

Département d'Automatique, Télécommunications et d'Electronique

Projet de Fin d'Etudes

Pour l'obtention du diplôme de Master

Filière : Télécommunications

Spécialité : Système des télécommunications

Thème

La performance de la 5G pour la détection des objets dans le trafic urbain

Préparé par :

- LACHI Mehdi Rayane
- BENIDIRI Mounir
- **Dirigé par :**
- Mr. BELLAHSENE Hocine
- Mme TIMRICHT Imane

Examiné par :

Mr.TOUNSI Mohamad
Mme.GHENNAM Souhila

Année universitaire : 2022/2023

Remerciements

Nous remercions ALLAH qui nous a donné le courage et patience dans tout notre parcours

Nous souhaitons exprimer nos sincères remerciements à notre encadreur, Mr. BELLAHSENE Houcine, pour son soutien inestimable tout au long de notre troisième année et de notre deuxième année de master. Son encadrement de haute qualité, ses conseils judicieux et ses propositions ont été d'une grande valeur pour notre travail.

Nous tenons également à remercier chaleureusement chaque membre du jury pour l'intérêt qu'ils ont porté à notre recherche, en acceptant d'examiner notre travail et en le enrichissant par leurs précieuses propositions.

Nous exprimons notre gratitude envers M. BENIDIRI LAHLOU et M. HAMMOU Youfrer pour leurs conseils précieux, leur disponibilité infinie et leur orientation, qui ont apporté une contribution considérable à la réussite de ce projet.

Nous adressons également nos remerciements à Mme Timricht Imane pour leur encadrement.

Nos remerciements s'étendent à tous nos enseignants et aux membres du département des télécommunications de l'université ABDERRAHMANE MIRA. Leur soutien et leurs efforts ont été essentiels à la réalisation de ce travail.

Enfin, nous tenons à exprimer notre reconnaissance envers toutes les personnes qui ont contribué de près ou de loin à l'accomplissement de ce travail. Votre soutien, vos conseils et votre encouragement ont été d'une valeur inestimable pour nous. Merci du fond du cœur.

Mehdi & Mounir

Dédicace

Nous souhaitons exprimer notre gratitude profonde à nos parents pour les sacrifices qu'ils ont consentis envers nous. Leur dévouement, leur patience, leur amour inconditionnel et leur confiance ont été des sources d'inspiration et de soutien tout au long de notre parcours. Dans ce modeste travail, nous espérons que nos parents trouveront le témoignage de notre profonde affection et de notre attachement indéfectible envers eux. Aucune dédicace ne saurait véritablement exprimer la dette que nous avons envers eux.

Nous tenons également à remercier nos frères, sœurs et tous nos amis. Chaque mot de soutien que nous avons reçu, chaque geste d'amitié, chaque main tendue et chaque attention témoignée ont été précieux pour nous. Leur présence dans nos vies a apporté de la joie, du réconfort et de la motivation, et nous sommes reconnaissants de pouvoir compter sur leur soutien indéfectible.

Leur amitié et leur soutien ont été une source de force et de réconfort dans les moments difficiles et ont rendu les moments de joie encore plus spéciaux. Nous tenons à exprimer notre profonde gratitude envers eux et à leur dire combien nous apprécions leur présence et leur soutien constants.

À nos parents, à nos frères et sœurs et à tous nos amis exceptionnellement Ahmane yassine et , idjaad salim et ait kousaila anous vous remercions du fond du cœur pour tout ce que vous avez fait et continuez de faire pour nous. Votre amour, votre soutien et votre amitié sont des cadeaux inestimables, et nous sommes extrêmement reconnaissants de vous avoir dans nos vies.

Mehdi & Mounir

Abstract

This report focuses on evaluating the performance of 5G in obstacle detection in urban traffic using the YOLOv3 model. The 5G technology offers advanced connectivity benefits such as low latency and high bandwidth, which can enhance real-time detection accuracy and speed. The YOLOv3 model, a specialized convolutional neural network for object detection, is employed to analyze image streams from sensors mounted on autonomous vehicles. The study includes simulation and experimental testing to assess the performance of the YOLOv3 model in terms of precision, recall, and detection speed. The results demonstrate that integrating the YOLOv3 model with 5G technology significantly improves obstacle detection in urban traffic, thereby opening up new possibilities for safer and more efficient autonomous vehicles.

Résumé

Ce rapport se concentre sur l'évaluation des performances de la 5G dans la détection des obstacles dans la circulation urbaine en utilisant le modèle YOLOv3. La technologie 5G offre des avantages avancés en termes de connectivité tels que la faible latence et la large bande passante, ce qui peut améliorer la précision et la vitesse de détection en temps réel. Le modèle YOLOv3, un réseau neuronal convolutif spécialisé dans la détection d'objets, est utilisé pour analyser les flux d'images provenant des capteurs montés sur les véhicules autonomes. L'étude comprend des tests de simulation et expérimentaux pour évaluer les performances du modèle YOLOv3 en termes de précision, de rappel et de vitesse de détection. Les résultats démontrent que l'intégration du modèle YOLOv3 avec la technologie 5G améliore significativement la détection des obstacles dans la circulation urbaine, ouvrant ainsi de nouvelles possibilités pour des véhicules autonomes plus sûrs et plus efficaces.

Table des matières

Liste des figures	I
Liste des tableaux	IV
Liste des Abréviations	VI
Introduction générale.....	1
Chapitre 1 : Généralités sur la 5G.....	2
1.1 Introduction	3
1.2 Étude des technologies de réseaux mobiles.....	3
1.3 Étude du LTE (Long Terme Evolution).....	3
1.4 Améliorations apportées par la 5G	4
1.5 L'architecture générale du réseau 5G.....	6
1.5.1 Architecture Non-Standalone et Standalone	6
1.5.2 Les composants du réseau 5G	6
1.5.3 Les fonctionnalités du 5GC :.....	7
1.6 Les cas d'usage de la 5G	8
1.7 Les technologies envisagées par les réseaux 5G	9
1.7.1 Les ondes millimétriques	9
1.7.2 Les petites cellules	9
1.7.3 Le Massive MIMO.....	10
1.7.4 Le Beamforming.....	11
1.8 Objectifs de la technologie 5G	11
1.9 Comparaison entre les performances de la 5G et la 4G LTE Advanced	12
1.10 Performances de la 5G dans le domaine urbain	14
1.11 Étude du Network Slicing	14
1.11.1 Performances du Network Slicing dans le domaine urbain	15
1.12 Conclusion.....	15
Chapitre 2 : Caractéristiques des véhicules autonomes.	16
2.1 Introduction	17
2.2 La définition des véhicules autonomes.....	17
2.3 Importance et avantages des véhicules autonomes.....	17
2.4 Évolution et état actuel des véhicules autonomes	18

2.5	Les technologies clés des véhicules autonomes	18
2.5.1	Les Lidars	18
2.5.2	Les caméras	19
2.5.3	Les Ultrasons.....	19
2.5.4	Les radars	20
2.5.5	Capteurs de mouvements et de positions	20
2.6	Communication (V2V) et (V2I) et (V2X).....	20
2.6.1	La technologie V2I.....	20
2.6.2	La technologie V2V	21
2.6.3	La technologie V2X.....	21
2.7	Étude du réseau véhiculaire VANET	22
2.8	Caractéristiques des réseaux de véhicules	23
2.8.1	Types de messages	24
2.9	Appréhension de la voiture autonome dans son environnement	25
2.9.1	Perception de l'environnement.....	25
2.9.2	Analyse des données reçues.....	25
2.9.2.1	Le framework TensorFlow	25
2.9.2.2	Concernant la technologie VoxelNet.....	26
2.9.2.3	Les réseaux de neurones convolutifs (CNN ou ConvNET) :.....	27
2.10	Développements et perspectives des véhicules autonomes	27
2.11	Conclusion	28
Chapitre 3 : La détection d'objets.		29
3.1	Introduction	30
3.2	Réseaux de neurones artificiels	30
3.2.1	Les poids (weight).....	30
3.2.2	La fonction d'activation.....	31
3.2.3	Sortie.....	31
3.3	Réseaux Neuronaux Convolutifs (CNN).....	32
3.3.1	Couche d'entrée.....	32
3.3.2	Couches de convolution	32
3.3.3	Couches de pooling	34
3.3.4	Couche entièrement connectée (fully connected)	34
3.4	Conception de réseaux de neurones à convolution.....	36
3.4.1	Base de données utilisées pour l'apprentissage des réseaux de neurones CNN.....	36

3.5 La présentation du modèle YOLO.....	37
3.5.1 L'architecture du modèle YOLO	38
3.5.2 YOLO V3.....	39
3.5.3 Intégration du modèle YOLO V3 dans le véhicule autonome.....	40
3.5.4 L'intégration de YOLO et la puissance de la technologie 5G pour une conduite autonome avancée	41
3.6 Conclusion.....	41
Chapitre 4 : Simulation et résultats.	42
4.1 Introduction	43
4.2 Logiciels utilisés :.....	43
4.3 Schéma de conception	45
4.4 Création du projet	45
4.5 La base de données	45
4.6 Labellisation	46
4.7 Convertir les formats XML en format YOLO	48
4.8 Modifier le fichier configs.py de l'entraînement.....	49
4.9 Lancer l'entraînement du modèle	49
4.10 Evaluation de l'entraînement.....	50
4.11 Résultat	51
4.12 Discussions	58
4.13 Conclusion.....	58
Conclusion générale :.....	60
Bibliographie.....	61
WEBOGRAPHIE.....	64

Liste des figures

Figure 1: Évolution des réseaux mobiles [F1]	3
Figure 2: Services Evolution from 4G to 5G [F2]	4
Figure 3: Performances de la 5G [F3].....	5
Figure 4: Architecture 5G NSA et 5G SA [F4].	6
Figure 5: Schéma fonctionnel de l'architecture du réseau 5G [F5].	7
Figure 6: Scénarios d'utilisation de l'IMT-2020 [F6].	9
Figure 7: la technologie Massive MIMO [F7].	10
Figure 8: la technologie Beamforming[F8].....	11
Figure 9: Fonctionnement des STIs [F9].....	19
Figure 10: Communication Véhicule to infrastructure [F10].....	20
Figure 11: Communication Vehicule to Vehicule[F11].	21
Figure 12: Composants d'un VANET [F12].	23
Figure 13: Processus de détection d'objet [F13].....	26
Figure 14: Reconnaissance 3D détecté par Lidar [F14].	27
Figure 15: réseaux de neurones artificiels. [F15].....	30
Figure 16: fonction sigmoid et ReLU.[F16]	31
Figure 17: architecture des CNN. [F17].....	32
Figure 18: la couche de convolution. [F18]	33
Figure 19: principe de la fonction Relu. [F19].....	33
Figure 20: exemple de couche pooling (average et max pooling) [F20].	34
Figure 21: couche entièrement connectée [F21].	35
Figure 22: les couches de CNN [F22].	35
Figure 23: exemple de l'architecture CNN [F23].	36
Figure 24: exemple de modèles de détection d'objets [F24].	37
Figure 25: principe du modèle YOLO.[25].....	38
Figure 26: Architecture du modèle YOLO. [F26].....	38
Figure 27: Principe de fonctionnement de l'architecture YOLO [F27].	39
Figure 28: architecture du modèle YOLOV3 [F28].	40
Figure 29 : schéma test et résultat	45
Figure 30: création du projet et ajouts des labels	46
Figure 31: importation des images qu'on veut labéliser	46
Figure 32: dessiner les rectangles sur les objets.....	47
Figure 33: exemple d'un label crée à partir d'une image de la base de données.	47
Figure 34: exportation des résultats XML.....	48
Figure 35: Modifications de lignes de code	49
Figure 36: L'image représente principalement la détection d'un bus en premier plan, ainsi que des voitures et une moto en arrière-plan.....	52
Figure 37: L'image représente la même situation que celle d'avant.....	52
Figure 38: l'image représente la détection d'une moto ainsi que la personne qui la conduit.	53
Figure 39: Image représentative de la détection de la classe voiture.	53
Figure 40: détection d'un camion.....	54
Figure 41: Passage piétons.	54
Figure 42: Panneau de stop.	55
Figure 43: Détection d'une personne.	55
Figure 44: Feu rouge.	56

