterminer les caractéristiques qui permettent de localiser un objet.

Cette recherche sélective combine ou divise des segments d'image selon différents indices (couleur, forme, texture). [12]

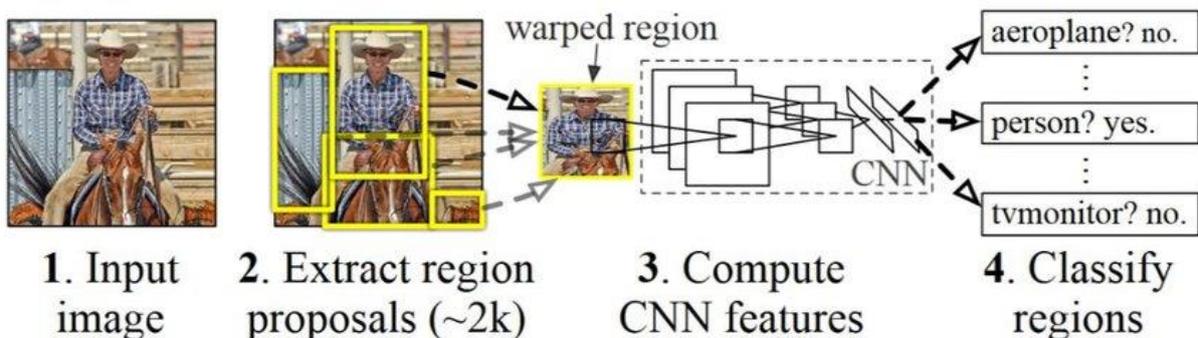


Figure II-1 : R-CNN

2. Extraction de caractéristiques

Une fois ces suggestions de régions générées, environ 2 000 régions sont extraites et ajustées à une taille uniforme(cohérent).

Chacune de ces régions est transmise en entrée à un modèle CNN qui tente d'extraire des caractéristiques précises.

3. Classification des objets

Les vecteurs de caractéristiques de la proposition de région sont entrés dans un classificateur d'apprentissage automatique pour déterminer si la proposition de région contient des instances de classes prédéfinies. [12]

- **Bounding Box Regression - Régression de la boîte englobante**

R-CNN effectue une régression du cadre de délimitation pour ajuster l'emplacement et la taille du cadre de délimitation autour de l'objet détecté. [12]

- **Non-Maximum Suppression (NMS)**

Une fois que R-CNN a classé les cadres de délimitation et effectué une régression sur chaque région proposée, il applique un « algorithme de suppression non-maximale » qui vise à supprimer les cadres de délimitation en double ou qui se chevauchent. [12]

L'algorithme NMS fonctionne comme suit :

- Trier les cadres de délimitation prédits par ordre décroissant en fonction de la valeur de confiance.
- Sélectionner le cadre de délimitation avec la valeur de confiance la plus élevée et supprimer tous les autres cadres qui chevauchent de manière significative de ce cadre de délimitation (c'est-à-dire les cadres qui ont un IoU qui ne dépasse pas un certain seuil sont éliminés et préserver les N premières valeurs). [13]
- Répéter l'étape 2 jusqu'à ce que toutes les boîtes soient traitées. [13]

A.2 Avantages

- Précision : R-CNN ont montré de bonnes performances en matière de détection d'objets.
- Localisation précise : Permettre de localiser des objets avec une grande précision.
- Flexibilité : Détecter des objets de plusieurs catégories dans une seule image.

A.3 Inconvénients

- Lent : La principale limitation de R-CNN est sa vitesse de traitement.
- Ces tests sont relativement longs à tester et peuvent gêner l'utilisation d'applications temps réel.
- Temps de préparation : La préparation du modèle prend du temps, car environ 2000 propositions de zones doivent être caractérisées pour chaque image.

De plus, le traitement de chaque image de test prend environ 47 secondes, elle ne peut donc pas être mise à jour en continu. [14]

B) Fast R-CNN

Cependant, le R-CNN n'est pas le modèle le plus rapide. Chaque image nécessite la classification de 2 000 propositions de régions, ce qui prend du temps pour entraîner le réseau et nécessite également beaucoup d'espace de stockage pour stocker les cartes caractéristiques des propositions de régions.

C'est alors en 2015 que le Fast R-CNN a été introduit pour la première fois, il a inévitablement ouvert la voie à une amélioration significative de la vitesse de détection d'objets. [33]

Fast R-CNN traite l'image de façon intégrale plutôt que chaque proposition de région individuelle. Il identifie des régions d'intérêt (RoI) pouvant contenir des objets et extrait pour chacune les caractéristiques correspondantes. [15]

B.1 Architecture et Fonctionnement de Fast R-CNN

Fast R-CNN se compose de trois composants principaux :

- Couche convolutive qui crée des cartes de caractéristiques à partir d'images d'entrée.
- Une couche de regroupement des régions d'intérêt (RoI) qui extrait un vecteur de caractéristiques de longueur fixe à partir de la carte des caractéristiques en utilisant des propositions (boîtes englobantes et leurs scores). [16]
- Chaque vecteur de caractéristiques passe par une couche entièrement connectée (FC) pour une amélioration supplémentaire.
- SoftMax fournit des estimations de probabilité pour K classes d'objets et une classe fourre-tout « d'arrière-plan ».
- Le régresseur de la boîte englobante estime quatre valeurs pour chacune des K classes. [17]

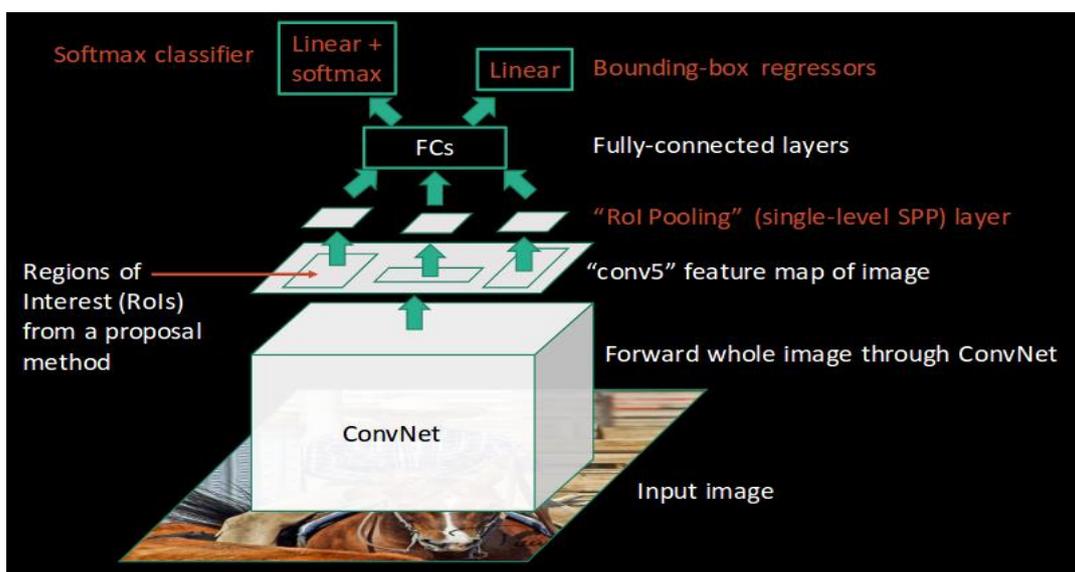


Figure II-2 : Architecture de Fast R-CNN [39]

B.2 Fonctionnement

L'image entière est transmise au réseau CNN principal pour obtenir les caractéristiques finales de la couche convolutionnelle. En fonction du CNN de base utilisé, la carte des caractéristiques de sortie sera nettement plus petite que la taille de l'image d'origine, et cela grâce à la foulée.

D'autre part, la fenêtre de proposition d'objet est obtenue à partir d'un algorithme de proposition de région tel que la recherche sélective. Elle est représentée par un rectangle et signifie donc la présence d'un objet sur l'image.

La partie de la carte des caractéristiques du réseau principal associée à cette fenêtre est transmise à la couche de Pooling RoI.

Les couches de Pooling RoI sont un cas particulier de couches de Pooling Pyramidal Spatial (SPP) avec une seule couche pyramidale.

Cette couche divise essentiellement les entités de la fenêtre de proposition sélectionnée (obtenue à partir de l'algorithme de proposition de région) en sous-fenêtres de taille $H \times W$ et effectue une opération de regroupement sur chacune de ces sous-fenêtres.

Cela produira des entités en sortie d'une taille fixe (hauteur x largeur) quelle que soit la taille en entrée.

H et W sont choisis de telle sorte que la sortie soit compatible avec la première couche entièrement connectée du réseau.

Ensuite, les caractéristiques de sortie de la couche de Pooling ROI ($N \times 7 \times 7 \times 512$, où N est le nombre de propositions) sont introduites dans les couches FC successives et les branches de BB (bounding box) régression et softmax.

La branche de classification softmax produit des valeurs de probabilité pour chaque RoI appartenant aux catégories K et à la catégorie d'arrière-plan.

La sortie de la branche de régression BBR (bounding box regression) est utilisée pour rendre la boîte englobante de l'algorithme de proposition de région plus précise. [18]

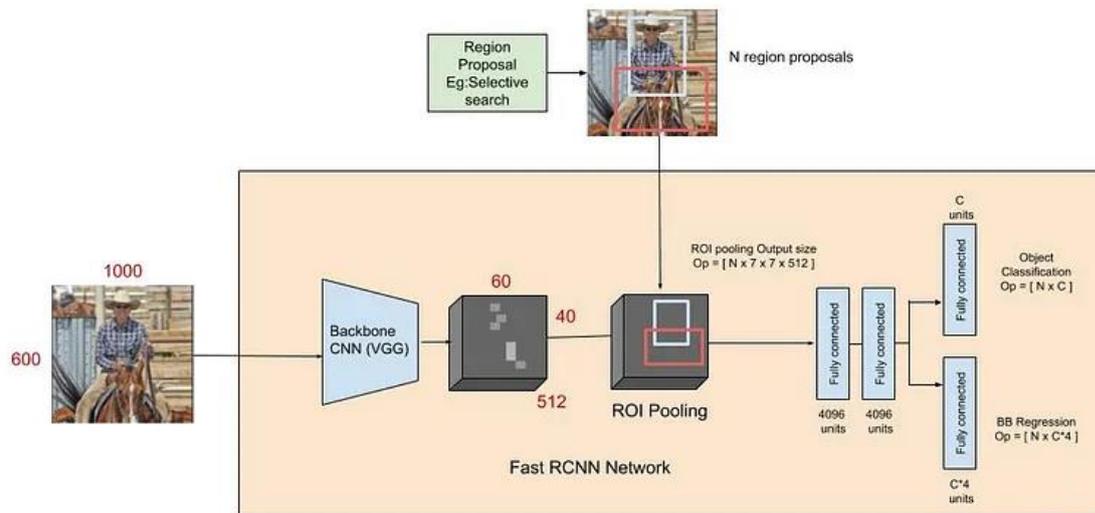


Figure II-3 : Fast R-CNN [40]

B.3 Avantages

- Fast R-CNN a apporté une performance de pointe
- Efficacité : Fast R-CNN a considérablement amélioré l'efficacité par rapport à ses prédécesseurs. Il est nettement plus rapide à la fois lors de la formation et des tests. [19]

B.4 Inconvénients

Le Fast R-CNN malgré ça performance, il est lent en termes de traitement et pas assez précis par rapport à Faster R-CNN. [14]

C) Faster R-CNN

Faster R-CNN est un algorithme de détection d'objets introduit pour la 1ere fois en 2015, il vise à améliorer la vitesse et la précision de détection par rapport à Fast R-CNN.

L'architecture Faster RCNN comprend un réseau de proposition de région (RPN) qui partage les caractéristiques convolutives de l'image entière avec le réseau de détection, lui permettant de suggérer des régions pratiquement sans frais. [16]

C.1 Fonctionnement et Architecture Faster R-CNN

Construit sur Fast R-CNN, Faster R-CNN visait à éliminer le besoin de techniques de proposition de région externe telles que la recherche sélective.

L'innovation clé a été l'intégration des réseaux de propositions régionaux (RPN) directement dans l'architecture du réseau. Les étapes de R-CNN rapides comprennent :

- Réseau fédérateur : CNN (généralement un réseau pré-entraîné tel que ResNet) traite l'image d'entrée.
- Réseau de propositions de région (RPN) : RPN génère des propositions de région à partir de cartes de fonctionnalités.
- RoI Pooling : Semblable à Fast R-CNN, le Pooling RoI aligne les fonctionnalités sur les suggestions régionales.
- Classification et Régression : La dernière étape consiste à classer et à affiner le cadre de délimitation, similaire à Fast RCNN. [20]

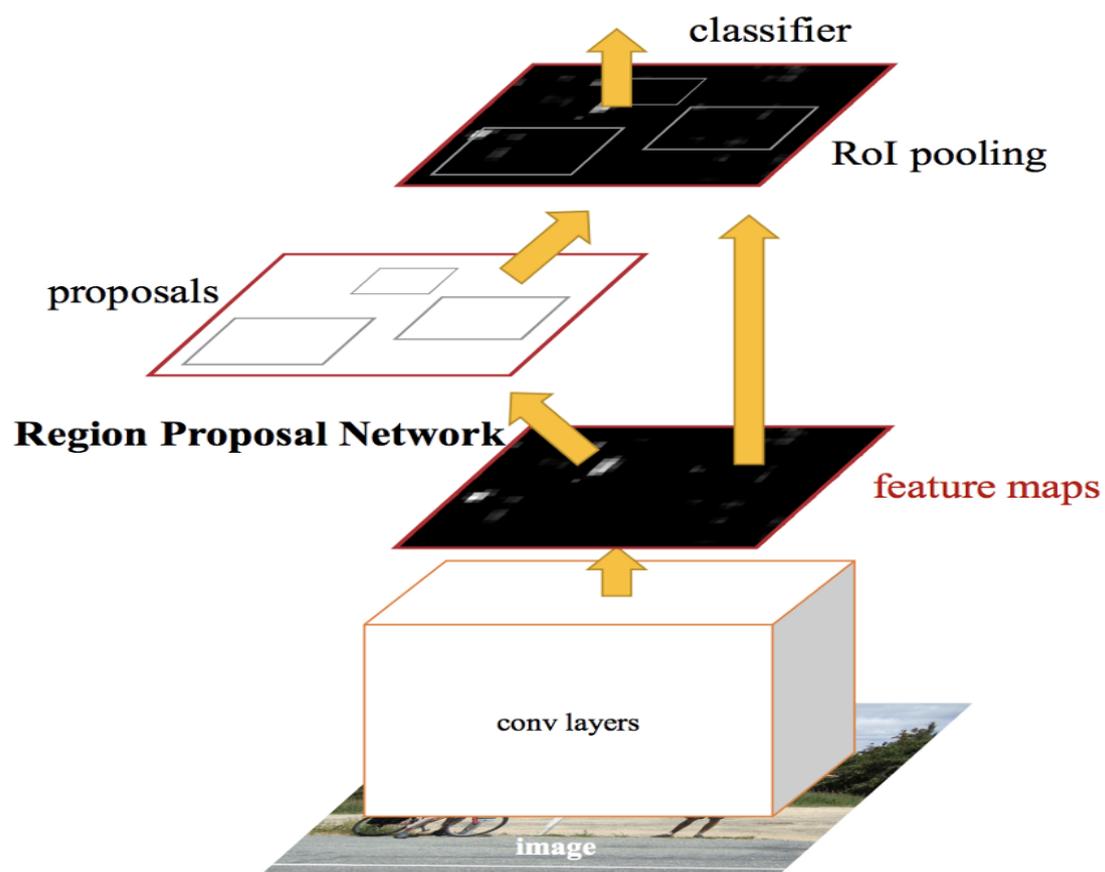


Figure II-4 : Architecture Faster R-CNN [39]

C.2 Fonctionnement

Faster R-CNN est l'une des méthodes de détection d'objets les plus populaires. Cela fait partie de la famille R-CNN développée en 2014 par Ross Girshick.

Il a été développé et affiné à l'aide de Fast R-CNN, aboutissant finalement à Faster R-CNN.

Son fonctionnement est décrit par :

- Une image en entrée qui est passée dans un réseau neuronal convolutif (CNN) pour obtenir une carte des caractéristiques des objets présents sur l'image. Cette partie de l'architecture de Faster R-CNN est appelée réseau « backbone ».
- Cette carte des caractéristiques est ensuite utilisée par un réseau de proposition de région (RPN) pour générer des propositions de régions (cadres de délimitation qui contiennent les objets pertinents de l'image) en utilisant des ancres (boîtes de référence de taille fixe placées uniformément dans l'image originale afin de détecter les objets). Ces régions sont par la suite filtrées par NMS (Non-Maximum Suppression) avec un threshold de 0.7 (70%). NMS est une méthode qui permet de passer au crible les régions proposées et choisir uniquement celles qui sont intéressantes.
- La carte caractéristique extraite par le CNN en 1 et les cadres de délimitation des objets pertinents sont utilisés pour générer une nouvelle carte caractéristique grâce à la mise en commun (Pooling) des régions d'intérêt (RoI) déterminées dans l'étape 2.
- Les régions regroupées passent ensuite par des couches entièrement connectées pour la prédiction des coordonnées des zones des objets et les classes de sortie. Cette partie de l'architecture de Faster R-CNN est appelée réseau d'en-tête[21].

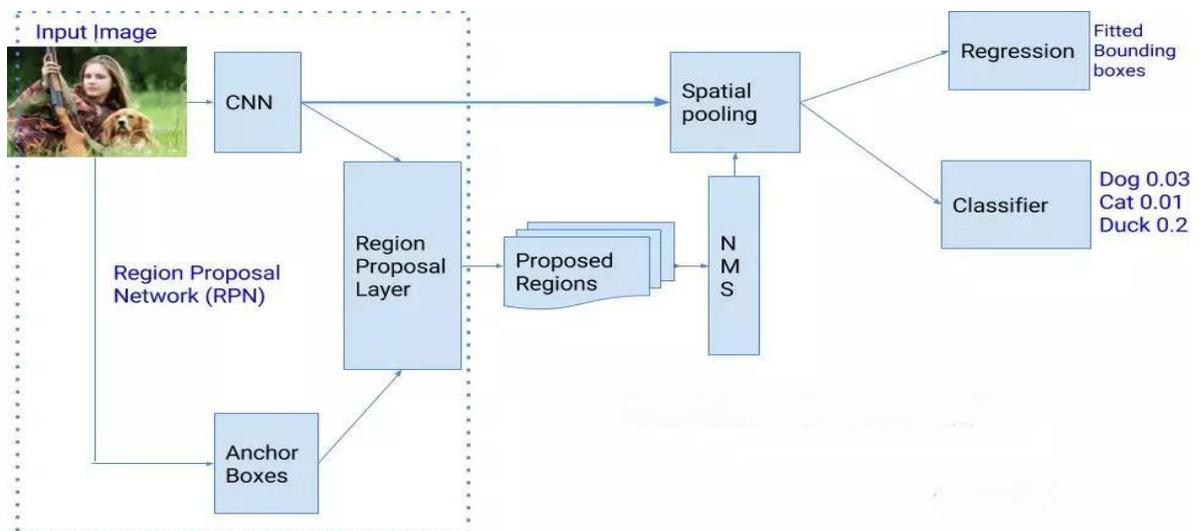


Figure II-5 : Faster R-CNN [43]

C.3 Avantages

- Faster-RCNN a apporté une performance de pointe
- Efficacité : Faster R-CNN a considérablement amélioré l'efficacité par rapport à ses prédécesseurs.

D) Récapitulation

Les architectures R-CNN, Fast R-CNN et Faster R-CNN ont considérablement repoussé les limites du domaine de la détection d'objets. Ils sont considérablement améliorés au fil des années et avec l'intégration de RPN (Faster R-CNN) a considérablement réduit le temps de calcul et permis la détection d'objets en temps réel.

Malgré leurs complexités, l'efficacité et la rapidité de ces modèles ont joué un rôle important dans l'avancement des applications d'apprentissage profond dans divers domaines.

II.2.2 YOLO détection (On ne Regarde qu'Une Foix)

YOLO est une méthode d'identification et de reconnaissance d'objets en temps réel. C'est une abréviation de You Only Look Once. [15]

Il a été Développé à l'origine par Joseph Redmon, Ali Farhadi et Santosh Divvala, YOLO vise à atteindre une grande précision dans la détection d'objets en temps réel. [16]

YOLO a atteint un tournant avec son approche innovante. La localisation et la classification simultanées d'objets en un seul passage via un réseau neuronal convolutif ont permis de combiner vitesse en temps réel et la précision. [14]

Depuis sa création en 2016 jusqu'en (2023), la famille YOLO n'a cessé d'évoluer à un rythme rapide.



Figure II-6 : YOLO [22]

YOLO a évolué au fil des années et a connu différentes versions (YOLOv5, YOLOv6, YOLOv7, etc.) pour devenir le modèle recommandé pour la détection d'objets dans divers domaines tels que la robotique et la vidéo surveillance.[22]

La dernière en date était YOLOv8 avant l'arrivée de la toute version en version YOLOv9 en Mars 2024.

Dans l'ensemble, la haute précision et les performances de YOLOv8 ont fait un concurrent sérieux pour les projets de vision par ordinateur. [23]

A. YOLOv8

YOLOv8 est un cadre d'IA qui prend en charge plusieurs tâches de vision par ordinateur. Ce cadre peut être utilisé pour la détection, la segmentation, la classification et l'estimation de pose. Chacune de ces tâches a des objectifs et des cas d'utilisation différents. [19]

A.1) Détection :

La détection est la principale tâche prise en charge par YOLOv8. Cela implique de détecter des objets dans une image ou une image vidéo et de dessiner un cadre de délimitation autour d'eux. Les objets détectés sont classés en différentes catégories en fonction de leur propriété.

YOLOv8 peut détecter plusieurs objets dans une seule image ou image vidéo avec une précision et une vitesse élevée.



Figure II-7 : Détection des feux de forêt

A.2) Pose :

La détection de pose, point clé consiste à trouver des points spécifiques dans une image ou une image vidéo.

Ces points sont appelés points clés et sont utilisés pour le suivi du mouvement et l'estimation de pose. YOLOv8 peut détecter des points importants d'une image ou une image vidéo avec une grande précision et rapidité. [24]

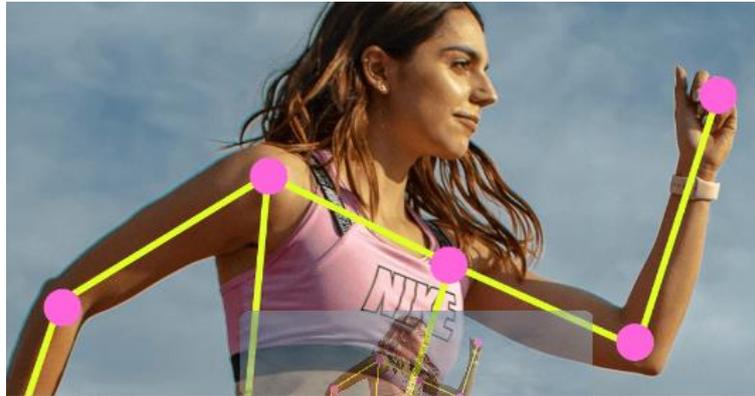


Figure II-8 : Pose [26]

A.3) Classification

La classification consiste à classer les images en différentes catégories. YOLOv8 vous permet de classer les images en fonction de leur contenu. Une variante de l'architecture efficace Net est utilisée pour la classification. [24]

A.4) Segmentation

La segmentation consiste à segmenter une image en différentes régions en fonction du contenu de l'image. Chaque région se voit attribuer une étiquette en fonction de son contenu. Cette tâche est utile dans des applications telles que la segmentation d'images et le traitement d'images médicales. YOLOv8 utilise une variante de l'architecture U-Net pour effectuer la segmentation. [24]



Figure II-9: Segmentation [27]

B. Architecture de YOLOv8

La première étape pour comprendre l'architecture YOLO est de comprendre que l'algorithme contient trois blocs importants.

- Colonne vertébrale (Backbone)
- Cou (Neck)
- Tête (Head) [23]

Mais le site officiel dénombre que 2 qui sont : (Backbone, Head)

B.1) Backbone :

Caractéristiques : Le backbone, également connu sous le nom d'extracteur de fonctionnalité, est chargé d'extraire les fonctionnalités significatives de l'entrée.

Activité :

- Capturer des motifs simples tels que des bords et des textures dans le premier calque.
- Pouvoir présenter plusieurs échelles de représentation au fil du temps et capturer des fonctionnalités à différents niveaux d'abstraction.
- Fournir une riche représentation hiérarchique des entrées. [23]

B.2) Neck :

Fonctionnalité :

- Le cou agit comme un pont entre la colonne vertébrale et la tête, effectuant des opérations de fusion de caractéristiques et intégrant des informations contextuelles.
- Fondamentalement, le cou assemble une pyramide de fonctionnalité en agrégeant les cartes de fonctionnalité obtenues à partir du backbone.
- En d'autres termes, le cou collecte des cartes de caractéristiques de différentes étapes de la colonne vertébrale.

Activité :

- Effectuer une concaténation ou une fusion de caractéristiques de différentes échelles afin que le réseau puisse détecter des objets de différentes tailles.
- Incorporer des informations contextuelles pour améliorer la précision de la reconnaissance en considérant le contexte plus large de la scène.
- Réduire la résolution spatiale et la dimensionnalité des ressources pour simplifier les calculs. Cela augmente la vitesse, mais peut également réduire la qualité du modèle. [23]

B.3) Head :

Fonction : La tête est la dernière partie du réseau et est chargée de produire des sorties réseau telles que le cadre de délimitation et valeur de confiance pour la détection d'objets.

Activité :

- Créer des cadres de délimitation associés aux objets possibles dans une image.
- Attribuer une valeur de confiance à chaque cadre englobant pour indiquer la probabilité que l'objet existe.
- Trier les objets dans des cadres de délimitation en fonction de la catégorie. [23]

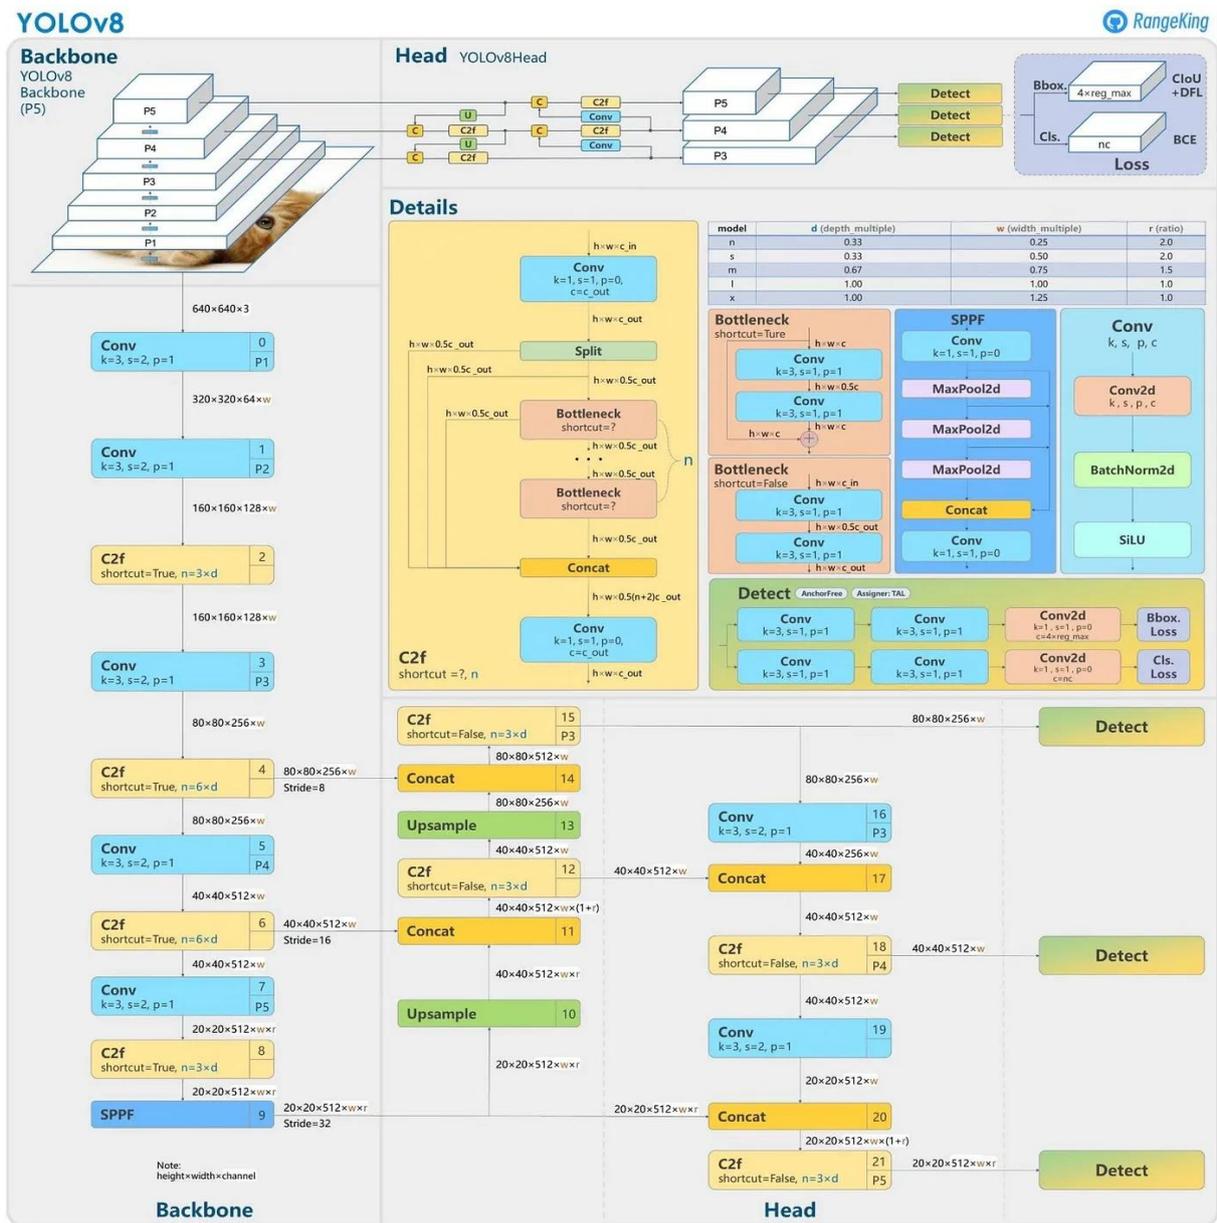


Figure II-10 : YOLOv8 [28]

C. Quelques détails importants

C.1) Conv

La convolution est une opération mathématique qui combine deux fonctions pour produire une troisième fonction.

Dans le traitement de l'image et du signal, la convolution est souvent utilisée pour filtrer des images ou des signaux afin de mettre en valeur certains modèles.

Les réseaux de neurones convolutifs (CNN) utilisent des convolutions pour extraire des caractéristiques d'entrée telles que des images. Les plis sont structurés par un noyau (K), une foulée (s) et un rembourrage (p).

C.2) Noyau

Un noyau, également appelé filtre, est un petit tableau de nombres qui est décalé sur l'entrée (image ou signal) pendant l'opération de convolution.

L'objectif est d'appliquer des opérations locales à l'entrée pour détecter des fonctionnalités spécifiques.

Chaque élément du noyau représente un poids qui est multiplié par la valeur correspondante dans l'entrée lors de la convolution. [23]

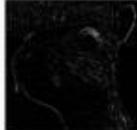
$\begin{bmatrix} 1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & 1 \end{bmatrix}$	
$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$	
$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$	

Figure II-11 : Noyau [29]

C.3) Foulée

La foulée est la quantité de déplacement subie par le noyau lorsqu'il se déplace à travers l'entrée pendant la convolution.