Figure 45: Feu orange.	56
Figure 46: Feu vert.	57
Figure 47: détection plusieurs.	57
Figure 48: détection d'une erreur.	58

Liste des tableaux

Tableau 1: comparaison entre les performances de la 5G et de la 4G LTE Advanced.....	13
Tableau 2: Les Package utilisés.....	44
Tableau 3: résultat des Précision moyenne par classe.....	50

Liste des Abréviations

3D : Trois dimensions

3G : Troisième génération

3GPP : 3rd Generation Partnership Project

4G : Quatrième génération

5G : Cinquième génération

5G-AN : 5G Access Network

5G-NR : 5G New Radio

5GC : 5G Core

5GS : 5G Source

AF : Application Function

AMF : Access and Mobility Management

CNN : Convolutional Neural Network

CONVNETS : Convolutional Networks

CU : Central Unit

DU : Distributed Unit

EPC : Evolved Packet Core

eMBB : Enhanced Mobile Broadband

eNodeB : Evolved Node B

FAST R-CNN : Fast Region-based Convolutional Neural Network

GNSS : Global Navigation Satellite System

GPS : Global Positioning System

gNodeB : Next Generation NodeB

IoT : Internet of Things

KPI : Key Performance Indicator

LTE : Long Term Evolution

MANET : Mobile Ad hoc Network

MASK R-CNN : Mask Region-based Convolutional Neural Network

Mbps : Megabits per second

MIMO : Multiple-Input Multiple-Output

mMTC : Massive Machine Type Communications

Mu MIMO : Multi-User MIMO

NG-RAN : Next Generation Radio Access Network

NSA : Non-Standalone

OBUs : On-Board Units

OBU : On-Board Unit

OFDM : Orthogonal Frequency Division Multiplexing

PCF : Policy Control Function

PDN : Packet Data Network

PDN : Packet Data Network

RCNN : Region-based Convolutional Neural Network

ReLU : Rectified Linear Unit

RF : Radio Frequency

RAN : Radio Access Network

RSU : Roadside Unit

SA : Standalone

SMF : Session Management Function

SSD : Single Shot MultiBox Detector

STIs : Smart Transportation Systems

TA : Time Alignment

uRLLC : Ultra-Reliable and Low Latency Communications

UPF : User Plane Function

UDM : Unified Data Management

VANET : Vehicular Ad hoc Network

V2D : (Vehicle-to-Device)

V2I : Vehicle-to-Infrastructure

V2N : Vehicle-to-Network

V2P : Vehicle-to-Pedestrian

V2V : Vehicle-to-Vehicle

V2X : Vehicle-to-Everything

VOXENET : VoxelNet

Wimax : Worldwide Interoperability for Microwave Access

XML : eXtensible Markup Language

Mots clés : 5G, Voitures Autonomes, trafic urbain, YOLO, CNN, détection d'objets

Introduction générale

La performance de la 5G pour la détection d'obstacles dans le trafic urbain est un domaine d'étude crucial pour le développement des véhicules autonomes. La technologie 5G, avec ses caractéristiques de connectivité avancées, offre de nouvelles possibilités pour améliorer la détection en temps réel des objets dans des environnements urbains complexes. Ce rapport se concentre sur l'utilisation du modèle YOLOv3, un réseau de neurones convolutifs spécialement conçu pour la détection d'objets, en combinaison avec la 5G, pour améliorer la sécurité et l'efficacité des véhicules autonomes dans le trafic urbain.

Chapitre 1 : Généralités sur la 5G

Ce chapitre fournit une vue d'ensemble détaillée de la technologie 5G. Il explique les principales caractéristiques et avantages de la 5G, tels que la faible latence, la haute bande passante et la connectivité massive des objets. De plus, il met en évidence les applications potentielles de la 5G dans le domaine des véhicules autonomes et de la détection d'obstacles.

Chapitre 2 : Caractéristiques du véhicule autonome

Ce chapitre se concentre sur les caractéristiques spécifiques des véhicules autonomes. Il explore les capteurs utilisés dans les véhicules autonomes pour la perception de l'environnement, tels que les caméras, les lidars et les radars. De plus, il examine les défis liés à la détection d'obstacles dans le trafic urbain et l'importance de solutions précises et rapides.

Chapitre 3 : La détection d'objet avec YOLOv3

Ce chapitre présente en détail le modèle YOLOv3 pour la détection d'objets. Il explique l'architecture du modèle, ses différentes couches et leur fonctionnement. De plus, il discute des techniques avancées utilisées par YOLOv3 pour détecter avec précision les objets dans des scènes complexes du trafic urbain.

Chapitre 4 : Simulation et résultats avec le modèle YOLOv3

Ce chapitre porte sur la simulation et les résultats obtenus en utilisant le modèle YOLOv3 pour la détection d'obstacles dans le trafic urbain. Il décrit la méthodologie de la simulation, les jeux de données utilisés et les mesures de performance évaluées. De plus, il présente les résultats obtenus et analyse les performances du modèle en termes de précision, de rappel et de vitesse de détection.

La conclusion générale résume les principaux résultats et enseignements tirés de l'étude. Elle met en évidence l'importance de la combinaison de la 5G et du modèle YOLOv3 pour améliorer la détection d'obstacles dans le trafic urbain. De plus, elle souligne les opportunités et les défis futurs dans ce domaine, ainsi que l'impact potentiel sur la sécurité et l'efficacité des véhicules autonomes.

Chapitre 1 : Généralités sur la 5G.

1.1 Introduction

Ce chapitre se concentre sur l'étude des technologies de réseaux mobiles, en mettant l'accent sur l'évolution de la 4G (LTE) vers la 5G. Nous examinerons les caractéristiques, les objectifs et l'architecture de la 5G, ainsi que les principales différences avec la 4G en termes de débit, de latence, de couverture et d'efficacité énergétique. Nous explorerons également les cas d'utilisation de la 5G tels que l'eMBB, l'uRLLC et le mMTC, ainsi que les indicateurs de performances utilisés pour évaluer les systèmes 5G. Enfin, nous discuterons des différentes bandes de fréquences utilisées dans la 5G, y compris les basses fréquences, les fréquences moyennes et les hautes fréquences (ondes millimétriques), ainsi que de leurs avantages et limites.

1.2 Étude des technologies de réseaux mobiles

Depuis l'émergence des réseaux de communication analogiques dans les années 1980, les réseaux de communication mobile ont connu une évolution remarquable. Cette évolution n'est pas un processus unique, mais le résultat de plusieurs générations avec différentes normes, capacités et approches techniques. Environ tous les dix ans, une nouvelle génération est introduite [1].

The Evolution of 5G



Figure 1: Évolution des réseaux mobiles [F1]

1.3 Étude du LTE (Long Terme Evolution)

La 4G, également connue sous le nom de LTE (Long Terme Evolution), succède à la 3G et a été introduite pour la première fois en 2009. Voici quelques informations sur la 4G :

- **Débit** : La technologie 4G offre des vitesses de téléchargement beaucoup plus rapides que la 3G, allant jusqu'à 100 Mbps en fonction du signal et du nombre de personnes connectées à la même station dans la région. Cela permet aux utilisateurs de télécharger des fichiers volumineux en quelques secondes seulement, comparé aux minutes requises par la 3G.

- **Latence** : La 4G offre un temps de réponse plus rapide, ce qui permet d'accéder rapidement aux applications et aux sites web, sans délai important.

- **Couverture** : La 4G offre une couverture plus étendue que la 3G, permettant un accès à Internet dans plus d'endroits. Cependant, la couverture peut varier selon les zones géographiques et les opérateurs.
- **Sécurité** : La 4G offre un niveau de sécurité supérieur à la 3G, avec des algorithmes de cryptage plus robustes pour protéger les données des utilisateurs.
- **Technologie** : Elle utilise une technique appelée OFDM (Orthogonal Frequency Division Multiplexing) pour envoyer les données à des fréquences élevées, réduisant ainsi le temps nécessaire.
- **Applications** : La 4G permet l'utilisation de fonctions avancées telles que le streaming vidéo HD, la réalité virtuelle/augmentée et la messagerie instantanée pour des activités telles que les jeux et la communication vocale sur IP.

Il est important de noter que la 4G est en train d'être remplacée par la 5G, offrant des vitesses de données plus élevées et une latence réduite. Cependant, [2].

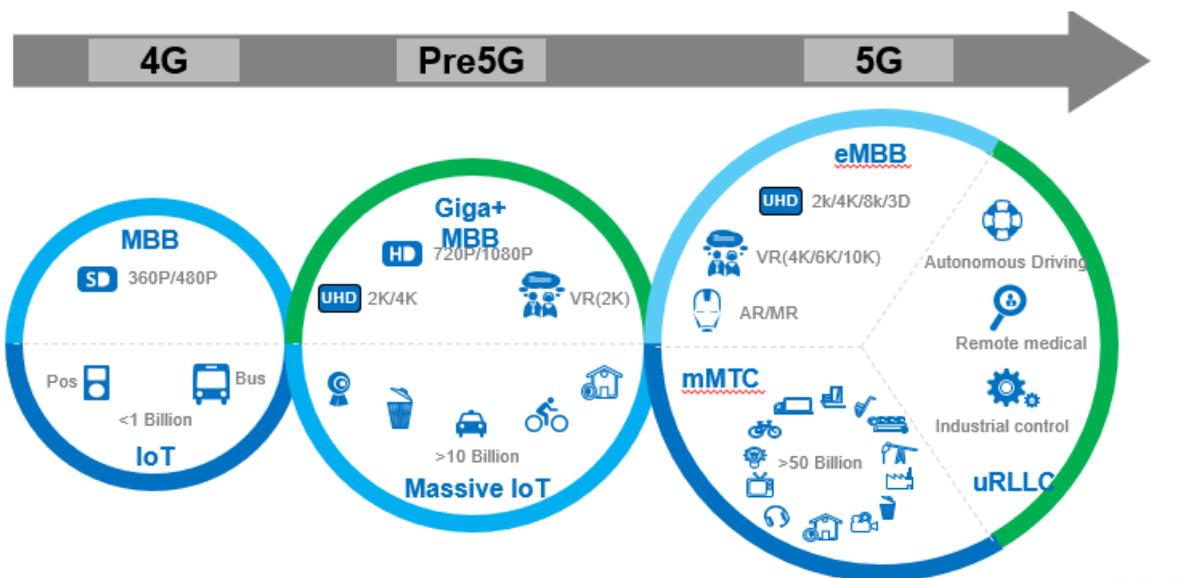


Figure 2: Services Evolution from 4G to 5G [F2]

1.4 Améliorations apportées par la 5G

Pour transformer la société en répondant à l'explosion des données et de la connectivité dans notre monde moderne. Elle promet d'améliorer les soins de santé, de rendre les villes plus intelligentes et les industries plus efficaces, en tirant parti de l'essor de l'Internet des objets. Ces avancées sont rendues possibles grâce à une gamme étendue de solutions innovantes qui stimulent La technologie de cinquième génération IMT-2020 présente un potentiel considérable l'économie contemporaine. La 5G offre des débits de

données plus rapides, des connexions fiables et une latence réduite La Figure 3 illustre les principales performances de la 5G par rapport à la 4G [3].