L'étape 1 signifie que le torse se déplace d'une position à la fois, et l'étape 2 signifie que le torse saute de deux positions à chaque mouvement. Cette étape affecte directement la dimension spatiale de la sortie de convolution.

Des pas plus grands peuvent réduire la dimensionnalité de la sortie, tandis que des pas plus petits préservent davantage d'informations spatiales.

Des pas plus importants réduisent la quantité de calcul, ce qui augmente la vitesse de fonctionnement et peut avoir un impact direct sur la qualité. [23]

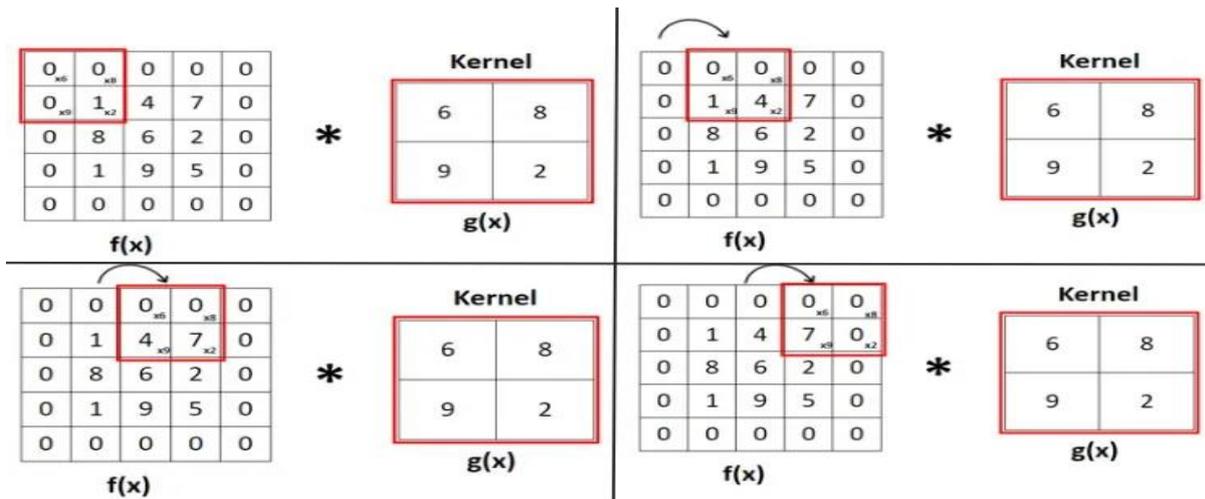


Figure II-12 : Foulée [24]

C.4) Remplissage

Le « remplissage » fait référence à l'ajout de pixels supplémentaires aux bords (généralement nuls) de l'image d'entrée avant d'appliquer l'opération de convolution.

Ceci est fait pour garantir que les informations sur les bords de l'image sont traitées de la même manière que les informations au centre pendant l'opération de convolution.

Lorsqu'un filtre (noyau) est appliqué à une image, le filtre traverse généralement l'image pixel par pixel.

Si aucun remplissage n'est appliqué, les pixels situés sur les bords de l'image auront moins de voisins que les pixels centraux, et les informations contenues dans ces zones peuvent être perdues. [23]

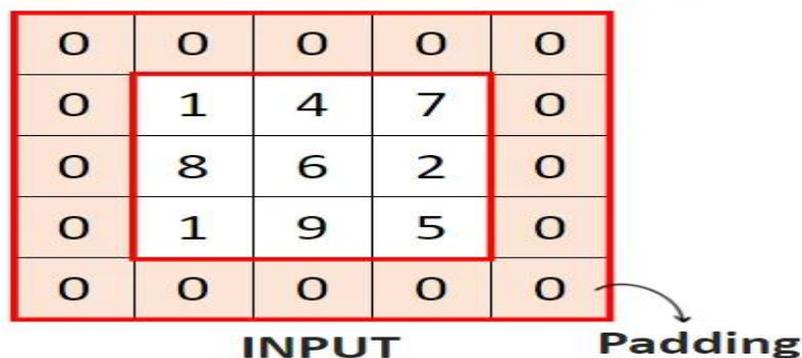


Figure II-13 : Remplissage [24]

C.5) Feature Fusion

Le module C2f combine efficacement des fonctionnalités sémantiques de haut niveau et des informations spatiales de bas niveau pour améliorer la précision de la détection des petits objets. [25]

C.6) Bottlenecks and SPPF

Les goulots d'étranglement dans le backbone CSPDarknet53 réduisent la complexité de calcul tout en maintenant la précision.

De plus, la couche SPPF (Spatial Pyramid Pooling Fast) capture les caractéristiques à plusieurs échelles pour améliorer encore les performances de détection. [25]

D. Fonctionnement de YOLOv8

Il s'agit de l'avant-dernière version de la populaire famille YOLO, s'appuyant sur son prédécesseur et introduisant de nouvelles fonctionnalités et améliorations.

Voici un aperçu du principe de fonctionnement de yolov8 :

- Division de l'image :

L'image d'entrée est d'abord divisée en une grille de cellules de taille normale 13 x 13 ou 26 x 26.

Chaque cellule est responsable de la prédiction des objets dans sa zone allouée.

- Extraction des caractéristiques :

Les réseaux de neurones convolutifs profonds (CNN) extraient des fonctionnalités de haut niveau à partir d'images.

Ces fonctionnalités capturent des détails importants tels que les bords, les formes et les textures qui sont importants pour l'identification des objets. [26]

- Prédiction de la boîte englobante :

Pour chaque cellule, YOLOv8 prédit plusieurs cadres de délimitation représentant l'emplacement et la taille des objets potentiels.

La prédiction inclut les coordonnées du centre du cadre de délimitation, sa largeur et sa hauteur. [26]

- Prédiction de classe :

En plus de la boîte englobante, YOLOv8 prédit la probabilité que chaque objet appartenant à une classe particulière (personne, voiture, chien, ...etc.).

Image d'une grille de cellules superposée à un diagramme circulaire représentant les probabilités de classe associées à chaque boîte englobante. Cela permet de distinguer différents objets au sein d'une même cellule. [26]

- Suppression non maximale (NMS) :

Les approches basées sur une grille prédisent souvent des cadres de délimitation qui se chevauchent.

Les cadres de délimitation des images se chevauchent autour du même objet dans la grille de cellules. Elle éliminer ces redondances en sélectionnant le cadre de délimitation le plus fiable pour chaque objet.

Suppression des valeurs non maximales de l'affichage de l'image, suppression des cadres de délimitation en double, ne laissant que le cadre de délimitation le plus fiable pour chaque objet. [26]

- Sortie :

YOLOv8 génère enfin une liste d'objets détectés, chacun avec une boîte englobante, un score de confiance et une classe prédite. [26]

E. Avantages de YOLOv8 :

YOLOv8 présente plusieurs avantages par rapport aux modèles précédents et aux autres modèles de détection d'objets ;

- Haute précision : YOLOv8 atteint une précision de pointe sur une variété de tests de détection d'objets.
- Vitesse en temps réel : Ce modèle offre une excellente vitesse d'inférence et convient aux applications en temps réel telles que les voitures autonomes et la robotique.
- Efficacité : YOLOv8 est léger et nécessite moins de ressources informatiques que les autres modèles, ce qui le rend idéal pour le déploiement sur des appareils de pointe. [25]

F. Applications de YOLOv8

La polyvalence de YOLOv8 le rend adapté à une variété d'applications, notamment :
Voitures autonomes : La détection d'objets est importante pour que les voitures autonomes se déplacent en toute sécurité et évitent les obstacles.

- Sécurité et surveillance : YOLOv8 peut être utilisé pour la détection d'anomalies, la détection d'intrusion et le suivi d'objets dans les systèmes de sécurité.
- Vente au détail et fabrication : Le modèle peut être utilisé pour l'identification des produits, le contrôle des stocks et le contrôle qualité dans les environnements de vente au détail et de fabrication. [25]
- Robotiques : YOLOv8 permet aux robots d'être conscients de leur environnement et d'interagir intelligemment avec les objets.
- Images médicales : les modèles peuvent faciliter le diagnostic médical en identifiant automatiquement les objets dans les images médicales, tels que les tumeurs ou les anomalies[25].

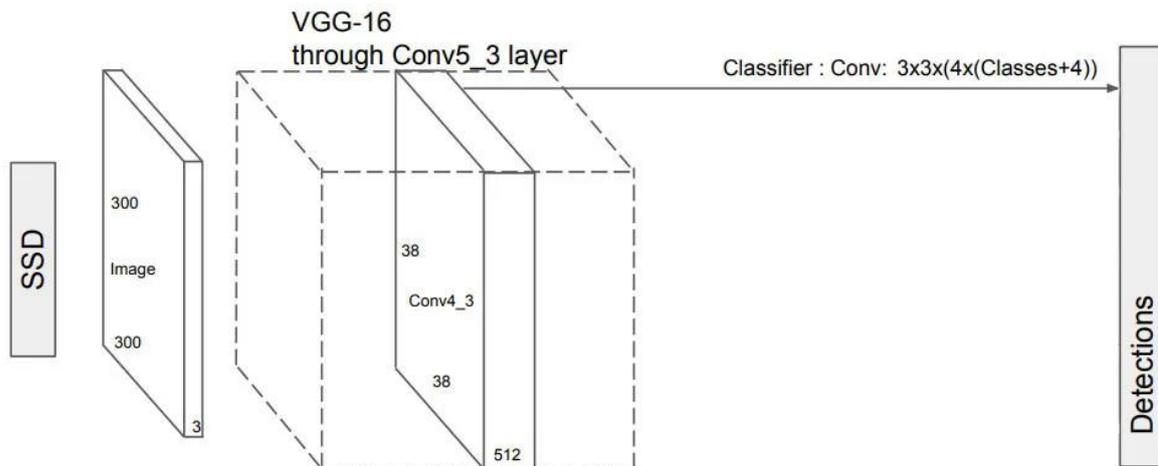


Figure II-15 : SSD détection [45]

A.1 VGG16 Réseau convolutif pour la classification et la détection :

VGG16 est un modèle de réseau neuronal convolutif proposé par K. Simonyan et A. Zisserman de l'Université d'Oxford. [29]

Il est amélioré par rapport à AlexNet en remplaçant les filtres de grande taille de noyau (1×1 et 5×5 dans les premières et deuxième couches convolutives, respectivement) par plusieurs filtres de taille de noyau 3×3 , l'un après l'autre. [29]

A.2 L'architecture

L'architecture décrite ci-dessous est VGG16.

- L'entrée de la couche cov1 est une image RVB de taille fixe de 224 x 224. Cette image traverse une pile de couches convolutives (Conv) dans lesquelles ont utilisé des filtres avec de très petits champs récepteurs : 3×3 (c'est-à-dire pour capturer les notions (objet) de taille minimale (de gauche/droite, haut/bas, centre).
- Une configuration utilise également un filtre de convolution 1×1 , qui peut être considéré comme une transformation linéaire des canaux d'entrée.
- La foulée de convolution est fixée à 1 pixel ; le remplissage spatial de Conv.
- L'entrée de la couche est telle que la résolution spatiale est maintenue après convolution. C'est-à-dire le remplissage est de 1 pixel pour une Conv 3×3 .
- Le max Pooling est effectué par jusqu'à cinq couches de regroupement suivies de plusieurs transformations.
- Le Max Pooling est effectué sur une fenêtre de 2×2 avec foulée 2.

- Conv-1 Layer à 64 filtres, Conv-2 à 128 filtres, Conv-3 à 256 filtres, Conv 4 et Conv 5 ont 512 filtres.
- Trois couches entièrement connectées (FC) suivent une pile de couches convolutives : les deux premières ont chacune 4 096 canaux, la troisième effectue une classification 1 000 voies et contient donc 1 000 canaux (un pour chaque classe). La couche finale est la couche SoftMax (c'est la fonction d'activation utilisée en dernière couche d'un réseau de neurone pour déterminer la classe de l'objet ayant la plus forte probabilité). [29]

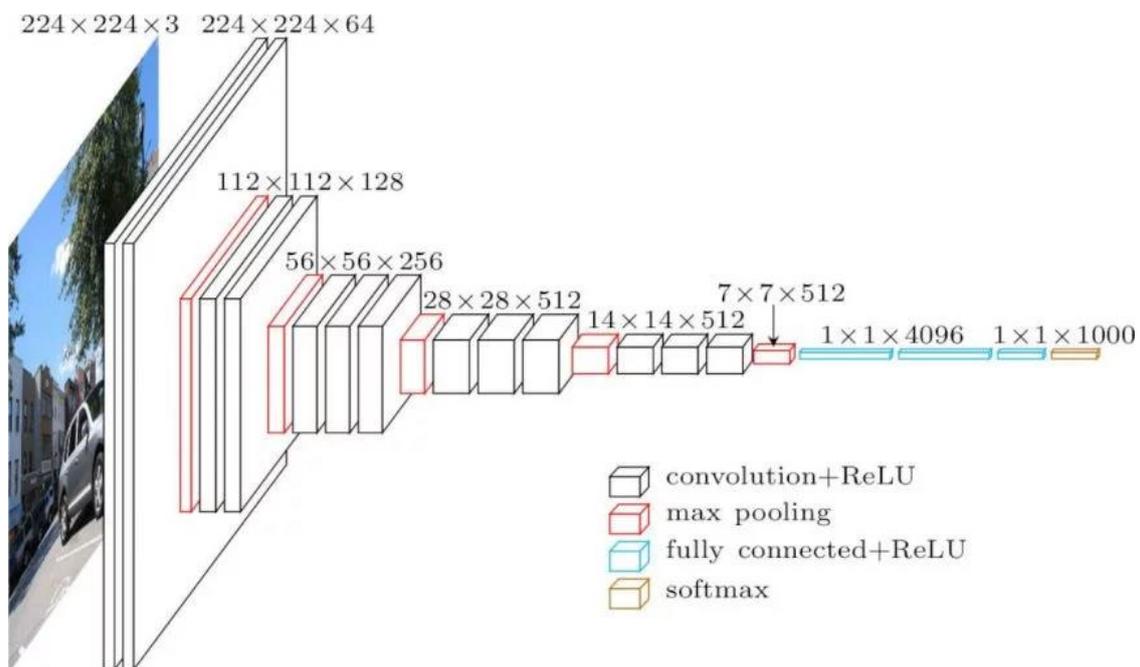


Figure II-16 : VGG16 [46]

- Application des filtres de convolution pour détecter les objets

Il se compose de plusieurs couches convolutives empilées les unes sur les autres et ajoutées au sommet du modèle.

Cela vous donnera la sortie sous forme de cadre de délimitation de l'objet.

Ces couches convolutives reconnaissent différents objets dans l'image.

B) Comment fonctionne le SSD

SSD est basé sur l'utilisation d'un réseau convolutif qui génère plusieurs boîtes englobantes de différentes tailles et évalue la présence d'instances de classe d'objets dans ces boîtes, suivie d'une étape de suppression non maximale qui effectue la détection finale. [27]

Les fonctionnalités ont été extraites à l'aide de neuf couches de fonctionnalités à partir des modules de taille 38×38 , 19×19 , 10×10 , 5×5 , 3×3 et 1×1 .

Au premier niveau du calculateur de convolution, la taille de l'image d'entrée était de 300×300 .

Au niveau convolutif, nous avons utilisé un filtre 3×3 généré aléatoirement pour extraire 64 caractéristiques et adopté l'activation de la fonctionnalité d-ReLu pour supprimer les valeurs négatives.

Plus tard, la normalisation par lots a été introduite pour améliorer la stabilité de la distribution des données.

Après deux cycles d'extraction de caractéristiques convolutives, la couche de Pooling a réduit la taille de l'image à 150×150 pour la deuxième série de calculs de convolution.

Le filtre a extrait 128 caractéristiques au deuxième niveau de caractéristiques calculées par convolution. [30]

Il en va de même pour le reste des calculs.

Enfin, la couche de regroupement a réduit l'image à une taille de 1×1 .

Puis on rassemble l'intégralité des caractéristiques ainsi extraites et appliquer la suppression non maximale. [30]

Suppression non maximale (NMS)

SSD utilise la suppression non maximale pour supprimer les propositions de cadre de délimitation en double pour le même objet. Tous les résultats prédits sont classés du plus confiant au moins confiant en fonction du degré de confiance de la classification, et cela grâce à la valeur IoU ainsi obtenue qui ne dépasse pas un certain seuil et les N premiers résultats sont utilisés. [31]

Sortie :

SSD génère enfin une liste d'objets détectés, chacun avec une boîte englobante, un score de confiance et une classe prédite. [26]

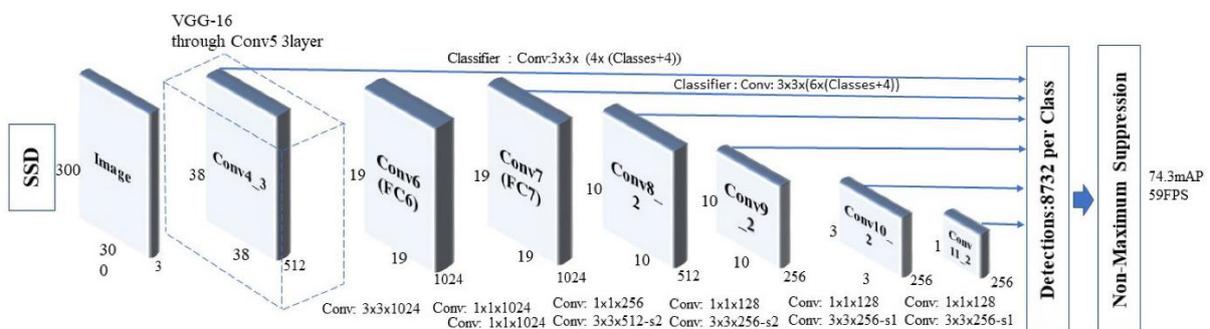


Figure II-17 : Structure du modèle de détecteur MultiBox à tir unique [47]

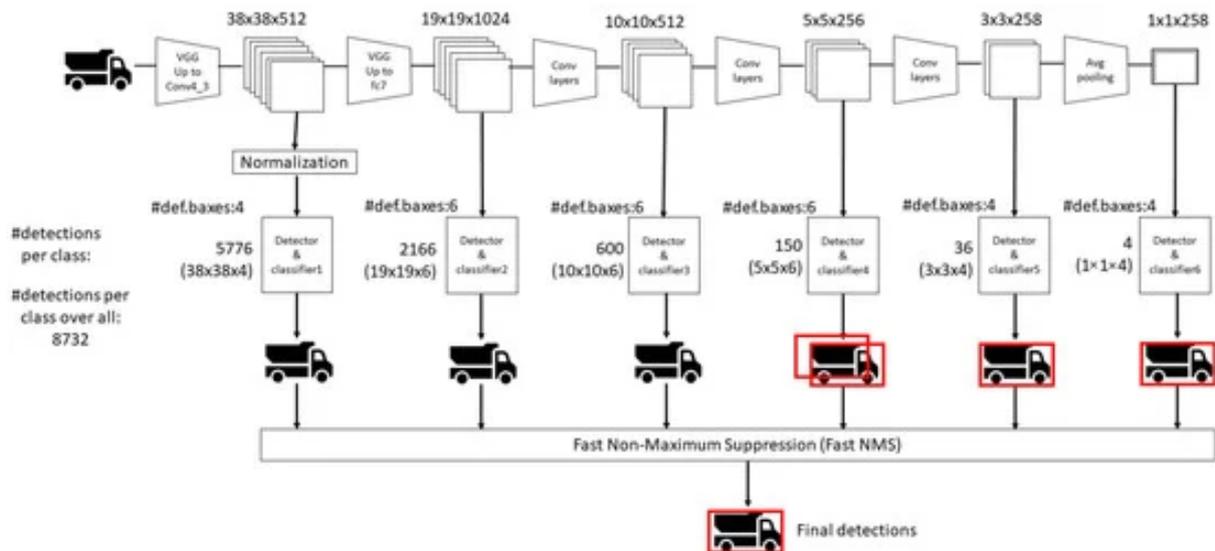


Figure II-18 : Processus de détection des caractéristiques de la cible du détecteur MultiBox à tir unique [47].

1. Avantages des SSD :

Les SSD présentent de nombreux avantages, notamment en termes de rapidité et d'efficacité.

La détection d'objets en temps réel est possible grâce à l'utilisation d'un réseau unique qui favorise leurs rapidités. [32]

2. Inconvénients des SSD :

Étant donné que le SSD repose sur un seul réseau, il n'est pas aussi précis que les méthodes alternatives telles que la famille de techniques R-CNN. [32]

C) Récapitulation

SSD n'utilise pas de réseau de proposition de région et prédit les cadres de délimitation directement à partir des cartes de fonctionnalités en un seul passage.

Plus rapide peut atteindre une précision de pointe comparable à R-CNN, mais fonctionne beaucoup plus rapidement, ce qui le rend largement utilisé pour la détection d'objets en temps réel. [31]

II.3 Comparaison entre les modèles de détection d'objets : R-CNN, YOLO et SSD

Les principaux modèles de détection d'objets actuellement utilisés sont Faster R-CNN, YOLO et SSD.

Chaque modèle présente ses propres compromis en termes de complexité, de rapidité, de précision et d'efficacité. [33]

A) Comparaison des différents modèles

Modèle	Complexité	Vitesse	Exactitude	Efficacité	Architecture
Faster R-CNN	Haute	Lente	Haute	Moins efficace	VGG16
YOLO	Moyenne	Rapide	Moyenne	Efficace	Darknet53
SSD	Basse	Rapide	Haute	Efficace	VGG16

Tableau I : Comparaison entre les algorithmes de détection

Comme le montre le tableau, le R-CNN rapide se caractérise par sa précision, mais son architecture complexe le rend lent et moins efficace. [33]

Les modèles YOLO réduisent le temps d'inférence, mais peuvent se faire au détriment de la précision.

Le modèle SSD offre un équilibre efficace entre vitesse et précision, ce qui en fait un choix polyvalent pour de nombreuses applications. [33]

B) Comparaison en termes de performances

Comparaison des performances entre les modèles YOLOv8, SSD et Faster R-CNN.

Modèle	Images par seconde (FPS)
YOLOv8	40-155
SSD	22-46
Faster R-CNN	5-7

Tableau II : études comparatives en terme temps d'exécution

Observations :

- Images par seconde indique le nombre d'images traitées par seconde (FPS ou Frame per second).
- Pour 44-155, 22-46 et 5-7 :
 1. 44, 22 et 5 représentent les bornes inférieures des intervalles des nombres des images qui seront traitées par YOLOv8, SSD et Faster R-CNN.

2. 155, 46 et 7 représentent les bornes supérieures des intervalles des nombres des images qui seront traitées par YOLOv8, SSD et Faster R-CNN.

Comme le montre le tableau, YOLOv8 surpasse à la fois le SSD et le Faster R-CNN en termes de vitesse, soulignant encore d'avantage son adéquation aux applications en temps réel. [33]

II.4 Conclusion

Les algorithmes de détection d'objets ont révolutionné le monde, chacun présente des qualités propres à lui-même qui le rends irremplaçable. Ils sont utilisés dans des domaines tels que la conduite autonome, la surveillance, la reconnaissance faciale et l'imagerie médicale. Dans le prochain chapitre on va avoir un aperçu général sur le monde des drones et présenter le drone qu'on va l'utiliser pour faire des expérimentations.

CHAPITRE III : Drones de surveillance

III.1 Introduction

La technologie continue de repousser les limites de ce qui était autrefois considéré comme impossible.

Dans cet environnement, les drones de surveillance sont devenus un outil puissant dans le domaine de la surveillance aérienne.

Ce type de véhicule aérien sans pilote est équipé d'une technologie de pointe et peut voler avec précision dans le ciel. Dans ce chapitre nous présenterons les différents drones de surveillance, leurs objectifs et nous ferons un meilleur choix parmi ces technologies aériennes.

III.2 Les drones de surveillance

Les drones de surveillance, également appelés véhicules aériens sans pilote (UAV) ou systèmes d'avions sans pilote (UAS), sont des véhicules aériens sans pilote de pointe qui peut voler de manière autonome ou être contrôlé à distance depuis le sol. Equipés de capteurs et de caméras avancés, ils permettent un accès sans précédent à des endroits difficiles et fournissent des données et des informations en temps réel. [34]

Ils jouent un rôle important dans des applications telles que la détection d'objets et la reconnaissance d'objets. [34]

Les drones peuvent être de n'importe quelle taille, de quelques centimètres à des dizaines de mètres, mais la plupart des concepteurs choisissent de conserver une taille petite (de quelques centimètres à un peu plus d'un mètre).

Les drones sont souvent utilisés par les militaires, mais d'autres membres de la société civile, comme les chercheurs, les entreprises, les étudiants et même les organisations humanitaires, s'intéressent également à l'utilisation civile de mini-drones qui peuvent améliorer la vie de plusieurs personnes grâce à de meilleurs produits et services. [35]

A) Caractéristiques de drone de surveillance (UAVs)

Ils sont caractérisés par :

Contrôlé à distance : les drones peuvent être contrôlés à distance par un opérateur humain autonome. Cela signifie qu'il peut suivre des itinéraires prédéfinis sans intervention humaine directe. [36]

Taille et portée : Les drones peuvent être aussi petits que des drones récréatifs ou aussi grands que des drones militaires. La portée de vol est déterminée par la technologie embarquée et la batterie. [36]

Capteurs : Le drone est équipé de capteurs tels que des caméras, des capteurs lidar, radar et infrarouge. Ces capteurs peuvent être utilisés pour collecter des données pour diverses applications.

Temps de vol : Le temps de vol du drone dépend de la batterie et de l'efficacité énergétique. Certains drones peuvent voler plusieurs heures, tandis que d'autres ont une courte portée.

Stabilité et maniabilité du : Le drone est conçu pour être stable en vol et capable de fonctionner dans diverses conditions météorologiques.

Charge utile : Certains drones sont conçus pour transporter des charges utiles telles que des caméras haute résolution, des capteurs scientifiques, des marchandises et même des armes. [36]

Communication : Les drones utilisent des systèmes de communication pour transmettre des données à l'opérateur ou à d'autres drones. Cela peut se faire via des liaisons radio, des satellites ou des réseaux de communication. [36]

B) Les différents types de drone (UAVs)

Il existe une variété de drones disponibles, chacun étant conçu pour remplir un créneau spécifique.

La capacité de s'adapter à un si large éventail de niches opérationnelles tout en conservant la même idée de base que les véhicules aériens sans pilote (UAV) est au cœur de ce qui rend les drones uniques. Nous avons :

B.1 Drones à rotor unique

- Les drones ont souvent une faible stabilité et, même s'ils peuvent survoler une certaine zone, ils peuvent également être difficiles à piloter par rapport aux drones, qui ont plusieurs rotors pour maintenir l'équilibre dans les airs.
- Ils n'utilisent qu'un seul rotor (parfois en plus d'un stabilisateur horizontal) et peuvent souvent générer une poussée plus efficace que leurs homologues multi rotor. [37]



Figure III-1 : Drones à rotor unique [55]

B.2 Drones multi rotors

- Ces rotors supplémentaires permettent à l'avion de maintenir plus facilement l'équilibre et de continuer à planer. Ces unités offrent donc une excellente stabilité, qui atteint souvent son maximum après 30 minutes de vol. [37]
- Ils sont faciles à piloter.
- La plupart des types de drones multi rotor sont incapables de transporter de lourdes charges utiles en raison du déséquilibre maintenu par le rotor d'équilibrage. [37]



Figure III-2 : Typhoon H480 [56]

B.3 Grands drones de combat

Ces unités peuvent fonctionner pendant 14 heures à une portée de 1 000 kilomètres.

Il est capable tirer des missiles air-sol et des bombes à guidage laser sur des cibles. [37]



Figure III-3 : Grands drones de combat [54]

B.4 Grand Drones de reconnaissance

Il existe également de gros drones qui ne sont pas utilisés pour le combat. Ceux-ci peuvent prendre en charge diverses tâches, souvent de reconnaissance, et sont utilisés pour des missions de reconnaissance à grande échelle. [37]

Ces unités peuvent fonctionner pendant 14 heures à une portée de 1 000 kilomètres. [37]



Figure III-4 : Grand drones de reconnaissance [54]

Comme nous venons de découvrir les véhicules aériens sans pilote (UAVs) sont nombreux et chacun possède un avantage qui le rends spécial. Dans notre cas si nous avons opter pour un drone multi-rotors plus précisément un Typhoon H480.

B.5 Typhoon H480



Figure III-5 : Typhoon H480 [57]

Typhoon H480 de Yuneec profite de l'expertise de INTEL, société mère de Yuneec et leader mondial dans les processeurs électroniques, pour proposer un drone à la pointe de la technologie.

Le drone Typhoon H480 est un Hexacopter (6 moteurs). Il est Plus spécialement conçu pour la réalisation de prises de vues aériennes, avec un appareil photo C23 et un capteur, il est capable de capturer des photos et des vidéos de qualité professionnelle en 4K à 60 images par seconde. [43]

A) Caractéristiques (constituent) de drone Typhoon H480

Typhoon H480 est un drone hors normes possèdent des caractéristiques :

- Six rotors
- Durée de vol : Jusqu'à 25 min
- Dimension : 520x457
- Batterie : Batterie Lipo 4S 14,8 V (POWER 4)
- Altitude de vol maximale : 122 m (400 pieds, réglable via GUI)
- Vitesse de descente maximale : (3 m/s)
- Longueur du bras du cadre : 187 mm
- Dimension du train d'atterrissage : 100° [38]
- En termes de Poids et licence, le Typhoon H pèse 2 kg, ce qui le place dans la catégorie des drones nécessitant une licence pour fonctionner. [39]
- Le Typhoon H480 est équipé d'une caméra 4K montée sur un cardan 360°, cela permet une prise de vue panoramique et vous donne plus de flexibilité lors de la capture d'images. [45]
- Les modèles dotés de la technologie Intel RealSense intègrent deux capteurs à ultrasons orientés vers le bas et deux caméras optiques qui fournissent des images 3D à l'hélicoptère. Cela améliore la détection et l'évitement des obstacles. [39]
- Le modelé est équipé d'une caméra Intel RealSense R200 et d'un processeur Intel® qui communique en permanence avec le vol. [40]

a) C'est quoi la Technologie Intel RealSense ?