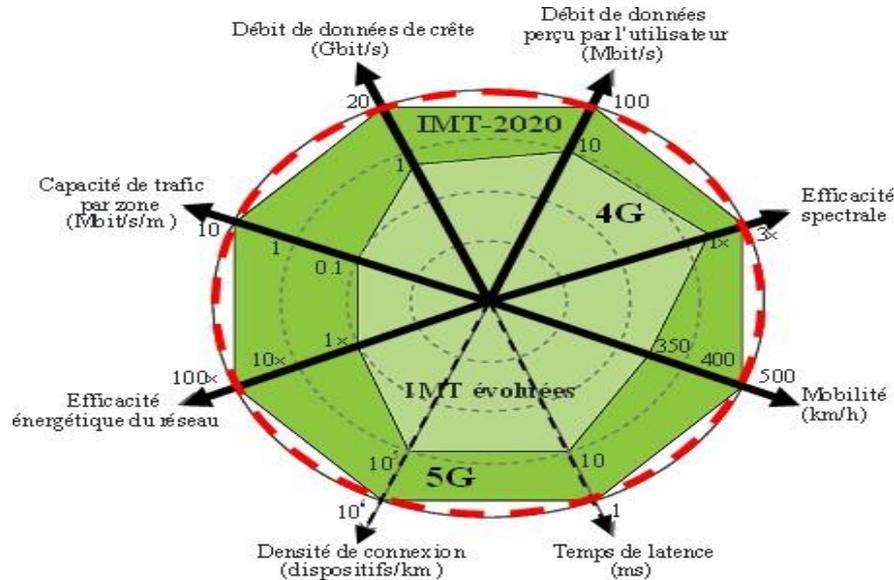


Figure 3: Performances de la 5G [F3].

Dans le cadre des recommandations de l'IMT-2020, voici les objectifs à atteindre définis par les huit indicateurs clés de performance (KPI) [3] :

- La 5G doit offrir des débits utilisateurs et maximaux respectivement 10 et 20 fois supérieurs à ceux de la 4G.
- L'efficacité spectrale doit être augmentée, permettant une utilisation plus efficace de la bande passante avec une amélioration trois fois supérieure.
- La mobilité doit être étendue jusqu'à 500 km/h pour garantir des performances spécifiques.
- La latence doit être réduite d'au moins 10 fois, avec une latence cible de 1 ms, afin de donner l'impression d'un réseau réactif pour certaines applications.
- La densité de connexion doit être considérablement augmentée, multipliée par 10, pour activer la connectivité de l'Internet des objets (IoT) avec une complexité minimale.
- Le réseau doit être 100 fois plus efficace sur le plan énergétique, en utilisant un traitement du signal et du matériel plus efficaces.
- La capacité de trafic doit être augmentée de 100 fois, en créant un réseau dense avec plus de points d'accès.
- La fréquence plus élevée de la 5G lui permettra, à long terme, de traiter de grandes quantités de données [3].

1.5 L'architecture générale du réseau 5G

1.5.1 Architecture Non-Standalone et Standalone

Selon la spécification 3GPP pour la 5G, le premier mode de déploiement des réseaux et des appareils sera le mode non autonome (NSA), ce qui signifie qu'il s'appuiera sur les infrastructures existantes du réseau 4G pour augmenter progressivement sa puissance et offrir des débits plus élevés]. Lorsqu'un appareil fonctionne en mode NSA, il se connecte d'abord à un réseau 4G LTE et peut utiliser la 5G si elle est disponible, afin de bénéficier d'une bande passante supplémentaire [8].

Au fil des années, de plus en plus d'infrastructures de réseau 5G seront déployées et évolueront vers un mode autonome uniquement (SA, Standalone Access). Dans ce mode, le réseau 5G fonctionnera de manière totalement indépendante du réseau 4G, offrant des améliorations significatives en termes de débit, de latence et la capacité de connecter un grand nombre d'appareils IoT. Ce sont là quelques-uns des principaux avantages de la 5G [8].

1.5.2 Les composants du réseau 5G

Le réseau central 5G, qui fait partie intégrante du système 5GS (source), joue un rôle essentiel en prenant en charge les fonctionnalités avancées du réseau 5G. Il constitue l'un des trois composants fondamentaux du système, aux côtés de l'équipement utilisateur (UE) et du réseau d'accès 5G (5G-AN). Le réseau d'accès 5G-AN comprend le réseau d'accès radio de nouvelle génération (NG-RAN), qui utilise la nouvelle interface radio 5G (NR) [3].

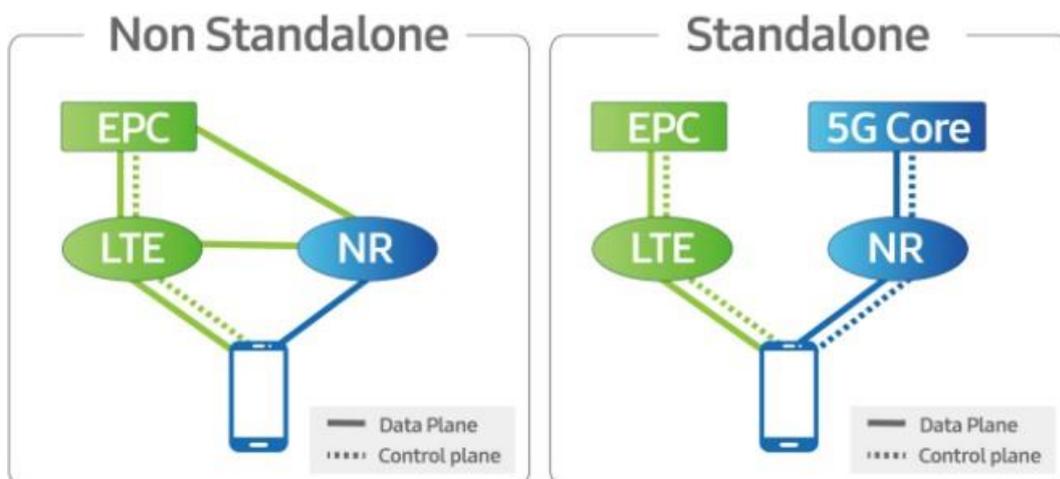


Figure 4: Architecture 5G NSA et 5G SA [F4].

Le cœur 5G met en place une architecture basée sur les services dans le cloud, qui offre des fonctionnalités telles que l'authentification des appareils interconnectés, la sécurité, la gestion des sessions et l'agrégation du trafic. Cette architecture nécessite une interconnexion complexe des différentes fonctions réseau. Ainsi, un réseau 5G se compose à la fois d'un réseau d'accès 5G (AN) et d'un réseau central 5G [3].

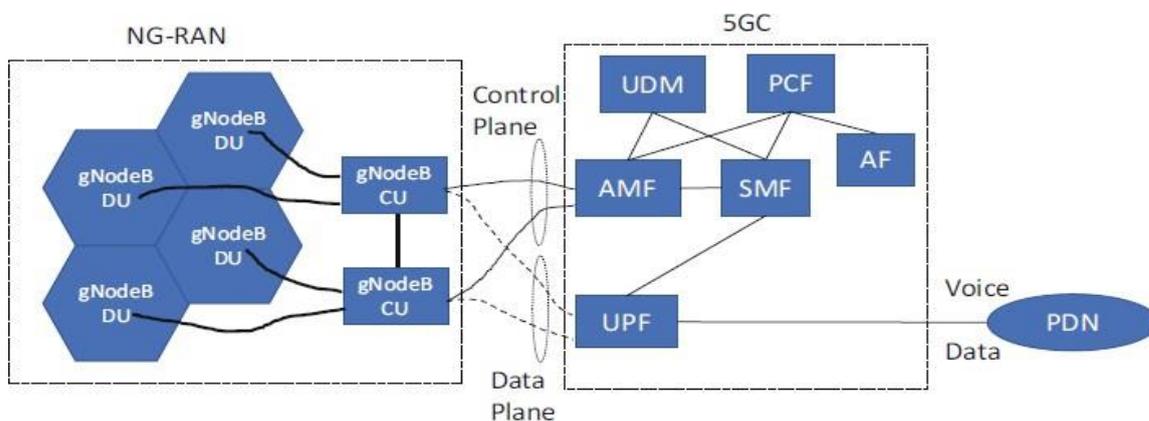


Figure 5: Schéma fonctionnel de l'architecture du réseau 5G [F5].

La figure (5) illustre le schéma fonctionnel de l'architecture du réseau de téléphonie cellulaire de cinquième génération (5G). Dans cette architecture, le cœur de la 5G (5GC Core) a remplacé l'EPC (Evolved Packet Core), tandis que le réseau d'accès radio de nouvelle génération (NG-RAN, Next-Generation Radio Access Network) est composé d'unités distribuées (DU) et d'unités centralisées (CU). De plus, le gNodeB a remplacé l'eNodeB. La flexibilité et l'évolutivité sont des éléments essentiels de l'architecture 5G. Ainsi, la combinaison de DU et de CU a été introduite pour prendre en charge différentes options de division du réseau d'accès radio afin de tirer parti des avantages mentionnés ci-dessus [3].

1.5.3 Les fonctionnalités du 5GC :

La fonction de gestion d'accès et de mobilité (AMF, Access and Mobility Management Function) : elle assure le chiffrement, l'intégrité, l'authentification, l'autorisation et la gestion de mobilité d'accès.

La fonction de gestion de session (SMF, Session Management Function) : elle attribue des adresses IP aux appareils, sélectionne et contrôle l'UPF (User Plane Function), et gère le roaming, entre autres.

La gestion des données unifiées (UDM, Unified Data Management) : elle gère les abonnements, les données utilisateur, l'enregistrement et la gestion de la mobilité, etc.

La fonction de contrôle de la politique (PCF, Policy Control Function) : elle met en œuvre des règles de politique pour les fonctions de contrôle de plan, etc.

La fonction de plan utilisateur (UPF, User Plane Function) : elle assure le point d'interconnexion externe au réseau de données, applique la politique de QoS dans le plan utilisateur, etc.

La fonction d'application (AF, Application Function) : il s'agit d'une fonction spécifiée et déployée par l'opérateur pour des services spécifiques [4].