Le module Intel RealSense est un système d'évitement d'obstacles (vol de manière autonome, portant la créativité et la sécurité à un tout autre niveau) et un système de calcul de trajectoire le plus avancé sur le marché des drones. [40]

Le module RealSense possèdent :

- Poids : 70 g
- Dimensions : 153*107 mm
- Distance de détection maximale vers l'avant face aux obstacles : 10 m

- Distance entre RealSense et le sol : 4.5m
- Vitesse maximale d'évitement de collision : 5m/s
- Champ de vision (vertical) : 40°
- Champ de vision (horizontal) : 60° [38]

b) LA CAMERA CGO3+ possèdent :

- Poids : 255 g
- Pixels effectifs : 12,4 mégapixels
- Fourchette de transmission vidéo : jusqu'à 2 km
- Système de transmission : 5,2 GHz — 5,8 GHz
- Vidéo UHD : 4K 30 fps [38]

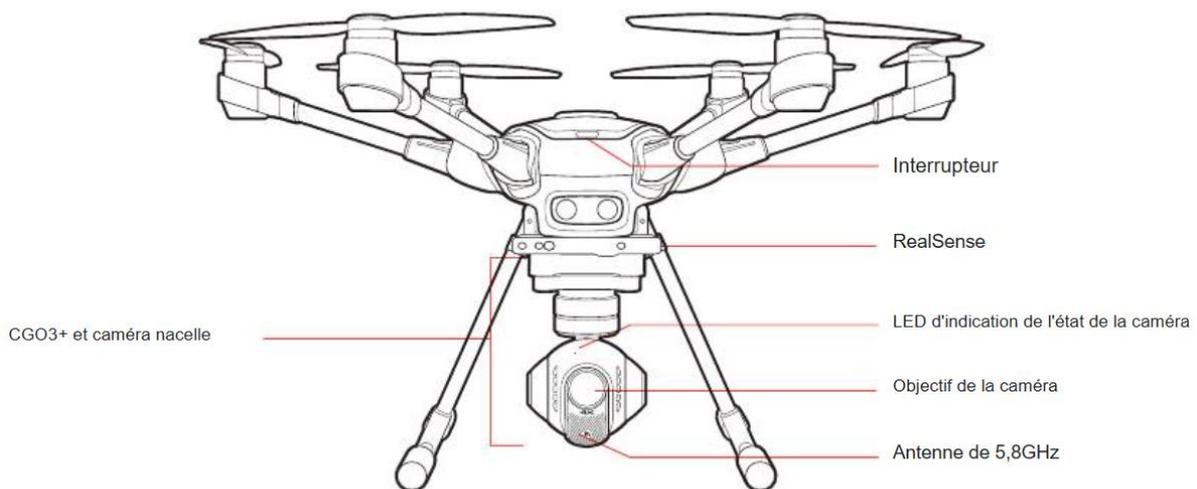


Figure III-6 : Typhoon H480 [59]

B) Fonctionnement de drone Typhoon H480

Pour le bon fonctionnement du drone Typhoon H480, il faut :

- Placer le drone Typhoon H480 sur une surface plane et stable.
- Allumer le drone.
- Si un signal GPS correct est reçu, le moteur peut démarrer.
- Le Typhoon H480 peut suivre une trajectoire de vol prédéfinie à l'aide de points GPS définis.
- Pouvoir contrôler la vitesse en ajustant l'accélérateur.
- Pouvoir contrôler la caméra 360° 2 pendant le vol. [38]

C) Les avantages du drone Typhoon H480

- Technologie RealSense : équiper ce drone d'un système d'évitement automatique d'obstacles. Cela améliore considérablement la sécurité des vols et évite les collisions avec des objets et des personnes.
- Hexacopter avec 6 moteurs : Contrairement au quadricoptère classique, le Typhoon H480 est équipé de 6 moteurs pour une stabilité de vol améliorée.
- Le bras extensible facilite le transport et le rangement.
- Qualité Vidéo UHD : Le drone est équipé d'une caméra UHD montée sur la nacelle qui pivote à 360° Cela vous permet d'enregistrer des vidéos de haute qualité et d'explorer sous différents angles. [41]

D) Les inconvénients du drone Typhoon H480

- Pas de caméra évolutive
- Autonomie encore trop faible
- Écart de prix élevé par rapport à la version dépourvue de RealSense. [41]

III.3 Conclusion

En résumé, les drones et leurs capacités se sont révélés utiles pour répondre aux besoins de nombreux secteurs, notamment la sécurité civile (pompiers et police), qui utilisent les capacités des drones pour protéger la population. Dans le prochain chapitre on va voir comment préparer un environnement virtuel sur lequel on va faire une simulation de détection faite par le drone Typhoon H480 sur un terrain forestier, ainsi que voir comment entraîner YOLO et comment préparer un Dataset pour faire l'entraînement de YOLO.

CHAPITRE IV : Simulation de drone pour la détection automatique des feux de forêt

IV.1 Introduction

La détection d'objets en temps réel est un domaine important de la vision par ordinateur moderne. Le but est d'identifier et de localiser des objets intéressants dans un flux d'images ou vidéo en temps réel. Parmi les algorithmes de détection les plus avancés nous avons : YOLO, SSD, et R-CNN.

Les technologies aéronautiques ont une grande responsabilité à la détecter et à prévenir les incendies en collectant et en transmettant des informations concrètes et fiables. Parmi ces technologies, nous avons les drones. Notre objectif dans ce chapitre est d'utiliser les drones pour la détection automatique des feux de forêt.

IV.2 Utilisation des drones pour la détection de feux de forêt

« Le drone est un outil qui nous permet de patrouiller au-dessus d'une zone suspecte, de se rendre rapidement sur un départ de feu, voire d'agir directement sur un feu, indique Éric Rodriguez, commandant du Service départemental d'incendie et de secours (Sdis) des Bouches-du-Rhône. En Outre la rapidité, la précision et l'accessibilité à tout type de terrain, le drone permet également de protéger la vie de nos hommes et femmes et, en cas de danger, de leur substituer une machine. » [42]

« De plus, équipé des nouvelles technologies embarquées, il peut faire mieux que l'homme. » [42]

L'utilisation des outils bien appropriés sont donc nécessaires pour une meilleure utilisation de drone à la détection des feux de forêt. Dans notre cas si, Nous avons besoin :

A) Système d'exploitation

Linux (Ubuntu), qui est un gratuit et open source installée sur une machine virtuelle (virtuel box).

B) Conception de drone

Pour la conception d'un drone nous aurions besoin de :

a) PX4 Autopilot

PX4 Autopilot est un système de contrôle de vol open source pour drones et autres véhicules sans pilote. Il est actuellement utilisé dans les applications des drones industriels et des drones civils, et il est devenu une plateforme de recherche majeure pour les drones. Ceci est rendu possible par une forte communauté de contributeurs qui travaillent ensemble chaque jour pour l'améliorer. [43]

Il assure la construction et le pilotage des véhicules sans pilote sur une base de code unifiée pour plusieurs types de véhicules, notamment les drones, les avions, les rovers et les bateaux ça dernière version en date est 1.14.

PX4 est hébergé par Drone_code (une organisation à but non lucratif de la Linux Fondations). [43]



Figure IV-1 : Px4 Autopilot

a.1 Installation de PX4 Autopilot

Le PX4 peut être construit à partir du code source sur la console (Terminal) ou dans un IDE, pour les cibles simulées et matérielles.

Pour l'installer, nous devons entrer les commandes suivantes dans un terminal :

```
cd ~  
git clone https://github.com/PX4/PX4-Autopilot.git --recursive  
bash ./PX4-Autopilot/Tools/setup/ubuntu.sh
```

b) ROS

ROS (Robot Operating System), comme son nom l'indique, est un système d'exploitation pour robots.

Semblable aux systèmes d'exploitation pour PC, serveurs ou appareils autonomes, ROS est un système d'exploitation complet pour la robotique de service (ce service répond également à un autre besoin : la communication synchrone entre deux nœuds.).

La dernière version en date est ROS2 qui utilise une distribution pour un meilleur usage. Une distribution ROS et un ensemble version de package ROS, Celles-ci sont similaires aux distributions Linux (telles que Ubuntu).

Le but d'une distribution ROS est de permettre aux développeurs de travailler avec une base de code relativement stable jusqu'à ce qu'ils soient prêts à faire avancer quelque chose, et dans ce cas si nous utilisons la distribution humble la dernière version et la plus stable de tous.



Figure IV-2 : ROS2 Humble

b.1 Installation de ROS2

Pour installer ROS2 nous devons activer la référence d'Ubuntu :

```
sudo apt install software-properties-common  
sudo add-apt-repository universe
```

Puis terminer par installer ROS2 humble en exécutant sur le terminal :

```
sudo apt update && sudo apt upgrade -y  
sudo apt install ros-humble-desktop  
sudo apt install ros-dev-tools
```

Il faut également installer le middleware uXRCE-DDS par exécuter les commandes suivantes sur le terminal :

```
cd ~  
git clone https://github.com/eProxima/Micro-XRCE-DDS-Agent.git  
cd Micro-XRCE-DDS-Agent  
mkdir build  
cd build  
cmake ..  
make  
sudo make install  
sudo ldconfig /usr/local/lib/
```

uXRCE-DDS est un des logiciels de ROS2 et permet donc au PX4 de communiquer efficacement avec d'autres systèmes et capteurs pour faciliter le partage de données, on parle de la communication Agent & Client.

c) Gazebo

Gazebo Classic est un puissant environnement de simulation 3D pour robots autonomes, particulièrement adapté aux tests d'évitement d'objets et de vision par ordinateur.



Figure IV-3 : Gazebo

c.1 Installation de gazebo

```
sudo apt install aptitude  
sudo aptitude install gazebo libgazebo11 libgazebo-dev
```

d) MAVSDK

MAVSDK est une collection de bibliothèques dans divers langages de programmation permettant de se connecter à travers une interface aux systèmes MAVLink (protocole de messagerie très léger pour communiquer avec les drones et entre les composants embarqués du drone) tels que les caméras et les systèmes au sol.

La bibliothèque fournit une API simple pour gérer un ou plusieurs véhicules, accéder par programme aux informations et à la télémétrie des véhicules et contrôler les missions, les mouvements et d'autres opérations.

MAVSDK est multiplateforme : Linux, MacOS, Windows, Android et iOS.



Figure IV-4 : Gestion des véhicules

Dans ce cas si on utilise MAVSDK-Python.

d.1 Installation de MAVSDK

Pour installer MAVSDK-Python, il faut exécuter sur le Terminal les commandes suivantes :

```
pip install mavsdk  
pip install aioconsole  
pip install pygame
```

C) Contrôle et pilotage de drone

Pour le contrôle et le pilotage de drone, il faut utiliser QGROUNDCONTROL.

a) QGROUNDCONTROL

QGROUNDCONTROL est un logiciel de station de contrôle au sol utilisé pour la configuration, le contrôle et le pilotage des drones.

Il communique avec les drones à l'aide de messages MAVLink, qui est le protocole standard de communication entre les stations de contrôle au sol et les drones.



Figure IV-5 : QGROUNDCONTROL

a.1 Installation de QGROUNDCONTROL

Pour installer QGROUNDCONTROL, il faut :

- Télécharger l'interface (APK) QGROUNDCONTROL
- Installer (et exécuter) à l'aide des commandes du terminal :

```
chmod +x ./QGroundControl.AppImage  
./QGroundControl.AppImage
```

D) Procédure de détection de feux de forêt :

a) Choix des algorithmes de détection

Il est sans savoir que la détection d'objets est une technologie de pointe d'apprentissage automatique et d'apprentissage profond qui permet aux ordinateurs d'identifier et de localiser avec précision des objets (Flame, No_Flame) dans des images et des vidéos.

Divers algorithmes de détection sont donc mis à notre disposition comme YOLO, SSD et la famille R-CNN pour une meilleure précision avec une performance de haut niveau.

Chacun de ses algorithmes ainsi cités, a une particularité bien propre à lui-même et cela dépend juste du mode où nous l'employons.

1. YOLO

C'est un algorithme de détection d'objets temps réel qui traite 40 à 155 images par seconde. Alors sur un jeu de données de 3919 images nous avons annoté l'intégralité de ce Dataset et procédé par la suite à un entraînement au bout duquel nous avons pris 80% des images pour (entraînement) train | 10% valid | et 10% de test. Le résultat ainsi obtenu est illustré par la courbe si dessous avec une moyenne de précision mAP50 = 80%.

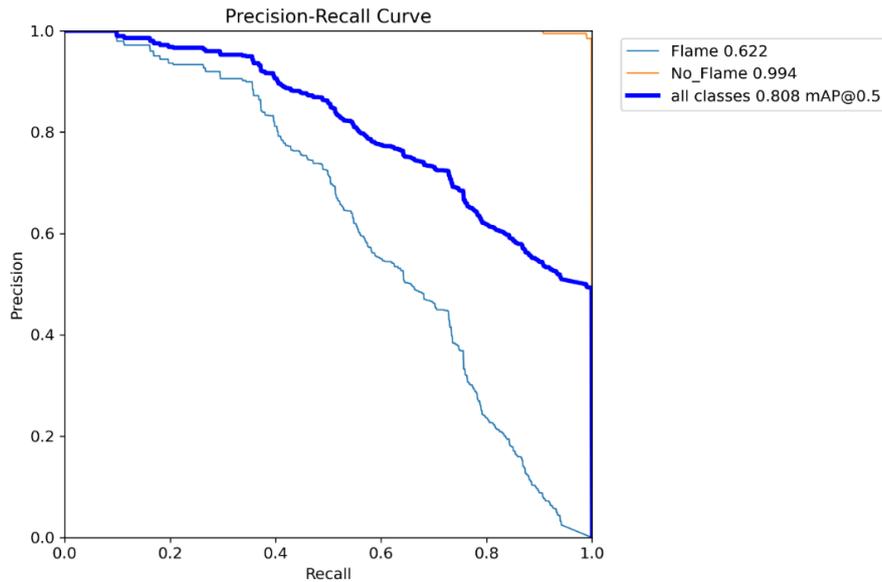


Figure IV-6 : Graphe Précision

2. SSD300

C'est un algorithme de détection d'objets temps réel qui traite 22 à 46 images par seconde. Alors sur le même jeu de données de 3919 images de YOLO, nous avons converti l'intégralité de ce Dataset qui avait été annotée, avec une perte de 3 images et une perte de données (pixels et annotations) considérables par rapport au redimensionnement de l'images (c'est à dire le SSD300 ne prends que des images de taille inférieure ou égale à (300*300) or nous avons des images de 512*512) ce qui a contribué à des pertes de donnée importantes. Puis nous avons procédé à l'entraînement au bout duquel nous avons pris 80% des image pour (entraînement) train | 10% valid | et 10% de test, le résultat ainsi obtenu est illustré par l images si dessous avec une moyenne de précision mAP50 = 73.72%.

```
/content/mAP
Calculating mAP at 0.50 IoU threshold..
47.44% = Flame AP
100.00% = No_Flame AP
mAP = 73.72%
```

Figure IV-7 : Pourcentages

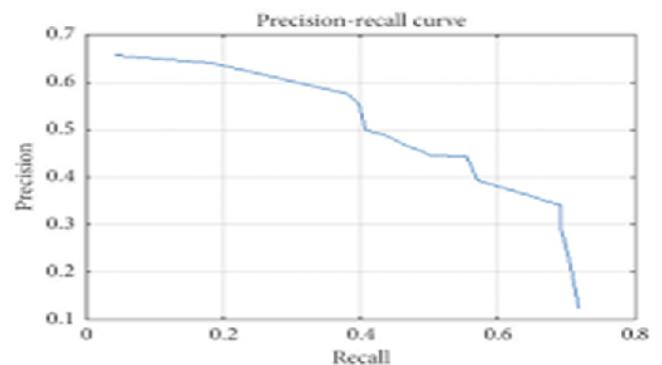


Figure IV- 8: Graphe de prédiction

Finalement l'algorithme SSD a un faible pourcentage en termes de précision sur notre Dataset par rapport à YOLO mais après tester sur un jeu de données SSD a montré un meilleur résultat par rapport à YOLO, et cela parce que le SSD300 prédit les zones de délimitation et les

classes en un seul passage, en se basant uniquement sur les cartes d'entités, sans recourir à un réseau de propositions de régions déléguées.

En revanche, YOLO divise l'image en une grille et prédit les boîtes englobantes et les classes pour chaque cellule de la grille. YOLO effectue plusieurs prédictions par cellules, ce qui lui permet d'obtenir une vitesse encore plus élevée par rapport à SSD.



Figure IV-9 : SSD Détection de feux



Figure IV-10 : YOLO Détection de feux

Après analyser face un problème aussi grave que les incendies de forêt, nous avons opté pour l'algorithme YOLO et cela grâce à sa rapidité en termes de traitement d'images et de (temps de réponse).

b) Détection des feux de forêt à travers l'algorithme YOLO

Pour détecter les feux de forêt avec YOLO nous devons :

Etape 1 :

- Créer un compte sur la plateforme RoboFlow

RoboFlow est une plateforme logicielle en ligne conçue pour l'annotation d'images et la gestion de données. Elle permet aux utilisateurs de télécharger des images, d'ajouter des cadres de délimitation aux images pour la détection d'objets et d'organiser des ensembles de données pour des projets d'apprentissage automatique.

Il offre des fonctionnalités telles que la possibilité de diviser les images en ensembles d'entraînement, de validation et de test et de les annoter).