1.6 Les cas d'usage de la 5G

La norme 5G offre de nombreuses possibilités d'utilisation, dont trois ont été définies par l'UIT (Union internationale des télécommunications) : les communications de type machine à machine (mMTC), les communications à ultra haut débit (eMBB) et les communications ultra-fiables et à faible latence (uRLLC). Cette catégorisation vise à associer chaque type d'utilisation aux besoins en termes de performances et de qualité de service du réseau [6].

Les cas d'utilisation de la 5G sont regroupés en trois catégories :

1. Les communications à ultra haut débit (eMBB) : elles correspondent aux communications mobiles à très haut débit et font suite aux générations précédentes de téléphonie mobile. Ce cas d'utilisation répond à la demande croissante d'utilisation des données mobiles. Il englobe des applications telles que la diffusion vidéo de haute qualité, la réalité virtuelle et augmentée. L'objectif est de répondre à une demande toujours plus importante en termes de quantité de données et de vitesse de transfert [6].

2. Les communications de type machine à machine (mMTC) : il s'agit des communications entre objets, notamment dans le contexte de l'Internet des objets (IoT). Cette catégorie se caractérise par la capacité à gérer un grand nombre de connexions (jusqu'à un million par kilomètre carré). Les quantités de données transférées par communication sont généralement limitées, et la vitesse de transfert n'est pas une contrainte majeure. Un exemple d'application typique est la gestion de services dans une ville intelligente à l'aide de réseaux de capteurs [6].

3. Les communications ultra-fiables et à faible latence (uRLLC) : dans les communications critiques, la fiabilité et le temps de réponse sont cruciaux. L'application phare de cette catégorie est la voiture autonome, mais elle englobe également les communications pour la sécurité et les services médicaux d'urgence tels que la chirurgie à distance. Il ne doit y avoir aucune panne ni interruption de communication, et la transmission doit être aussi rapide que possible [6].

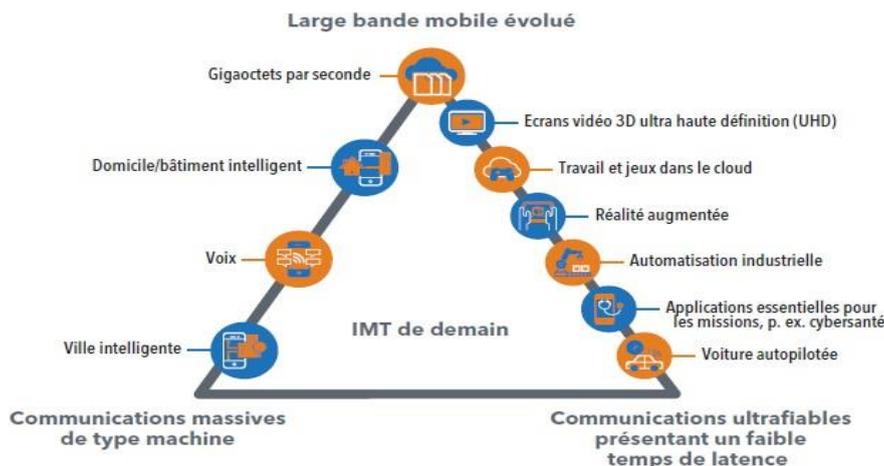


Figure 6: Scénarios d'utilisation de l'IMT-2020 [F6].

1.7 Les technologies envisagées par les réseaux 5G

Les systèmes radio 5G utilisent des fréquences de diffusion ultra-hautes pour transférer de grandes quantités de données. Les fréquences d'ondes millimétriques, caractérisées par une perte de propagation élevée, nécessitent l'utilisation de techniques telles que la formation de faisceaux et le massive MIMO afin d'optimiser l'efficacité spectrale et de fournir une couverture rentable et fiable [8]. Voici les principes de ces nouvelles technologies :

1.7.1 Les ondes millimétriques

Traditionnellement, les communications cellulaires utilisaient des fréquences inférieures à 6 GHz, tandis que les fréquences supérieures étaient réservées à d'autres services tels que l'imagerie médicale, la télédétection par micro-ondes et la radioastronomie. Cependant, l'augmentation massive du trafic de données a entraîné une congestion du spectre des radiofréquences, limitant ainsi la bande passante disponible pour chaque utilisateur et entraînant des connexions plus lentes et moins fiables. Pour résoudre ce problème, la communication sans fil a opté pour l'utilisation de fréquences supérieures à 6 GHz, notamment les ondes millimétriques qui se situent entre 30 GHz et 300 GHz. Ces fréquences offrent une bande passante dix fois supérieure à celle de l'ensemble de la bande cellulaire 4G. Cependant, elles sont moins adaptées aux communications à longue portée, ne peuvent pas pénétrer les bâtiments et sont absorbées par la pluie. Afin de surmonter ces limitations, d'autres technologies sont nécessaires [8][7].

1.7.2 Les petites cellules

L'utilisation d'ondes millimétriques permet d'utiliser des antennes de quelques centimètres seulement, ce qui facilite leur déploiement dans des environnements urbains denses et en intérieur. Cela conduit à la création de cellules de petite taille, couvrant des zones géographiques réduites de moins d'une centaine de mètres. Ce découpage des cellules permet de partager le débit de chaque antenne entre un nombre restreint d'utilisateurs, évitant ainsi la saturation du réseau. Les petites cellules jouent un rôle crucial dans la fourniture d'un haut débit

mobile et d'une latence ultra-faible pour la 5G. On distingue les microcellules, les femtocellules et les picocellules en fonction de la zone de couverture et du nombre d'utilisateurs pris en charge [8].

1.7.3 Le Massive MIMO

Le Massive MIMO constitue une avancée par rapport aux systèmes MIMO actuels utilisés dans les réseaux sans fil. Il regroupe des centaines, voire des milliers d'antennes au niveau de la station de base et permet de desservir simultanément plusieurs dizaines d'utilisateurs en partageant les mêmes ressources temporelles et fréquentielles. Les antennes supplémentaires utilisées dans le Massive MIMO contribuent à concentrer l'énergie dans une région spatiale plus restreinte, ce qui améliore l'efficacité spectrale et le débit.

Avec l'augmentation du nombre d'antennes, les faisceaux émis deviennent plus directs et focalisés, ce qui augmente le débit pour l'utilisateur ciblé tout en réduisant les interférences avec les utilisateurs voisins. Les systèmes Massive MIMO nécessitent une formation de faisceaux et un décodage précis, tout en utilisant des algorithmes plus simples voire linéaires. Cependant, des techniques de traitement de signal efficaces doivent être utilisées aux deux extrémités pour surmonter la complexité de la surcharge de signalisation [7].

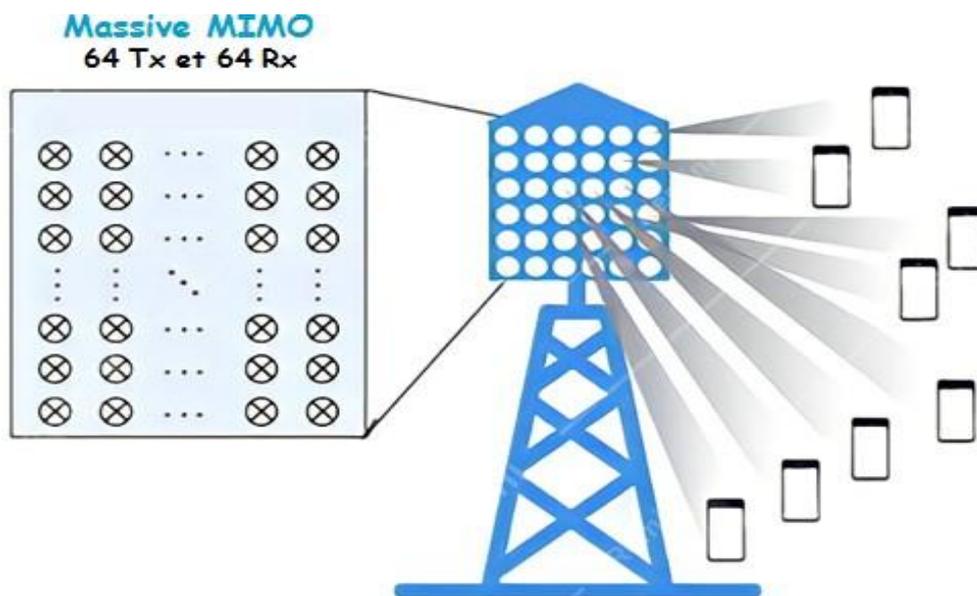


Figure 7: la technologie Massive MIMO [F7].

1.7.4 Le Beamforming

Le beamforming, également connu sous le nom de filtrage spatial ou formation de faisceaux, est une technique qui permet aux stations de base de trouver des chemins appropriés pour fournir des données aux utilisateurs. Il consiste à concentrer les signaux provenant de plusieurs antennes en un faisceau puissant, réduisant ainsi l'énergie dans les lobes latéraux à l'extrémité de l'émetteur. Du côté de la réception, le beamforming implique le regroupement spatial des signaux reçus, les superposant dans une direction spécifique tout en rejetant les signaux provenant d'autres directions considérées comme des interférences. Cette technologie offre plusieurs avantages pour les réseaux 5G. Dans les systèmes Massive MIMO, le beamforming contribue à améliorer l'efficacité spectrale, tandis que pour les ondes millimétriques, il permet d'augmenter le débit de données [7].

Dans un système Massive MIMO, la station de base peut envoyer des données aux utilisateurs par le biais de différents chemins, et le beamforming synchronise les échanges de paquets et les heures d'arrivée, ce qui permet à plusieurs utilisateurs d'envoyer des données simultanément. Étant donné que les ondes millimétriques ne peuvent pas pénétrer les obstacles et se propagent sur de courtes distances en raison de leurs longueurs d'onde plus courtes, le beamforming permet d'envoyer des faisceaux concentrés vers les utilisateurs, compensant ainsi ces limitations [8].

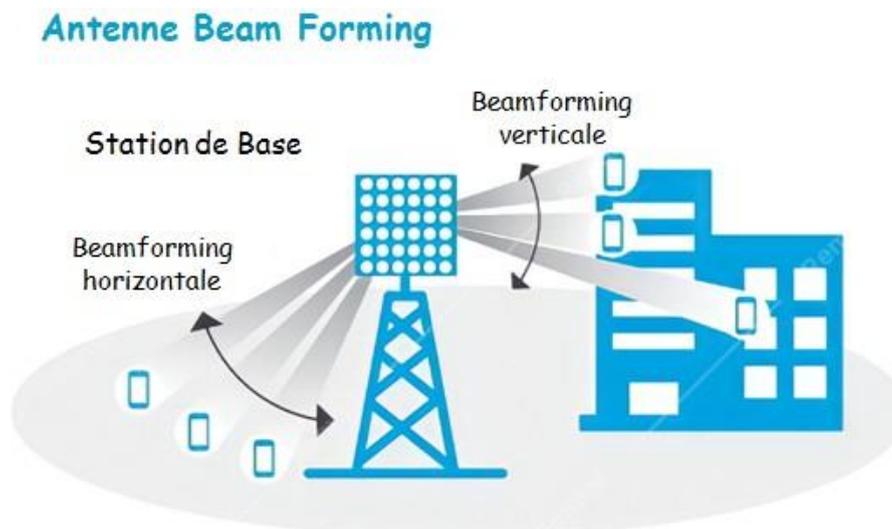


Figure 8: la technologie Beamforming[F8].

1.8 Objectifs de la technologie 5G

La cinquième génération de réseau mobile vise à offrir des débits utilisateur et des débits maximaux 10 à 20 fois plus rapides que ceux disponibles actuellement avec la 4G. Son objectif est d'améliorer l'efficacité énergétique et de garantir une connexion stable, même lorsque l'utilisateur est en mouvement. La 5G offre également un réseau extrêmement fiable avec des performances homogènes, indépendamment de la position de l'utilisateur par rapport à la station de base. Elle vise également à réduire considérablement la latence pour favoriser l'émergence

d'applications critiques, en particulier dans les zones urbaines. Cependant, la 5G ne permet pas le CS-Fallback, ce qui signifie que le transfert entre le réseau d'accès radio 5G et GERAN (2G) ou UTRAN (3G) n'est pas défini [1].

1.9 Comparaison entre les performances de la 5G et la 4G LTE Advanced

Le terme 4G signifie 4ème génération. Ce réseau permet de surfer jusqu'à 150 Mb/s par seconde sur le réseau SFR, offrant ainsi une navigation rapide avec des temps de chargement très courts.

La vitesse du réseau 5G sera considérablement améliorée par rapport à celle de la 4G, grâce à l'utilisation de la nouvelle bande 5G (3,5 GHz). Elle permettra une navigation jusqu'à 10 fois plus rapide que la 4G, avec une réactivité optimisée pour les échanges constants et quasi-immédiats entre les objets et les serveurs applicatifs. En plus de fournir des débits élevés, la bande 3,5 GHz permettra d'assurer une couverture optimale du territoire [1].

Globalement, la 5G sera bien plus rapide, intelligente et performante que la 4G. Elle promet une vitesse de débit mobile qui dépassera largement celle des réseaux locaux à haut débit les plus rapides d'aujourd'hui.

- **Débit maximal**

Le débit maximal par utilisateur est défini comme le débit crête. Pour la 5G, les exigences en termes de débit de données sont de 20 Gbit/s en téléchargement et 10 Gbit/s en téléversement.

- **Débit utilisateur**

Ce critère correspond au débit de données atteignable par un utilisateur ou un appareil mobile dans la zone de couverture, exprimé en Mbps. Il reflète l'expérience utilisateur dans cette zone. L'UIT-R a fixé une exigence de débit pour ce KPI, à 100 Mbps en téléchargement et 50 Mbps en téléversement.

- **Efficacité spectrale**

C'est le débit de données maximal dans des conditions idéales normalisé par la bande passante du canal, exprimé en bit/s/Hz. L'UIT-R a fixé un objectif d'efficacité spectrale pour la 5G à 30 bits/Hz en téléchargement et 15 bit/s/Hz en téléversement. Pour atteindre ces exigences, il est nécessaire d'avoir 1 GHz de spectre, avec un minimum de 100 MHz de bande passante. La combinaison de cet indicateur clé de performance et du débit maximal souligne l'importance d'une large bande passante pour une performance optimale de la 5G.

- **Mobilité**

Il s'agit de la vitesse maximale à laquelle les terminaux peuvent se déplacer tout en garantissant une communication continue et sans perte. Cette vitesse est définie en fonction de quatre classes de mobilité : mode stationnaire (0 km/h), déplacement à pied

(0 km/h à 10 km/h), déplacement en véhicule (10 km/h à 120 km/h) et déplacement à haute vitesse (120 km/h à 500 km/h).

- **Latence**

Elle varie selon le cas d'utilisation et est fixée à 4 ms pour les services eMBB et à 1 ms pour les services uRLLC.

- **Nombre d'objets connectés dans une zone**

Cela mesure le nombre d'objets connectés pouvant être pris en charge par unité de surface. L'UIT-R a fixé un objectif de 1 million de dispositifs par km² pour les communications de type machine.

- **Efficacité énergétique du réseau**

Cela représente la quantité de données transmises ou reçues par les utilisateurs par unité de consommation d'énergie du réseau d'accès radio (RAN). Du côté des appareils, cela fait référence à la quantité de données transmises ou reçues par unité de consommation d'énergie du module de communication.

- **Capacité de débit surfacique**

Cela se réfère à la quantité de données qui peuvent être transférées par unité de surface (par exemple, Mbps/m²). Cela permet de mesurer l'efficacité du réseau dans la couverture d'une zone géographique donnée en fournissant une indication de la quantité de données qui peuvent être transférées dans cette zone.

Tableau 1: comparaison entre les performances de la 5G et de la 4G LTE Advanced.

Caractéristiques	5G	4G LTE Advanced
Débit	Jusqu'à plusieurs gigabits par seconde	Jusqu'à plusieurs dizaines de mégabits par seconde
Couverture	Expansion progressive de la couverture, principalement dans les zones urbaines	Couverture étendue, disponible dans de nombreuses régions du monde
Bande de fréquences	Utilise des bandes de fréquences inférieures à 6 GHz et des fréquences millimétriques (mmWave) pour des débits plus élevés	Utilise principalement les bandes de fréquences inférieures à 6 GHz
Capacité	Capacité extrêmement élevée, supportant un nombre massif d'appareils simultanés	Limite de capacité élevée, supportant un grand nombre d'appareils simultanés
Latence	Inférieure à 1 milliseconde	Environ 10 à 20 millisecondes
Technologies	Les technologies telles que la modulation d'onde millimétrique (mmWave), le Massive, le beamforming, etc.	Basé sur la technologie LTE (Long Term Evolution)

1.10 Performances de la 5G dans le domaine urbain

La 5G offre bien plus qu'une simple amélioration des communications pour les voitures autonomes. Les passagers pourront bénéficier d'une connectivité Internet à bord des véhicules, leur permettant de se divertir et d'accéder à Internet, à des contenus multimédias et à des jeux en ligne. Grâce à l'eMBB (broadband mobile amélioré), la 5G offre un débit important et une latence réduite (4 ms). De plus, la 5G permet la connectivité entre la voiture et la maison de l'utilisateur, offrant la possibilité de contrôler à distance des appareils domestiques. La technologie mMTC contribue à l'efficacité énergétique des voitures et permet une augmentation de la densité de connexions avec d'autres objets connectés. Dans le domaine de la conduite autonome, la 5G permet une communication instantanée entre les véhicules et l'infrastructure routière, offrant une réactivité rapide face aux obstacles [1].

1.11 Étude du Network Slicing

Le network slicing est une évolution des réseaux mobiles vers la virtualisation, permettant de créer des services de connectivité spécialisés pour des utilisations

spécifiques. Le réseau est découpé en tranches logiques indépendantes, appelées "slices", qui reposent sur l'infrastructure physique de la 5G. Cela offre plusieurs avantages, tels qu'une plus grande élasticité, robustesse, sécurité et stabilité des opérations. Chaque slice est optimisé pour les besoins spécifiques des services ou des segments pour lesquels il est défini. L'orchestration automatisée des services basée sur l'intelligence artificielle apporte flexibilité et efficacité [1].

1.11.1 Performances du Network Slicing dans le domaine urbain

Le network slicing divise les différents cas d'utilisation de la 5G en tranches. Dans le domaine de la mobilité autonome, le slice uRLLC est utilisé pour garantir une faible latence et une fiabilité élevée pour le trafic routier. Les véhicules sont équipés de routeurs mobiles (OBUs) qui se connectent au réseau 5G, leur permettant d'avoir une vue complète de leur environnement. Le network slicing permet de séparer les flux de données afin d'optimiser l'utilisation de la bande passante. Les flux multimédias destinés au divertissement des utilisateurs sont différenciés des données de communication entre véhicules. Ainsi, même en cas de saturation de la cellule du réseau, cela n'affecte pas le trafic dans le slice Ultra Low Latency High Reliability, qui reste isolé et maintient ses performances élevées en termes de débit et de latence [1].

1.12 Conclusion

Dans ce chapitre nous avons supervisé en premier lieu l'étude de réseaux mobiles en suite l'étude de LTE (Long Terme Evolution) et enfin notre étude s'est porter sur la 5G , son Architecture , La couche d'accès de la 5G ,son mode de déploiement et son Objectifs, également nous avons effectué une Comparaison entre les performances de la 5G et la 4G LTE Advanced , également on a évoqué les Caractéristiques de la 5G , les catégories d'usage de la 5G qui comporte les objectifs de l'eMBB , l'uRLLC et l'mMTC et Performances du la 5G du Network Slicing dans le trafic urbain.

Chapitre 2 : Caractéristiques des véhicules autonomes.

2.1 Introduction

Dans ce chapitre nous avons étudié les véhicules autonomes, qui fonctionnent sans intervention humaine grâce à des technologies de pointes très avancées telles que capteurs, caméras et lidars. Ils permettent d'améliorer la sécurité routière, réduisent les embouteillages et nous offrent une accessibilité accrue. Malgré des déploiements commerciaux limités, le niveau d'autonomie totale reste un défi. Les technologies clés incluent les capteurs, la communication V2V et V2I. Le chapitre souligne également les caractéristiques des réseaux de véhicules (VANET) et les défis liés à la mobilité et à la sécurité.

2.2 La définition des véhicules autonomes

Un véhicule autonome est un type de véhicule qui utilise des technologies avancées pour fonctionner sans intervention humaine. Il est équipé de capteurs, de caméras, de lidars et d'autres technologies qui lui permettent de percevoir l'environnement, d'analyser les données en temps réel et de prendre des décisions appropriées. Les constructeurs automobiles ont développé ces véhicules pour améliorer la sécurité routière, compte tenu de l'augmentation des accidents mortels sur les routes. Les véhicules autonomes font partie des Systèmes de Transports Intelligents (STI) qui visent à améliorer la mobilité des personnes, ainsi que la sécurité, l'efficacité et la fiabilité des déplacements. Ils sont équipés de capteurs lidar, de systèmes de vision, de communication V2X et utilisent des technologies sans fil pour communiquer avec leur environnement [9].

2.3 Importance et avantages des véhicules autonomes

- **Sécurité accrue**

Les véhicules autonomes ont le potentiel de réduire considérablement les accidents de la route causés par des erreurs humaines, améliorant ainsi la sécurité routière et sauvant des vies.

- **Réduction des embouteillages et de la congestion**

Les véhicules autonomes utilisent des systèmes de navigation intelligents pour optimiser les itinéraires, ce qui permet de réduire les embouteillages et la congestion routière. Ils peuvent communiquer entre eux et s'adapter en temps réel aux conditions de trafic, favorisant ainsi une circulation plus fluide et une meilleure utilisation des infrastructures routières existantes.[9]

- **Accessibilité accrue**

Les véhicules autonomes offrent une mobilité accrue aux personnes ayant des limitations physiques ou ne pouvant pas conduire, améliorant ainsi leur indépendance et leur qualité de vie.

- **Réduction de la consommation d'énergie et des émissions**

Les véhicules autonomes peuvent être programmés pour adopter des comportements de conduite écoénergétiques, contribuant ainsi à la réduction des émissions de gaz à effet de serre et à une mobilité plus durable [9].