- Créer un nouveau projet sur RoboFlow

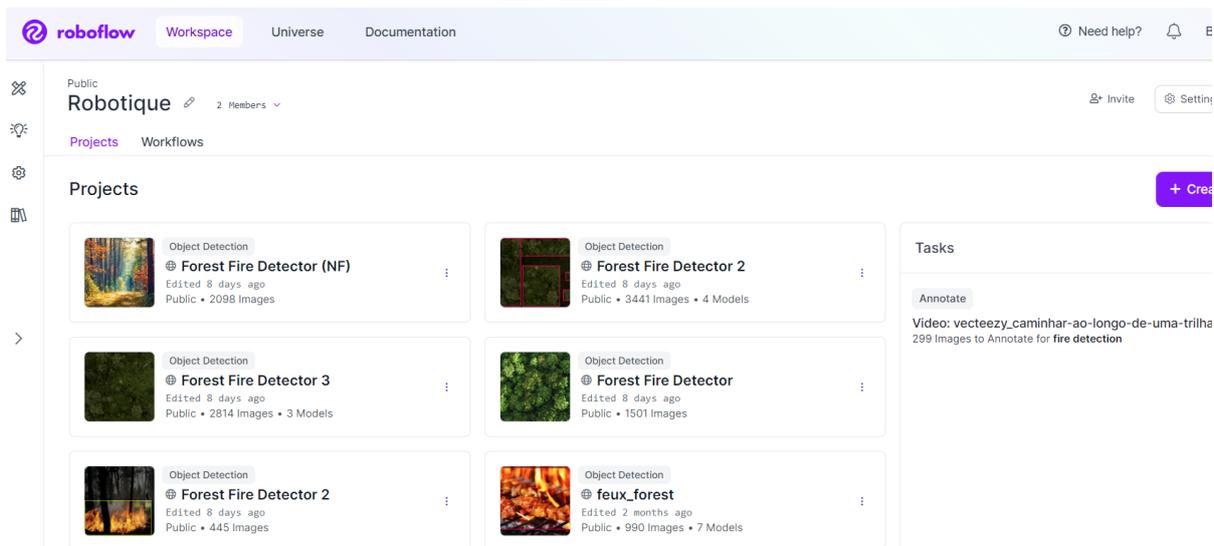


Figure IV-11 : Environnement de travail

Etape 2 : Télécharger (charger) l'intégralité des image (prêt de 3441 images).

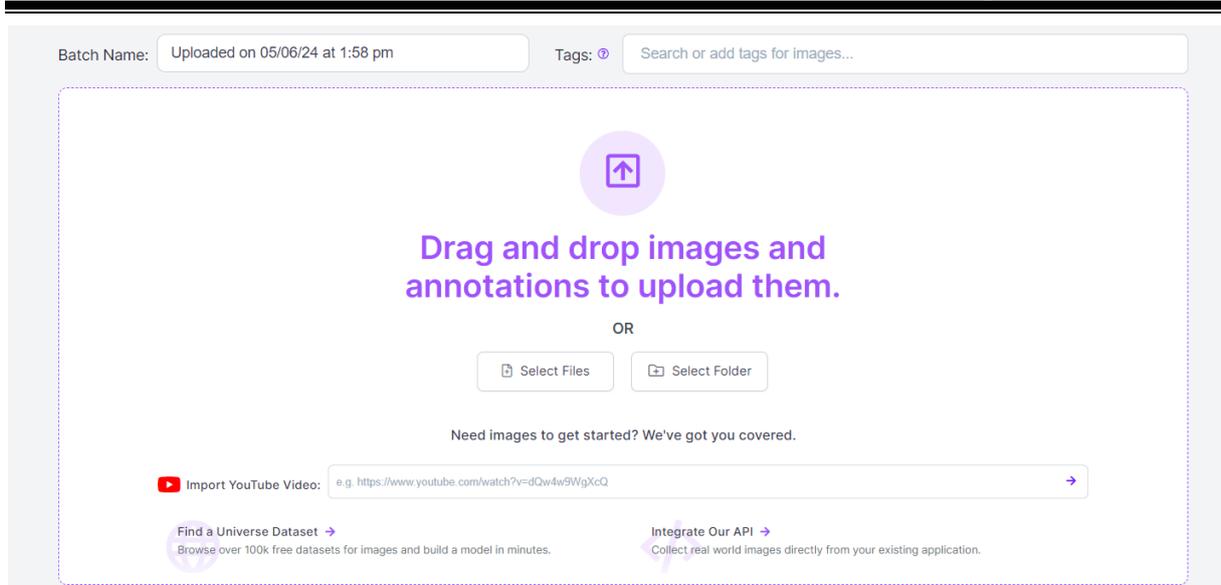


Figure IV-12 : Datasets à annoter

Etape 3 : Effectuer l'annotation des images (dessiner des cadres de délimitation tout en attribuant une classe à chacun).

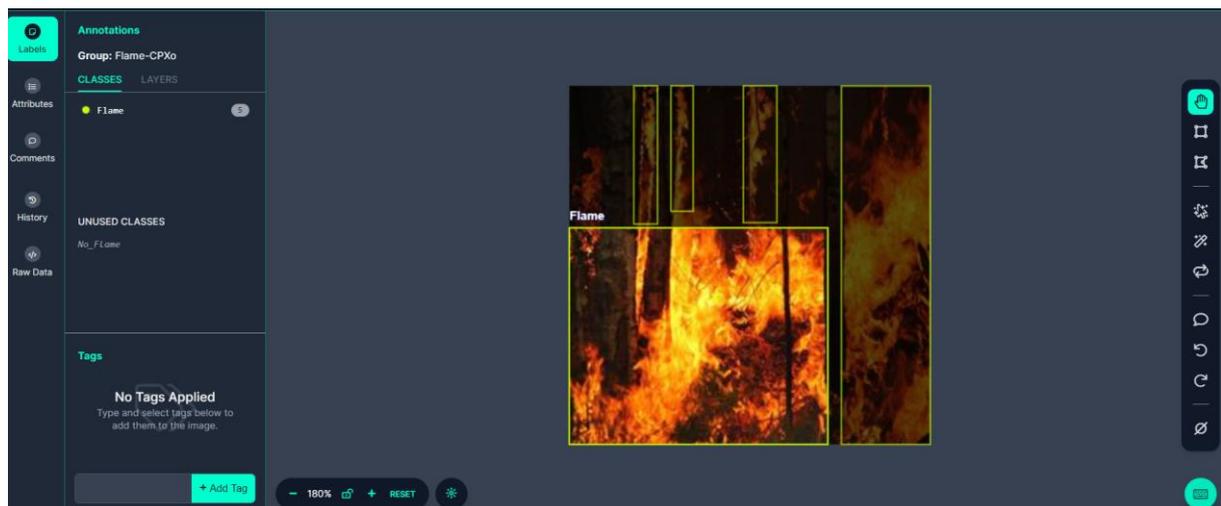


Figure IV-13 : Annotations

Etape 4 : Les images annotées sont tous stockées dans le Dataset.

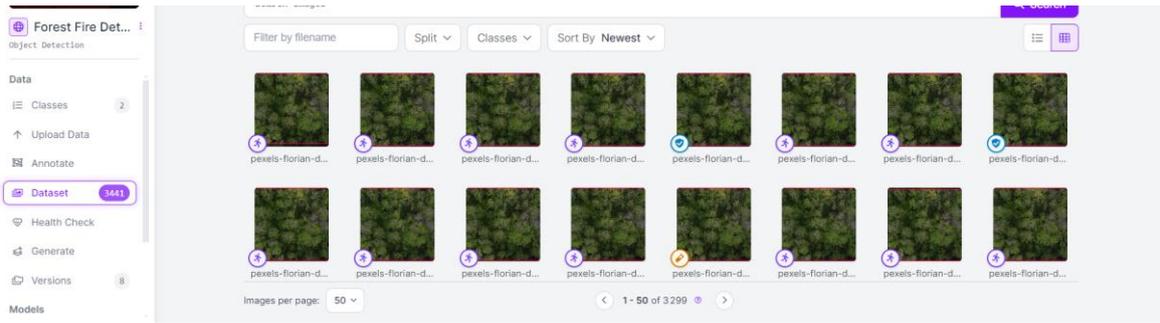


Figure IV-14 : Dataset

Etape 5 : Puis générer le Dataset (images et annotations où chaque image a son propre fichier d'annotations portant son même nom).

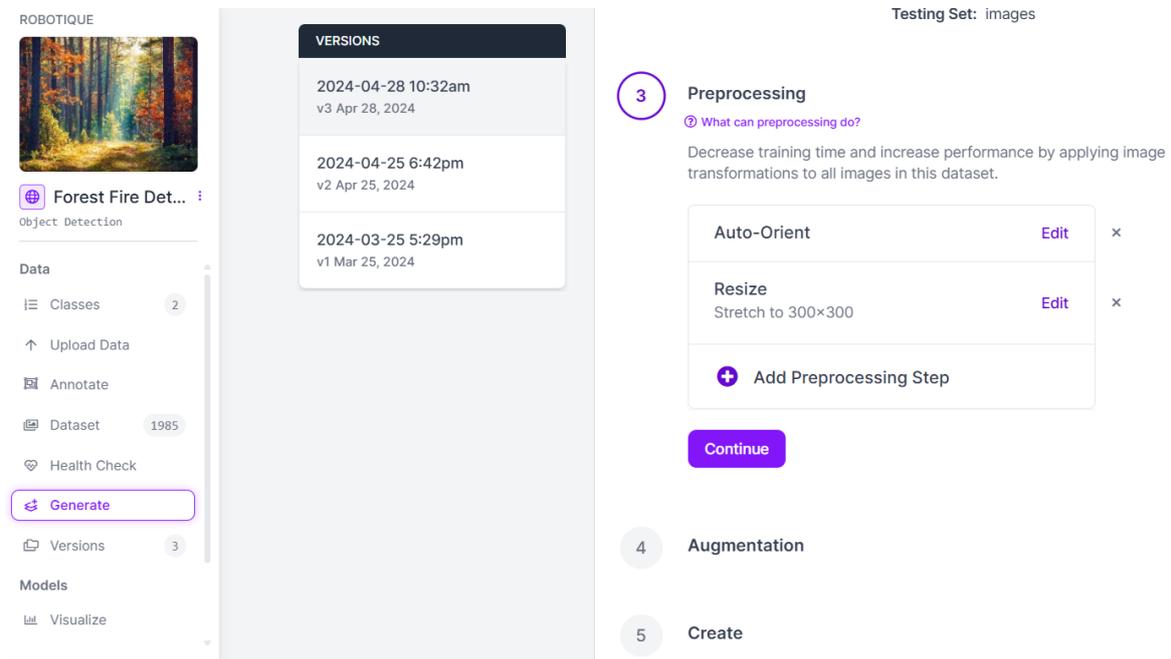


Figure IV-15 : Génération de Dataset

Etape 6 : Exporter les fichiers générés pour effectuer l'entraînement

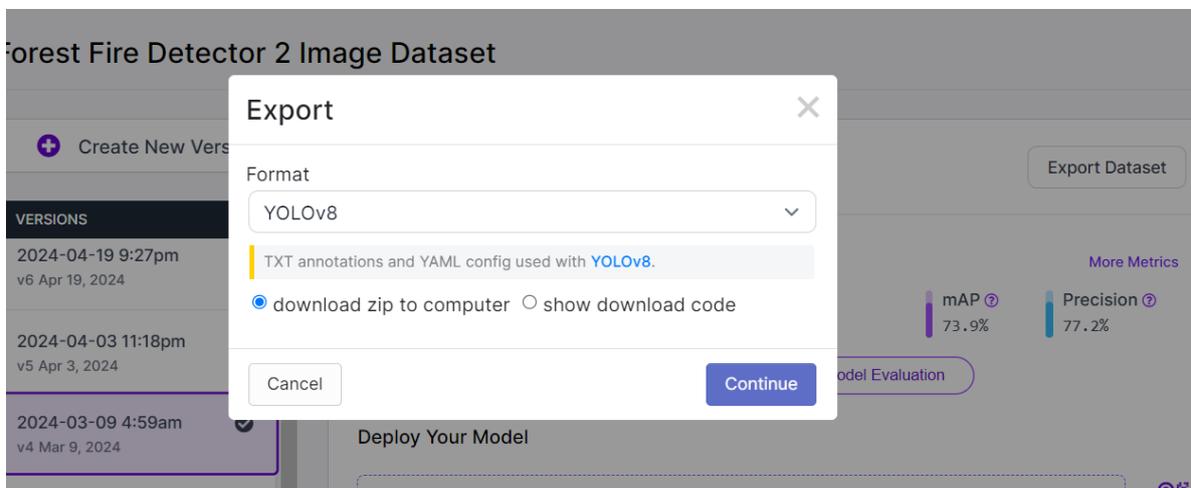


Figure IV-16 : Fichier YOLO

Etape 7 :

- Installer PyCharm
- Installer Python
- Installer YOLOv8 (en exécutant sur CMD ou Terminal : pip install ultralytics)
- Puis installer OpenCV (bibliothèques de vision par ordinateur)
- Procéder à l'entraînement est faite à l'aide du code :

```
from ultralytics import YOLO

model = YOLO("yolov8n.yaml")
#model = YOLO("yolov8n.pt")

results = model.train(data="data.yaml", epochs=50)
```

- Ce processus va générer à la fin un model entraîné sur notre jeu de données :

*Figure IV-17 : Modèle de détection de feux*

- A travers ce fichier nous procédons à la détection des feux de forêt :

*Figure IV-18 : Détection de feux**Figure IV-20 : Détection des feux de forêt**Figure IV-19 : Détection des feux de forêt**Figure IV-21 : Détection de feux de forêt*

IV.3 Simulation complète

- Construction de drone



Figure IV-22 : Création de drone

- Déploiement de drone

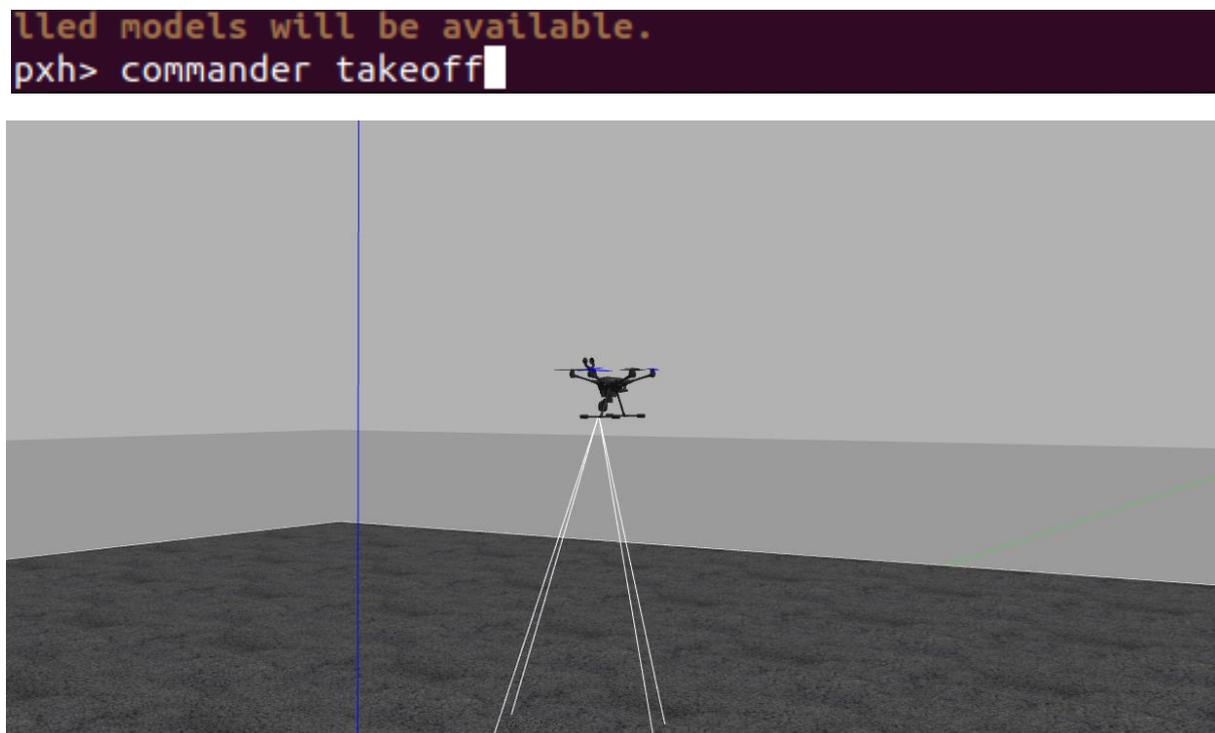


Figure IV-23 : Déploiement de drone

- *Connection entre drone et QGROUNDCONTROL (station de contrôle et le pilotage des drones)*