- **Utilisation efficace de l'espace urbain**

Les véhicules autonomes partagés et les services de covoiturage basés sur ces technologies pourraient réduire le besoin de stationnement dans les zones urbaines densément peuplées, libérant ainsi de l'espace pour d'autres infrastructures ou espaces verts.[9]

- **Productivité accrue**

Les passagers des véhicules autonomes peuvent utiliser leur temps de trajet de manière productive en travaillant, en se divertissant ou en se relaxant, améliorant ainsi leur productivité et leur bien-être.

2.4 Évolution et état actuel des véhicules autonomes

Les véhicules autonomes ont connu une évolution remarquable, passant de prototypes expérimentaux à des déploiements commerciaux limités. Les entreprises technologiques et les constructeurs automobiles ont investi massivement dans la recherche et le développement de cette technologie. Actuellement, la plupart des véhicules sur les routes sont de niveau 1 ou 2, offrant des fonctionnalités d'assistance à la conduite. Les véhicules de niveau 3 et 4, qui permettent une autonomie partielle dans des conditions spécifiques, sont en cours de développement. Cependant, le niveau 5, qui correspond à une autonomie totale dans toutes les conditions, reste un défi majeur. Bien que les véhicules autonomes offrent de nombreux avantages potentiels, leur adoption généralisée nécessite la résolution de questions réglementaires, de responsabilité, d'éthique et de confiance [15].

2.5 Les technologies clés des véhicules autonomes

Les capteurs intégrés aux voitures autonomes sont appelés capteurs intelligents et présentent certaines caractéristiques :

- Ils sont conçus pour effectuer des mesures.
- Ils utilisent la technologie numérique.
- Ils permettent une communication bidirectionnelle.
- Ils possèdent des capacités de traitement.

2.5.1 Les Lidars

Les véhicules autonomes sont équipés d'un ou plusieurs Lidars qui collectent des informations sur les objets environnants jusqu'à une distance de 150 mètres en utilisant des lasers qui effectuent une analyse à 360 degrés. Les Lidars fonctionnent en émettant des faisceaux laser dans l'environnement autour du véhicule. Ces faisceaux sont ensuite renvoyés

par les obstacles rencontrés et détectés par le Lidar, qui calcule avec précision la distance parcourue par le faisceau en utilisant la vitesse de propagation. Les données recueillies se présentent sous forme de milliers de points, ce qui permet la détection et la catégorisation précise des objets environnants tels que les voitures, les feux de signalisation, les piétons, les arbres, etc. [9].

2.5.2 Les caméras

Les caméras dans les véhicules autonomes ont pour rôle de détecter les obstacles proches de la voiture et de confirmer les informations recueillies par les autres capteurs. En général, il y a quatre caméras présentes dans une voiture autonome : une caméra frontale qui enregistre des vidéos de la route devant le véhicule, deux caméras latérales gauche et droite pour obtenir des informations sur les côtés, et une caméra arrière qui fournit des informations sur l'environnement à l'arrière du véhicule [9].



Figure 9: Fonctionnement des STIs [F9].

2.5.3 Les Ultrasons

Les véhicules autonomes sont équipés de plusieurs capteurs à ultrasons qui sont conçus pour détecter les obstacles à proximité. Ces capteurs permettent au véhicule de maintenir une distance sécuritaire avec les objets et les obstacles situés à l'avant, à l'arrière ou sur les côtés de la voiture [9].

2.5.4 Les radars

Les véhicules autonomes sont équipés de radars conçus pour détecter les obstacles à une distance plus grande que les capteurs à ultrasons. Ces radars utilisent des ondes électromagnétiques pour mesurer les distances entre le véhicule et les objets environnants.

2.5.5 Capteurs de mouvements et de positions

Afin d'assurer la sécurité de la circulation des véhicules autonomes, il est essentiel qu'ils connaissent en permanence leur position exacte avec une grande précision. Cela est rendu possible grâce à un capteur doté d'une unité de réception pour les signaux du système de positionnement par satellite (GNSS), qui permettent de déterminer avec précision la position absolue du véhicule autonome. Même en cas de perte de la connexion satellite, par exemple lorsqu'un véhicule entre dans un tunnel, le capteur de mouvements et de positions peut continuer à déterminer la position du véhicule pendant quelques secondes en calculant sa position relative par rapport à la dernière position absolue connue [9].

2.6 Communication (V2V) et (V2I) et (V2X)

2.6.1 La technologie V2I

La communication V2I, également appelée communication en mode infrastructure, utilise les différents composants du réseau VANET, tels que les unités embarquées des véhicules, les stations de base placées le long des routes et les terminaux d'accès, pour assurer les communications dans le réseau. Elle offre une connectivité plus fiable que la communication en mode V2V et permet une utilisation plus efficace des ressources du réseau. Les véhicules peuvent ainsi bénéficier de nombreuses fonctionnalités et services, tels que l'accès à Internet et aux informations météorologiques. Pour cela, la technologie V2I [10] utilise des réseaux tels que le Wi-Fi, le réseau cellulaire ou le Wimax pour permettre aux véhicules de recevoir des informations sur l'état des feux de signalisation et d'adapter leur vitesse en conséquence, améliorant ainsi la fluidité du trafic.



Figure 10: Communication Véhicule to infrastructure [F10].

2.6.2 La technologie V2V

Cette méthode de communication repose sur l'utilisation de dispositifs intégrés aux véhicules, connus sous le nom d'OBU (On-Board Unit), et suit une architecture décentralisée. Elle est similaire aux communications entre nœuds mobiles dans les réseaux MANETs. Les véhicules communiquent directement entre eux, en utilisant un mode ad hoc inter-véhiculaire, sans nécessiter l'utilisation d'infrastructures externes. Cependant, pour établir une communication, il est important que chaque véhicule se trouve dans la portée radio de l'autre. Dans le cas contraire, ils peuvent faire appel à d'autres véhicules agissant comme des ponts intermédiaires. Ce type de transmission est connu sous le nom de communication à plusieurs sauts. [9].



Figure 11: Communication Vehicule to Vehicule[F11].

2.6.3 La technologie V2X

La technologie V2X est une technologie qui permet aux véhicules de communiquer avec différents éléments du trafic qui les entourent, tels que les autres véhicules, les piétons, la signalisation, etc., en utilisant des signaux sans fil comme le Wi-Fi ou le réseau de téléphonie mobile. Cette technologie facilite les échanges de messages entre tous les acteurs du trafic, ce qui permet une perception collaborative ou coopérative.

Le concept V2X peut être divisé en plusieurs sous-catégories : la V2I (Vehicle-to-Infrastructure), la V2V (Vehicle-to-Vehicle), la V2P (Vehicle-to-Pedestrian), la V2D (Vehicle-to-Device) et la V2N (Vehicle-to-Network).

L'objectif ultime de la technologie V2X est d'améliorer la sécurité des usagers de la route, en particulier des plus vulnérables tels que les piétons et les cyclistes, en améliorant la collecte d'informations. De plus, cette technologie vise à réduire les embouteillages et à économiser de l'énergie.

Il est important de noter que cette technologie est actuellement en phase de test et n'est pas encore déployée à grande échelle à travers le monde.

2.7 Étude du réseau véhiculaire VANET

Les réseaux véhiculaires sans fil, connus sous le nom de VANET (Vehicular Ad-hoc Network), sont une forme spécifique de réseaux mobiles ad hoc (MANET), où les nœuds mobiles sont des véhicules. Ces réseaux permettent d'établir des communications entre les véhicules ou entre les véhicules et l'infrastructure le long de la route, dans le but d'améliorer la sécurité routière ou de fournir aux conducteurs un accès à Internet. Pour mettre en place un tel réseau, plusieurs équipements électroniques doivent être installés dans les véhicules, tels que des calculateurs, des cartes réseau, des capteurs, un système de localisation GPS et une plateforme de traitement. Différentes technologies peuvent être utilisées pour établir les communications véhiculaires, telles que les réseaux sans fil de type 802.11, WIMAX, Bluetooth, etc. [14]

Un réseau ad hoc de véhicules est composé de trois unités de communication :

- **L'OBU (On Board Unit)**

Il s'agit d'un dispositif électronique embarqué dans les véhicules intelligents. Il est composé de plusieurs composants matériels et logiciels avancés tels que le GPS, le radar, les caméras et divers capteurs. Son rôle est de permettre la localisation, la réception, le calcul, le stockage et l'envoi de données sur le réseau. L'OBU fonctionne comme un émetteur-récepteur et permet la connexion du véhicule au réseau de communication.

- **Le RSU (Road Side Unit) :**

Ce sont des entités situées au bord de la route, comprenant des lampadaires, des feux, des panneaux de signalisation, etc. Ils peuvent également servir de stations de base en relayant les informations envoyées par un véhicule. De plus, ils peuvent être utilisés comme points d'accès au réseau pour diffuser aux véhicules des informations sur l'état du trafic, les conditions météorologiques, l'accès à Internet et d'autres données.

- **Le TA (Trusted Authority) :**

Il joue le rôle de serveur de stockage et de transaction pour les différents équipements du réseau VANET, notamment les OBU et les RSU. Sa principale fonction consiste à garantir l'authenticité des identités des véhicules et à les transmettre aux différentes entités du réseau.[11]

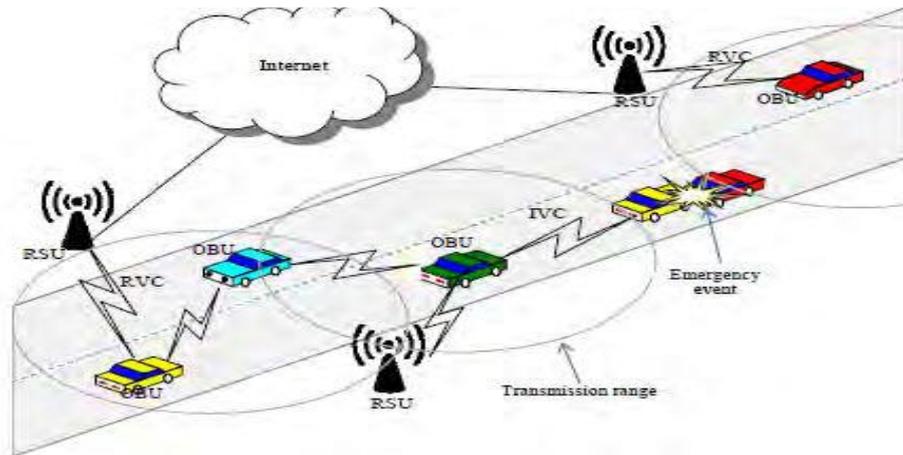


Figure 12: Composants d'un VANET [F12].

2.8 Caractéristiques des réseaux de véhicules

Les réseaux VANET se distinguent des réseaux sans fil traditionnels par plusieurs caractéristiques :

- **Forte mobilité**

Les réseaux VANET sont composés de nœuds mobiles à grande vitesse, capables de rejoindre ou de quitter rapidement le réseau. Cependant, cette mobilité élevée peut affecter la connectivité et réduire la durée de vie des liens établis. Ainsi, les véhicules peuvent entrer ou quitter le réseau à tout moment, ce qui représente un défi majeur pour ces réseaux ad hoc.[11]

- **Environnements de routage et modèles de mobilité**

En raison de la vitesse élevée des véhicules, le passage d'un environnement à un autre est souvent imprévisible. Chaque environnement peut varier en termes de densité et de vitesse des nœuds, rendant difficile la conception d'un protocole efficace adapté à toutes les situations possibles.

- **Capacité de traitement et puissance de la batterie**

Les réseaux VANET bénéficient de l'avantage de ne pas avoir de contraintes en termes d'énergie et de stockage, contrairement à d'autres types de réseaux. Les nœuds des réseaux VANET sont alimentés par l'énergie électrique produite en continu pendant la conduite, ce qui leur confère une grande capacité de traitement.

- **Échange fréquent d'informations**

Les nœuds sont motivés à collecter des informations à partir des unités bord de route et des autres véhicules, ce qui entraîne une fréquence élevée d'échanges d'informations entre les nœuds.

- **Communications sans fil**

Les données échangées entre les nœuds des réseaux de véhicules sont transmises sans fil, ce qui pose un défi majeur en termes de sécurité des messages transmis. Ainsi, la conception des protocoles de communication doit prendre en compte cet aspect crucial [11].

- **Temps critique**

Les données échangées doivent être transmises rapidement pour permettre aux nœuds de prendre des décisions en temps réel. Les informations sur les conditions routières peuvent être obtenues à partir de cartes géographiques et de systèmes de positionnement tels que le GPS (Global Positioning System) [11].

- **Mobilité prévisible**

Les réseaux de véhicules se distinguent des autres réseaux mobiles car les véhicules sont limités à suivre des mouvements restreints aux voies de circulation. Les informations routières sont souvent obtenues à partir de cartes géographiques et de systèmes de positionnement tels que le GPS. En utilisant la direction, la trajectoire de la route et la vitesse moyenne, il est possible de prédire la position future d'un véhicule [11].

2.8.1 Types de messages

Les messages transmis au sein des réseaux VANET peuvent être classés en deux catégories principales en fonction de leur utilité et de leur contenu : les messages liés à la sécurité et les messages à valeur ajoutée [14].

- **Les messages liés à la sécurité :**

L'objectif des réseaux VANET est d'assurer la sécurité des usagers de la route, et deux types de messages de sécurité sont couramment utilisés :

- **Les messages Beacon :**

Ils contiennent des informations telles que l'identité et l'état actuel du véhicule (position, vitesse, direction, etc.) et sont diffusés périodiquement pour faciliter l'identification des véhicules voisins. Ces messages sont essentiels pour la plupart des protocoles de routage et de sécurité dans les réseaux VANET.

- **Les messages d'alerte (URGENCE) :**

Ces messages sont transmis pour alerter les autres véhicules des situations d'urgence et des événements se produisant sur la route (accidents, embouteillages, conditions météorologiques, passages de véhicules d'urgence, etc.). Leur objectif est de donner aux conducteurs plus de temps pour réagir, contribuant ainsi à améliorer la circulation et la sécurité routière en prévenant les dangers potentiels. Les messages à valeur ajoutée :

Ce type de message peut inclure toutes sortes d'informations et de données, telles que des informations sur les services disponibles (restaurants, hôtels à proximité), des données multimédias ou toute autre information pouvant améliorer le confort des usagers de la route.

2.9 Appréhension de la voiture autonome dans son environnement

Les systèmes de véhicules autonomes génèrent d'importantes quantités de données provenant de capteurs embarqués, d'informations de localisation, de flux d'images et de communications telles que les e-mails, les SMS et les données de divertissement. Un véhicule autonome connecté peut produire jusqu'à 1 Go de données par seconde. Ces données collectées permettent au véhicule de percevoir son environnement, de l'analyser et de l'interpréter, puis de prendre des décisions pour naviguer efficacement dans diverses conditions [13].

2.9.1 Perception de l'environnement

Le véhicule autonome doit être capable de détecter et d'identifier tous les objets fixes ou mobiles dans son environnement, tels que les feux de circulation, les panneaux de signalisation, les autres véhicules, ainsi que les usagers et objets de la route. Cette détection des objets est réalisée grâce à la fusion des données provenant des capteurs radar, lidar et caméra, permettant ainsi une compréhension complète de la scène environnante. Les capteurs, équipés de dispositifs radio intégrés, envoient des informations vers l'antenne Mu-MIMO. Cette antenne dispose de plusieurs canaux ou connexions, ce qui lui permet de recevoir et d'envoyer des informations simultanément. Pour répondre à la demande continue des capteurs, l'antenne doit avoir une bande de fréquence suffisamment élevée (> 24 GHz). L'émission et la réception sur les antennes Mu-MIMO permettent de concentrer la puissance émise dans une direction spécifique (beamforming), améliorant ainsi les performances de transmission. Lorsque l'antenne reçoit une demande, elle alloue un débit élevé, ce qui entraîne une faible latence et permet un traitement rapide des informations [13].

2.9.2 Analyse des données reçues

Pour permettre à un véhicule autonome de naviguer de manière efficace, il est essentiel qu'il puisse identifier et classifier les obstacles tels que les piétons, les vélos, les motos, les bus et les camions. Cela est rendu possible grâce aux caméras embarquées sur le véhicule, qui valident en temps réel les données reçues des capteurs. L'utilisation d'algorithmes est donc nécessaire pour donner du sens aux données provenant des capteurs et des caméras, fournissant ainsi une représentation détaillée de l'environnement entourant le véhicule autonome. Plusieurs algorithmes permettent au véhicule d'identifier les objets en temps réel [12].

2.9.2.1 Le framework TensorFlow

TensorFlow est une solution avancée et à grande échelle d'intelligence artificielle utilisée dans les domaines de l'apprentissage automatique et de l'apprentissage profond. Développé par

Google, il sert d'algorithme largement adopté pour la détection d'objets et est intégré aux logiciels informatiques. Le système fonctionne en recevant constamment des images de la caméra embarquée. Ces images sont ensuite traitées localement par l'application, qui effectue l'inférence en utilisant un modèle pré-entraîné. Les objets détectés sont identifiés par leurs étiquettes et les coordonnées des images correspondantes sont transmises. En se basant sur ces informations, l'application génère de nouvelles images avec des rectangles entourant les objets détectés. Des images distinctes sont créées pour chaque catégorie d'objets, permettant ainsi au véhicule autonome de les différencier. Le processus de détection et de catégorisation des objets est illustré dans le diagramme suivant [11].

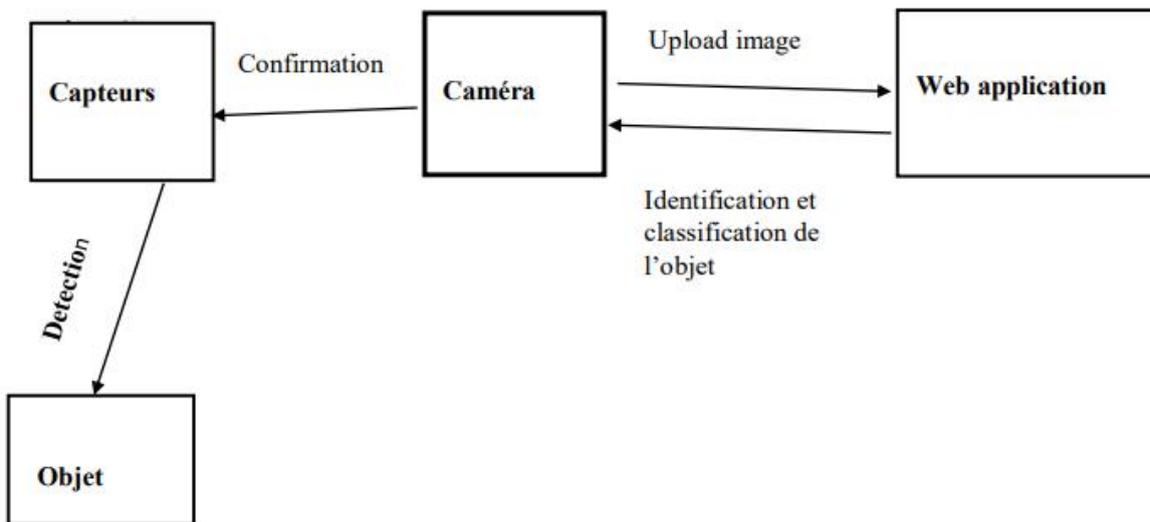


Figure 13: Processus de détection d'objet [F13].

2.9.2.2 Concernant la technologie VoxelNet

VoxelNet est un algorithme de détection d'objets en 3D développé par Apple pour les applications de conduite autonome. Il est capable de reconnaître des objets tels que les voitures, les cyclistes et les piétons. L'algorithme utilise des capteurs lidar pour obtenir des informations de profondeur précises, permettant ainsi de localiser avec précision les objets et de caractériser leur forme. VoxelNet divise l'espace en nuages de points et les regroupe en fonction de leur mouvement pour déterminer le volume et la vitesse des éléments en mouvement. Les données collectées sont ensuite transmises à un réseau de neurones qui classe les objets en différentes catégories telles que les piétons, les cyclistes, les voitures, etc. [11].

Cette approche sophistiquée de reconnaissance d'objets en 3D offre une précision élevée pour les véhicules autonomes.

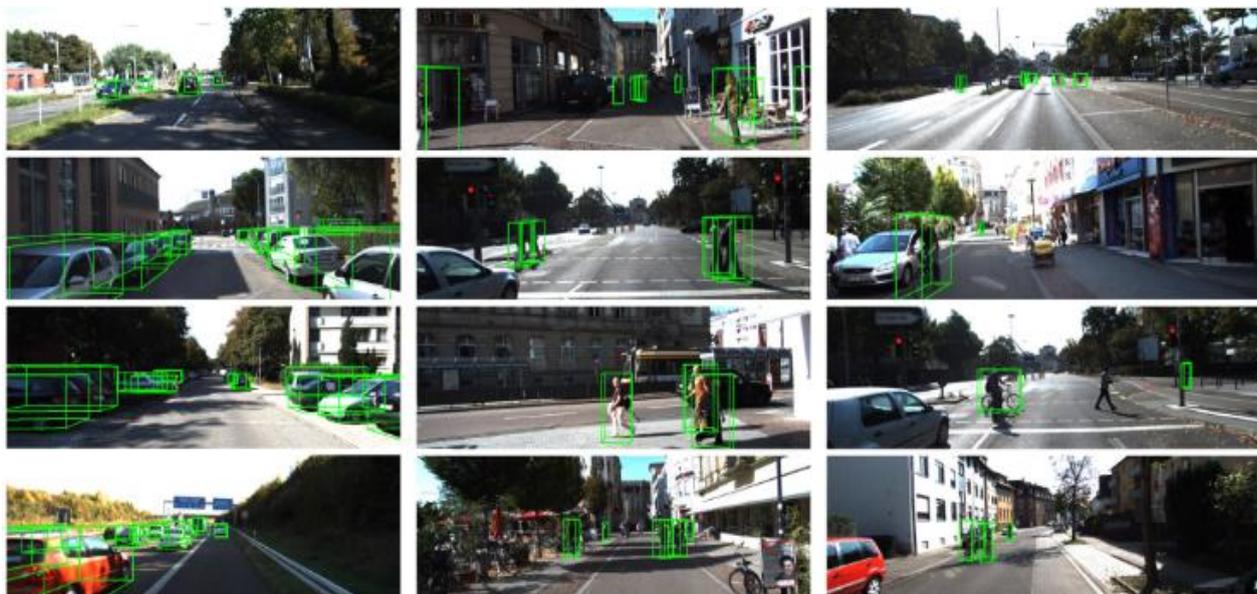


Figure 14: Reconnaissance 3D détecté par Lidar [F14].