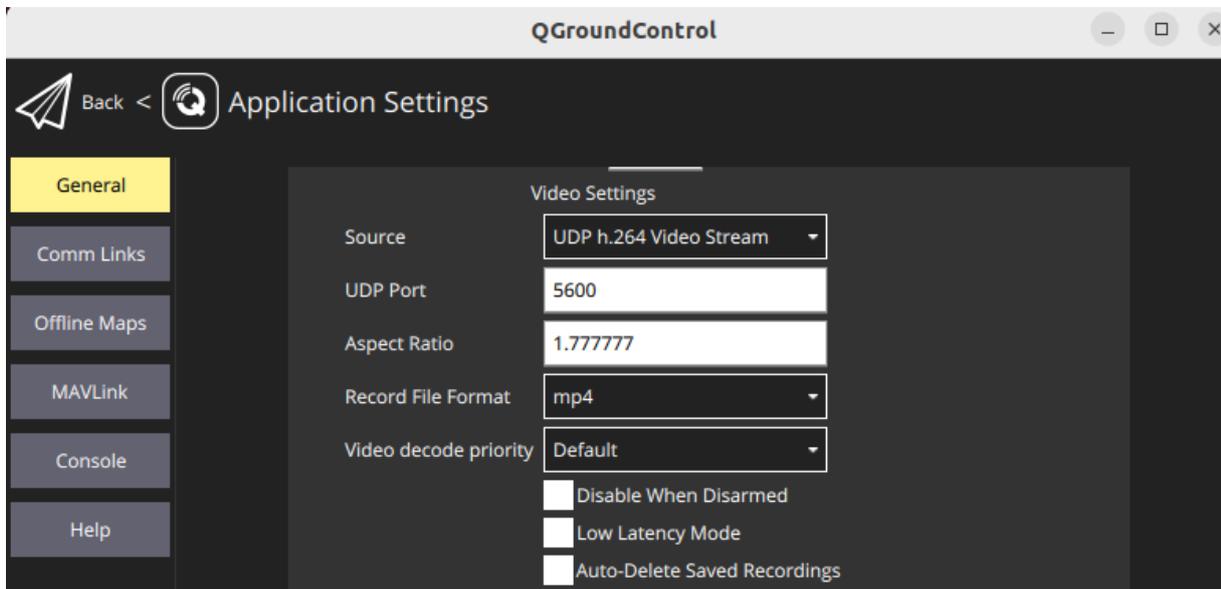


Figure IV- 24 : Contrôleur de vole

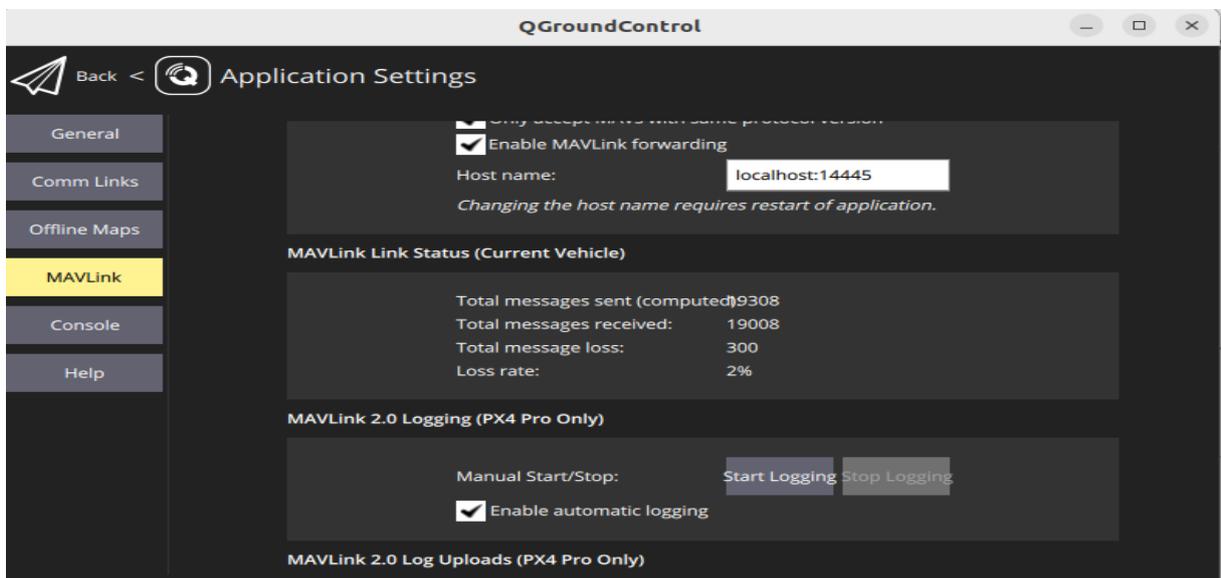


Figure IV-25 : Contrôleur de vole

- Dans l'environnement Gazebo on implante les différents modules dont nous avons besoin

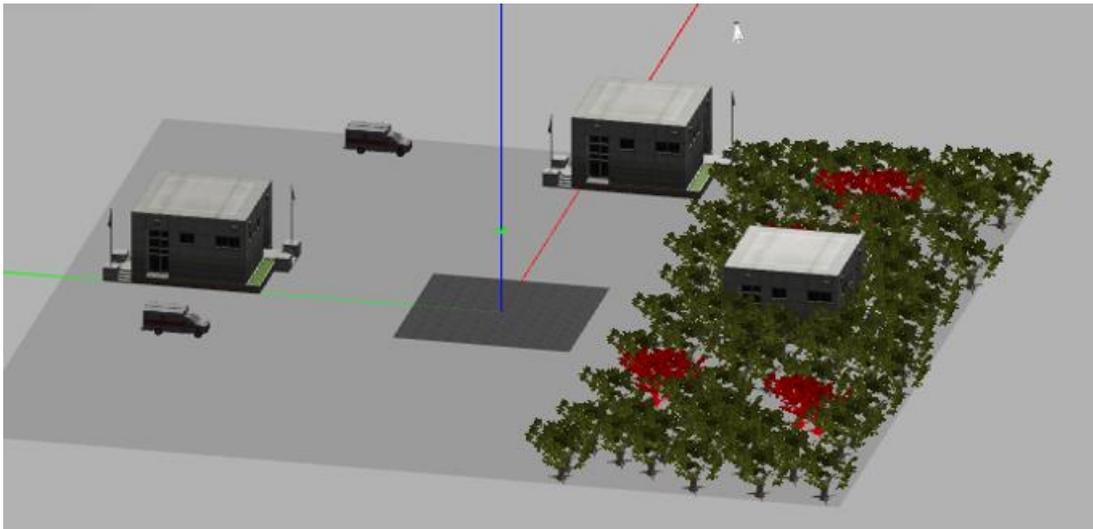


Figure IV-26 : Simulation de drone

- Connection entre modèle de détection et drone (camera)

Dans le code python de notre interface à travers le port 5600, on établit une connexion

```
def __init__(self, port=5600):
    """Summary
```

- Puis nous exécutons notre application
- Nous survolons tous les zones de risque et détectons les feux de forêt.

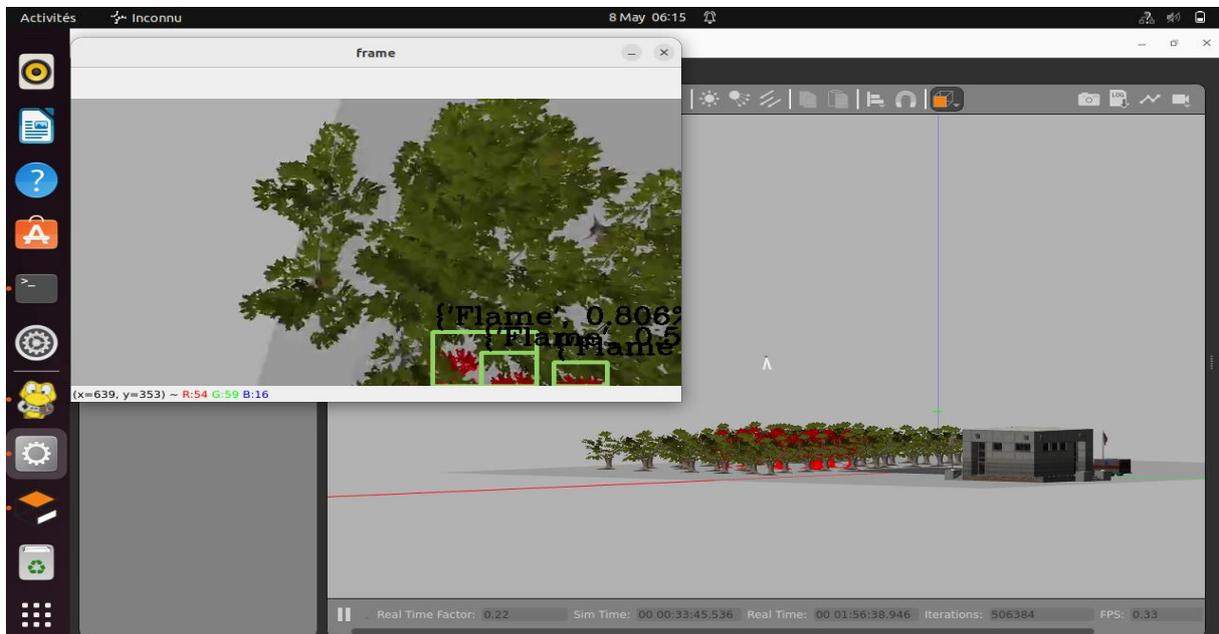


Figure IV-27 : Simulation de drone

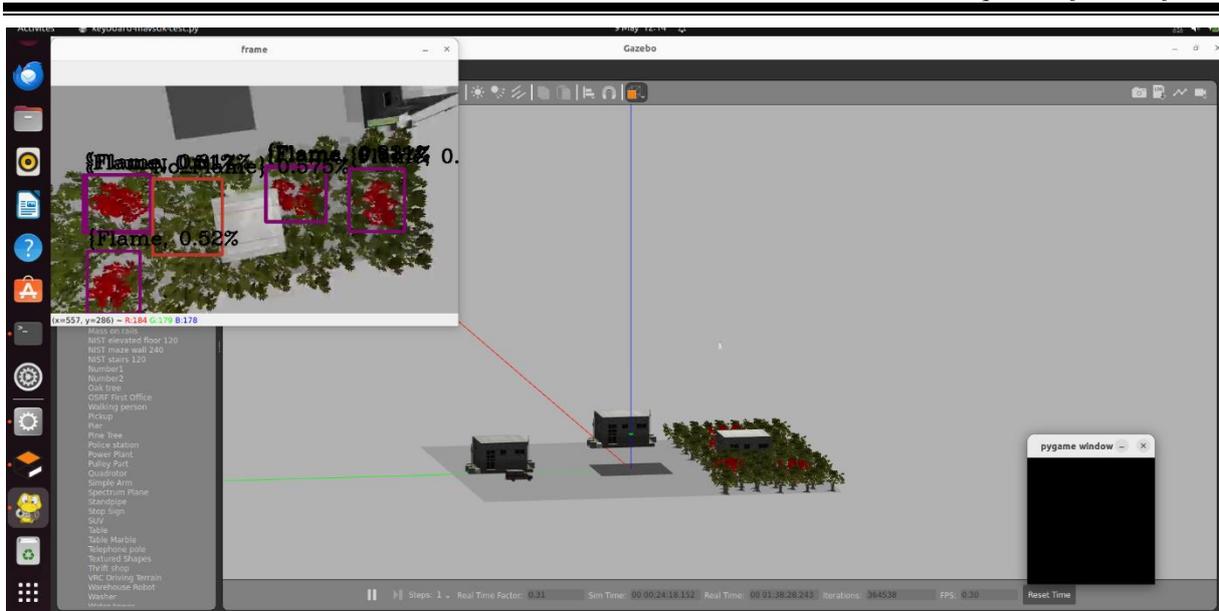


Figure IV-28 : Simulation de drone

IV.4 Conclusion

Ce chapitre a fourni un guide complet pour établir un environnement virtuel pour simuler la détection d'incendies de forêt à l'aide d'un drone, ainsi que des instructions détaillées pour entraîner l'algorithme YOLO (You Only Look Once) et préparer un ensemble de données adapté à l'entraînement de YOLO. En suivant les procédures étape par étape décrites ici, les chercheurs et les praticiens peuvent reproduire efficacement le dispositif expérimental et les méthodologies décrites dans ce chapitre. Ce guide complet constitue une ressource précieuse pour d'autres efforts de recherche dans le domaine de la détection des incendies de forêt et de la télédétection, facilitant l'avancement des techniques visant à améliorer les efforts de surveillance environnementale et de gestion des catastrophes.

Conclusion Générale

La détection des incendies de forêt est d'une importance capitale pour protéger les ressources naturelles, conserver la biodiversité et assurer la sécurité des personnes vivant à proximité des zones forestières.

Les avancées technologiques récentes telles que les drones équipés de caméras infrarouges offrent des moyens plus efficaces de détecter et de surveiller les incendies de forêts.

Cependant, malgré ces progrès, des défis demeurent, les faux positifs et les faux négatifs peuvent réduire l'efficacité des systèmes de détection (précisions), c'est pourquoi une amélioration continue des algorithmes et des technologies utilisés est donc nécessaire. De plus, l'accès à des zones éloignées ou difficiles d'accès peut poser des défis logistiques pour le déploiement de dispositifs de détection.

En bref, les améliorations des outils technologiques ont considérablement contribué à la détection des feux de forêt, qui est devenu la meilleure option pour prévenir et minimiser les dommages causés par les incendies de forêt.

L'intégration des algorithmes de détection d'objets dans les drones a contribué dans la divulgation des feux de forêt dans leurs premiers stages surtout l'algorithme YOLO grâce à sa grande vitesse de traitement d'images (40-155 FPS) et sa moyenne de précision qui a atteint 80%. De l'autre côté l'algorithme SSD a montré une bonne performance en termes de précision malgré que sa moyenne de précision a atteint 73.72% mais son seul défaut par rapport à YOLO est que sa vitesse de traitement des images est lente (22-46 FPS) ce qui rend YOLO plus adéquat pour les activités de surveillance en temps réel comme dans notre cas.

Bien que YOLO a montré des limites dans les tâches de détection d'objets en temps réel, des recherches futures pourraient explorer des alternatives telles que RetinaNet et EfficientDet, connues pour leurs performances compétitives.

Sur notre ensemble de données, les études futures pourront élucider leurs forces et faiblesses respectives, faisant finalement progresser l'état de l'art en matière de détection d'objets en temps réel.

V. L'ENTREPRENARIAT

- L'entrepreneuriat est l'action d'entreprendre, de démarrer ou de diriger un projet.
- Le terme « entreprendre », souvent utilisé dans le domaine des affaires, signifie créer une activité (économique) pour atteindre des objectifs et satisfaire des besoins.
- C'est l'intérêt de définir son business model.



Figure V-1 : Start up

V.1 L'entrepreneur

Un entrepreneur est une personne qui est à l'origine de la création d'une activité économique. Il poursuit des projets économiques et est prêt à prendre des risques pour développer des idées et un savoir-faire auxquels il croit. Son rôle est de créer, construire un business modèle d'une entreprise et de :

- Piloter
- Gérer
- Transformer au fur et à mesure que l'entreprise évolue

V.1.1 Le Business Model Canvas

A) Définition

Un business modèle est également appelé modèle économique, est un élément indispensable à tout projet de création. Le business model décrit et explique exactement comment une entreprise gagne de l'argent et crée de la valeur. [49]

B) Pourquoi l'utilisons-nous ?

Pour visualiser immédiatement via un tableau l'idée du projet. Cela va permettre de comprendre l'entreprise et d'établir un lien entre votre idée et sa mise en œuvre pour en faire une entreprise, et rechercher quels types de décisions des clients influencent l'utilisation du système.

Cela donne à chacun une idée claire de ce que pourrait être l'entreprise. [44]

C) Business Model

Après cette première études faite (études du marché) nous sommes à mesure de : définir quoi vendre, à qui, dans quel but, comment et pour quel profit.

Un modèle économique répond aux questions suivantes :

Quel produit ou service est proposé ?

- Dans ce cas si le produit est un drone équipé d'une caméra pour la détection de feux de forêt temps réel.

Quelle valeur ajoutée ce produit ou service a-t-il par rapport à ses concurrents ?

- La construction d'un drone bien sécurisé extrêmement sophistiqué et stable. La précision de détection (qui passe de 60% au paravent à 80%)

Quel est la cible ?

- Il est destiné à l'élément de caserne de pompiers, les dépotoirs d'engrais chimiques, mais aussi aux grandes entreprises de production agricole qui sont facilement inflammables dont il faut surveiller comme : coton, blé.

Comment allez-vous les atteindre ?

- En les proposant un drone capable de détecter des feux de forêt dans le but principal est de sauver des vies, prévenir contre la sécheresse et contre la destruction du sol, fumée toxique ; le réchauffement climatique.

Quels moyens doivent être utilisés pour produire le produit ou le service ?

- Se procurer (acheter) des matériels de drone puis procéder à l'assemblage et enfin la programmation pour qu'il soit opérationnel.

Quelles sont les principales dépenses et revenus générés par l'activité ?

- Les principales dépenses résident sur l'achat des matériels comme 6 hélices, le chargeur, la batterie, le boîtier central, la caméra et les frais de transport

- Concernant les revenus, le prototype ainsi sur pied (assemblage et programmation) sera donc vendu sur le marché à moindre coût. Les principales dépenses résident sur l'achat des matériels comme 6 hélices, le chargeur, la batterie, le boîtier central, la caméra et les frais de transport.

D) Outils indispensables pour BMC

Matrice Canvas est un outil est basé sur le livre Business Model Génération d'Alexander OSTERWALDER et Yves PIGNEUR.

Cela vous permet de cartographier les principaux éléments de votre projet et de les organiser en un premier ensemble cohérent, un second pertinent, voire innovant.

C'est une sorte de mémo qui évolue au fil du temps, une expérience qui peut préserver les souvenirs du développement et de l'innovation continus.

C'est également un moyen simple de trouver des innovations qui vous différencient fondamentalement de vos concurrents.

Cette méthode vous aide également à verbaliser et « vendre » facilement votre projet à des partenaires (fournisseurs, banquiers...). [45]

Business Model Canvas

Business Model Canvas		<i>Désigné pour :</i>		<i>Désigné par :</i>		<i>Date :</i>		<i>Version</i>	
Partenaires et Fournisseurs clés	Activités clés	Proposition de Valeur	Relations avec la clientèle		La clientèle				
Fabricant de drones	Recherche et développement	Détection précoce et prévention	Un soutien personnalisé		Organismes gouvernementaux				
Développeurs de logiciels	Collecte et analyse des données	Précision et efficacité	Formation et éducation		Entreprises privées de gestion forestière				
Organismes gouvernementaux	Tests et validation	Sûreté et sécurité	Communication continue (cas de mise à jour)		Entreprises privées de gestion d'un champ agricole				
ONG et organismes de conservation	Formation et éducation		Contrats de services (propose au client nos services)						
	Entretien assistance								
	Amélioration continue								
	Ressources clés		Canaux						
	Technologies des drones		Les ventes directes						
	Développement de logiciels		Plateformes en ligne						
			Médias sociaux et marketing de contenu						
			Partenariats de distribution						

Coûts	Revenues
<ul style="list-style-type: none">• Équipement et technologie (Coûts d'achat de drones, de capteurs, de systèmes de communication)• Conformité réglementaire• Partenariats et collaborations• Amélioration continue• Entretien et assistance• Commercialisation et promotion• Recherche et développement• Personnel	<ul style="list-style-type: none">• Vente des drone équipés pour la détection de feux

Tableau III : Business Model Canvas

BIBLIOGRAPHIE

- [1] Saagie, « Qu'est-ce que la détection d'objet ? », Saagie. Consulté le: 18 février 2024. [En ligne]. Disponible sur: <https://www.saagie.com/fr/blog/quest-ce-que-la-detection-dobjet/>
- [2] « Object Detection vs Object Recognition vs Image Segmentation », GeeksforGeeks. Consulté le: 20 février 2024. [En ligne]. Disponible sur: <https://www.geeksforgeeks.org/object-detection-vs-object-recognition-vs-image-segmentation/>
- [3] « TAI_COURS_GI_2019_2020.pdf ». Consulté le: 7 mai 2024. [En ligne]. Disponible sur: http://fmi.univ-tiaret.dz/images/1GI/2020/S2/TAI/TAI_COURS_GI_2019_2020.pdf
- [4] « Le traitement d'une image numérique », myMaxicours. Consulté le: 7 mai 2024. [En ligne]. Disponible sur: <https://www.maxicours.com/se/cours/le-traitement-d-une-image-numerique/>
- [5] R. Kassel, « Qu'est-ce que l'Apprentissage automatique ? », Formation Data Science | DataScientest.com. Consulté le: 19 février 2024. [En ligne]. Disponible sur: <https://datascientest.com/apprentissage-automatique>
- [6] B. L, « Réseau de neurones artificiels : qu'est-ce que c'est et à quoi ça sert ? », LEBIGDATA.FR. Consulté le: 22 février 2024. [En ligne]. Disponible sur: <https://www.lebigdata.fr/reseau-de-neurones-artificiels-definition>
- [7] « Qu'est-ce qu'un réseau de neurones ? | IBM ». Consulté le: 22 février 2024. [En ligne]. Disponible sur: <https://www.ibm.com/fr-fr/topics/neural-networks>
- [8] « Réseaux de Neurones Artificiels | PDF | Réseau de neurones artificiels | Neurone », Scribd. Consulté le: 24 février 2024. [En ligne]. Disponible sur: <https://fr.scribd.com/document/298684887/Reseaux-de-Neurones-Artificiels>
- [9] « RNN: Tout savoir sur les Couches Récurrentes - Meilleur Guide ». Consulté le: 23 février 2024. [En ligne]. Disponible sur: <https://inside-machinelearning.com/les-reseaux-de-neurones-recurrents-rnn/>
- [10] A. Pathak, « Réseaux de neurones convolutifs (CNN) : une introduction », Geekflare. Consulté le: 26 février 2024. [En ligne]. Disponible sur: <https://geekflare.com/fr/convolutional-neural-networks/>
- [11] J. Robert, « Convolutional Neural Network : Tout ce qu'il y a à savoir », Formation Data Science | DataScientest.com. Consulté le: 26 février 2024. [En ligne]. Disponible sur: <https://datascientest.com/convolutional-neural-network>
- [12] R. Kassel, « R-CNN (Region Based Convolutional Network) : tout sur ce modèle de Machine Learning », Formation Data Science | DataScientest.com. Consulté le: 7 avril 2024. [En ligne]. Disponible sur: <https://datascientest.com/r-cnn-ou-region-based-convolutional-network>
- [13] kamal_DS, « Non-Max Suppression », Medium. Consulté le: 7 avril 2024. [En ligne]. Disponible sur: <https://korlakuntasaikamal10.medium.com/non-max-suppression-b0569e89e9e7>
- [14] « R-CNN, R-CNN rapide, R-CNN plus rapide, YOLO - Algorithmes de détection d'objets — Vision par Ordinateur — DATA SCIENCE ». Consulté le: 28 avril 2024. [En

- ligne]. Disponible sur: <https://datascience.eu/fr/vision-par-ordinateur/r-cnn-r-cnn-rapide-r-cnn-plus-rapide-yolo-algorithmes-de-detection-dobjets/>
- [15] R. Kassel, « R-CNN (Region Based Convolutional Network) : tout sur ce modèle de Machine Learning », Formation Data Science | DataScientest.com. Consulté le: 28 avril 2024. [En ligne]. Disponible sur: <https://datascientest.com/r-cnn-ou-region-based-convolutional-network>
- [16] « Dévoiler l'architecture et l'efficacité de Fast et Faster R-CNN pour la détection d'objets – Kanaries ». Consulté le: 7 avril 2024. [En ligne]. Disponible sur: <https://docs.kanaries.net/fr/topics/Python/fast-rcnn>
- [17] « Fast R-CNN (Object Detection) ». Consulté le: 4 mai 2024. [En ligne]. Disponible sur: <https://www.linkedin.com/pulse/fast-r-cnn-object-detection-ayoub-kirouane>
- [18] S. Ananth, « Fast R-CNN for Object detection », Medium. Consulté le: 4 mai 2024. [En ligne]. Disponible sur: <https://towardsdatascience.com/fast-r-cnn-for-object-detection-a-technical-summary-a0ff94faa022>
- [19] « Comprendre Fast-RCNN pour la détection d'objets ». Consulté le: 28 avril 2024. [En ligne]. Disponible sur: <https://ichi.pro/fr/comprendre-fast-rcnn-pour-la-detection-d-objets-134261741190246>
- [20] P. singh, « Evolution of Object Detection: RCNN, Fast RCNN, and Faster RCNN », Medium. Consulté le: 4 mai 2024. [En ligne]. Disponible sur: <https://medium.com/@2003priyanshusingh/evolution-of-object-detection-rcnn-fast-rcnn-and-faster-rcnn-90cc872e6dae>
- [21] « Reconnaissance de caractères sur des reçus à l'aide du Faster R-CNN », Le Data Scientist. Consulté le: 4 mai 2024. [En ligne]. Disponible sur: <https://ledatascientist.com/detection-recu-rcnn/>
- [22] J. Terven et D. Cordova-Esparza, « A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS », arXiv.org. Consulté le: 3 mars 2024. [En ligne]. Disponible sur: <https://arxiv.org/abs/2304.00501v7>
- [23] J. Pedro, « Detailed Explanation of YOLOv8 Architecture — Part 1 », Medium. Consulté le: 3 mars 2024. [En ligne]. Disponible sur: <https://medium.com/@juanpedro.bc22/detailed-explanation-of-yolov8-architecture-part-1-6da9296b954e>
- [24] Ultralytics, « Ultralytics YOLOv8 Tâches ». Consulté le: 6 mars 2024. [En ligne]. Disponible sur: <https://docs.ultralytics.com/fr/tasks>
- [25] « Architecture YOLOv8 : une plongée dans son architecture - YOLOv8 ». Consulté le: 6 mars 2024. [En ligne]. Disponible sur: <https://yolov8.org/yolov8-architecture/>
- [26] « Comment fonctionne YOLOv8 ? Un coup d'œil à l'intérieur de son cerveau de détection d'objets - YOLOv8 ». Consulté le: 28 avril 2024. [En ligne]. Disponible sur: <https://yolov8.org/how-does-yolov8-work/>
- [27] « Single Shot Detector (SSD) + Architecture of SSD », OpenGenus IQ: Computing Expertise & Legacy. Consulté le: 16 avril 2024. [En ligne]. Disponible sur: <https://iq.opengenus.org/single-shot-detector/>
- [28] J. Hui, « SSD object detection: Single Shot MultiBox Detector for real-time processing », Medium. Consulté le: 16 avril 2024. [En ligne]. Disponible sur:

- <https://jonathan-hui.medium.com/ssd-object-detection-single-shot-multibox-detector-for-real-time-processing-9bd8deac0e06>
- [29] M. ul Hassan, « VGG16 - Convolutional Network for Classification and Detection ». Consulté le: 16 avril 2024. [En ligne]. Disponible sur: <https://neurohive.io/en/popular-networks/vgg16/>
- [30] L.-W. Lung et Y.-R. Wang, « Applying Deep Learning and Single Shot Detection in Construction Site Image Recognition », *Buildings*, vol. 13, n° 4, Art. n° 4, avr. 2023, doi: 10.3390/buildings13041074.
- [31] J. Han, « SSD: Single Shot MultiBox Detector », Analytics Vidhya. Consulté le: 16 avril 2024. [En ligne]. Disponible sur: <https://medium.com/analytics-vidhya/ssd-single-shot-multibox-detector-86e891113896>
- [32] « Single Shot Detectors(SSDs) For Object Detection ». Consulté le: 16 avril 2024. [En ligne]. Disponible sur: <https://www.linkedin.com/pulse/single-shot-detectorsssds-object-detection-kognitiv-club-zizuc>
- [33] « YOLOv8 vs SSD: Choosing the Right Object Detection Model », Keylabs: latest news and updates. Consulté le: 21 avril 2024. [En ligne]. Disponible sur: <https://keylabs.ai/blog/yolov8-vs-ssd-choosing-the-right-object-detection-model/>
- [34] « Drones de surveillance - Guide complet de la surveillance aérienne - UASolutions Sàrl ». Consulté le: 9 avril 2024. [En ligne]. Disponible sur: <https://uasolutions.ch/fr/drones-de-surveillance/>
- [35] « Les applications de drones aériens », Techniques de l'Ingénieur. Consulté le: 18 avril 2024. [En ligne]. Disponible sur: <https://www.techniques-ingenieur.fr/base-documentaire/automatique-robotique-th16/applications-en-robotique-42623210/les-applications-de-drones-aeriens-s7816/>
- [36] S. A. H. Mohsan, N. Q. H. Othman, Y. Li, M. H. Alsharif, et M. A. Khan, « Unmanned aerial vehicles (UAVs): practical aspects, applications, open challenges, security issues, and future trends », *Intel Serv Robotics*, vol. 16, n° 1, p. 109-137, mars 2023, doi: 10.1007/s11370-022-00452-4.
- [37] « 14 Different Types of Drones Explained with Photos », Aero Corner. Consulté le: 18 avril 2024. [En ligne]. Disponible sur: <https://aerocorner.com/blog/types-of-drones/>
- [38] « Spécifications; Spécifications Du ; Spécifications De Realsense; Spécifications Du Cgo3+ (Cgo3 Plus) - YUNEEC TYPHOON H Manuel De L'utilisateur [Page 4] », ManualsLib. Consulté le: 13 avril 2024. [En ligne]. Disponible sur: <https://www.manualslib.fr/manual/54160/Yuneeec-Typhoon-H.html>
- [39] « Yuneec Typhoon H - Test de cet engin hors normes », Drone Test. Consulté le: 13 avril 2024. [En ligne]. Disponible sur: <https://www.drone-test.com/yuneeec-typhoon-h/>
- [40] « Drone Hexaoptère - Yuneec Typhoon H-480 + CGO3 Pro 4K • EUR 890,00 », PicClick FR. Consulté le: 23 avril 2024. [En ligne]. Disponible sur: <https://picclick.fr/Drone-Hexaopt%C3%A8re-Yuneeec-Typhoon-H-480-CGO3-155870350142.html>
- [41] « Test Yuneec Typhoon H Professional RealSense ». Consulté le: 13 avril 2024. [En ligne]. Disponible sur: <https://www.lesnumeriques.com/drone/yuneeec-typhoon-h-prop48181/test.html>

- [42] « Des drones innovants pour lutter contre les feux de forêts », *La Croix*, 6 août 2019. Consulté le: 5 mai 2024. [En ligne]. Disponible sur: <https://www.la-croix.com/France/Securite/drones-innovants-lutter-contre-feux-forets-2019-08-06-1201039557>
- [43] R. Roche, « PX4 Autopilot Release v1.14: What You Need to Know », PX4 Autopilot. Consulté le: 5 mai 2024. [En ligne]. Disponible sur: <https://px4.io/px4-autopilot-release-v1-14-what-you-need-to-know/>
- [44] Sheda, « How To: Business Model Canvas Explained », Sheda. Consulté le: 16 mai 2024. [En ligne]. Disponible sur: <https://medium.com/seed-digital/how-to-business-model-canvas-explained-ad3676b6fe4a>
- [45] « Business Model Canvas gratuit sur nos tableaux partagés », Agoora. Consulté le: 16 mai 2024. [En ligne]. Disponible sur: <https://agoora.fr/business-model-canvas/>