2.9.2.3 Les réseaux de neurones convolutifs (CNN ou ConvNET) :

Les CNN, largement utilisés dans les applications embarquées telles que la détection d'objets pour les véhicules autonomes, sont des algorithmes qui exigent des temps de réponse extrêmement rapides pour la classification des objets. Les images capturées par les caméras sont transmises aux CNN, qui apprennent automatiquement les caractéristiques des objets et les classifient. Ces réseaux se composent d'une couche d'entrée, d'une couche de sortie et de plusieurs couches intermédiaires, chacune étant conçue pour identifier différentes caractéristiques d'un objet. Chacune de ces couches effectue des opérations qui modifient les données en vue d'apprendre les caractéristiques spécifiques à ces données. Les trois types de couches les plus couramment rencontrés dans les CNN sont les couches de convolution, les couches d'activation (ou ReLU) et les couches de pooling [34].

2.10 Développements et perspectives des véhicules autonomes

La technologie des véhicules autonomes est en plein essor, et de nombreux industriels et chercheurs travaillent activement à améliorer leur fiabilité. Cela inclut notamment la création de nouveaux capteurs capables de fonctionner dans toutes les situations. Au cours de la dernière décennie, les véhicules autonomes ont été largement testés dans le monde, ouvrant la voie à un avenir prometteur pour cette technologie. En France, par exemple, les essais de navettes autonomes ont démontré leur capacité à s'adapter en temps réel à l'environnement routier en évitant les obstacles et en tenant

compte du trafic. Des actions prioritaires sont prévues dans le cadre de la stratégie nationale pour le développement des véhicules autonomes en France, avec l'introduction prévue de services de transports publics autonomes et de véhicules automatisés. Des tests sont également réalisés dans d'autres pays tels que les États-Unis, l'Allemagne, le Royaume-Uni et la Suède pour évaluer la fiabilité de ces véhicules dans des environnements quotidiens. De nombreux acteurs, dont Google, Apple, Uber et plusieurs constructeurs automobiles, investissent dans cette technologie et cherchent à se positionner comme des leaders dans le domaine des véhicules autonomes [11].

Les véhicules autonomes reposent sur des systèmes de traitement de l'information et de prise de décision. L'intelligence artificielle (IA) joue un rôle central dans la perception et l'analyse de l'environnement du véhicule. L'apprentissage automatique permet aux véhicules d'améliorer leurs performances grâce à l'expérience et aux données. Les réseaux neuronaux sont utilisés pour la reconnaissance d'objets et l'interprétation des informations visuelles et sensorielles. La planification de trajectoire et le contrôle de vitesse sont des systèmes de prise de décision qui permettent aux véhicules de naviguer de manière optimale et sûre.

L'arrivée des véhicules autonomes est prévue à l'échelle mondiale dans les 10 à 20 prochaines années. Certains pays sont en avance dans ce domaine, notamment les États-Unis avec les voitures autonomes de Google et la France avec les navettes autonomes circulant dans les espaces publics. L'objectif principal de cette technologie est d'améliorer la mobilité durable, la sécurité routière et la fluidité du trafic. Les avantages offerts par les véhicules autonomes dépendront de leur statut, qu'il s'agisse de voitures individuelles, de véhicules en autopartage ou de navettes intégrées aux réseaux de transports collectifs [12].

2.11 Conclusion

Pour conclure ce chapitre nous allons dire que les véhicules autonomes sont basés sur des technologies avancées permettant leur fonctionnement sans intervention humaine. Ils offrent de nombreux avantages, tels que la sécurité accrue, la réduction des embouteillages, l'accessibilité pour les personnes à mobilité réduite, la diminution de la consommation d'énergie et des émissions, une meilleure utilisation de l'espace urbain et une productivité accrue des passagers. Cependant, malgré les progrès réalisés, l'adoption généralisée des véhicules autonomes nécessite la résolution de questions réglementaires, de responsabilité, d'éthique et de confiance pour garantir leur sécurité et fiabilité.

Chapitre 3 : La détection d'objets.

3.1 Introduction

La détection d'objets est importante en vision par ordinateur qui vise à identifier et à localiser les objets présents dans une image ou une vidéo en temps réel et cette technologie a de nombreuses applications, telles que la conduite autonome elle joue un rôle essentiel dans de nombreuses applications où la compréhension de l'environnement visuel est nécessaire les besoins de la détection d'objets incluent la précision, la vitesse d'exécution en temps réel, la capacité à traiter les scènes et l'adaptation à différentes catégories d'objets.

L'objectif du travail est de présenter les réseaux de neurones artificiels, les réseaux de neurones convolutif (CNN) et l'architecture de YOLO et son usage pour la détection des obstacles.

3.2 Réseaux de neurones artificiels

Les neurones artificiels sont inspirés par les neurones biologiques, on le définit comme une fonction qui apprend à manipuler des caractéristiques sur lesquelles il va appliquer une fonction, ensuite il va ressortir une nouvelle valeur qui va se propager vers d'autre neurone et il est utilisé pour traiter des informations dans les modèles de machine learning et l'intelligence artificielle [32].

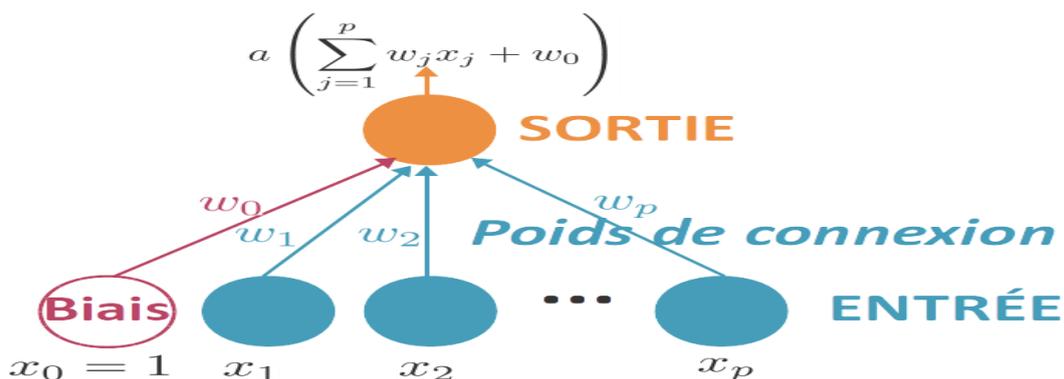


Figure 15: réseaux de neurones artificiels. [F15]

On a les valeurs entrées qui sont les caractéristiques, la fonction de combinaison calcule la somme pondérée des poids, le résultat de cette somme (n) s'appelle le niveau d'activation du neurone, et quand le niveau d'activation atteint ou dépasse le seuil, alors l'argument devient positif (ou nul) sinon, il est négatif.

3.2.1 Les poids (weight)

Les poids dans un réseau de neurones sont comme les coefficients d'une équation mathématique, ils déterminent l'influence de chaque entrée d'un neurone, un poids négatif réduit la valeur de la sortie, tandis qu'un poids positif l'augmente.

Le biais est simplement une valeur constante, ajoutée au produit des entrées et des poids, il est utilisé pour compenser et ajuster le résultat.

Lorsque le réseau neuronal est entraîné sur un ensemble de données, les poids sont initialisés avec des valeurs variables. au fur et à mesure de l'apprentissage, ces poids sont ajustés pour minimiser les erreurs de prédiction. le processus d'optimisation cherche à trouver les poids optimaux qui permettront au réseau de donner les meilleures prédictions.

$$Y = \sum (\text{poids} * \text{entrées}) + \text{bais}$$

3.2.2 La fonction d'activation

Le taux d'erreur du modèle est une fonction discontinue des paramètres de poids, ce qui rend difficile l'ajustement des poids optimaux en minimisant la fonction de perte et pour résoudre ce problème, la fonction d'activation continue est appliquée

Les fonctions d'activation sont des fonctions qui appliquent des transformations, affinent et combinent les poids et les caractéristiques d'entrée, il existe plusieurs fonctions d'activations et la fonction la plus utilisée est généralement l'unité linéaire rectifiée (ReLU) et (Sigmoid) [33].

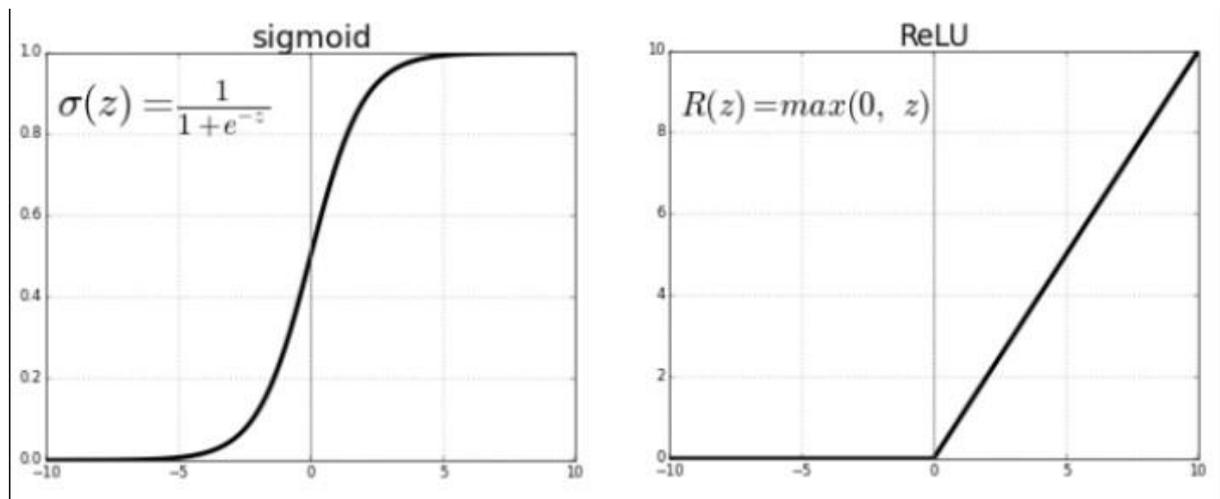


Figure 16: fonction sigmoid et ReLU.[F16]

3.2.3 Sortie

La sortie du neurone est le résultat de la fonction d'activation appliquée à la valeur pondérée. Cette sortie peut être transmise à d'autres neurones pour former des couches de neurones interconnectées dans un réseau de neurones.

Et en reliant plusieurs neurones artificiels ensemble dans des réseaux plus complexes comme les réseaux de neurones profonds, le modèle sera capable de traiter des informations et résoudre des problèmes.

3.3 Réseaux Neuronaux Convolutifs (CNN)

Les réseaux neuronaux convolutifs (CNN), également appelés ConvNets, sont un type de réseaux neuronaux à anticipation bien adaptés aux tâches liées au domaine de la vision par ordinateur, notamment à la reconnaissance d'objets [34].

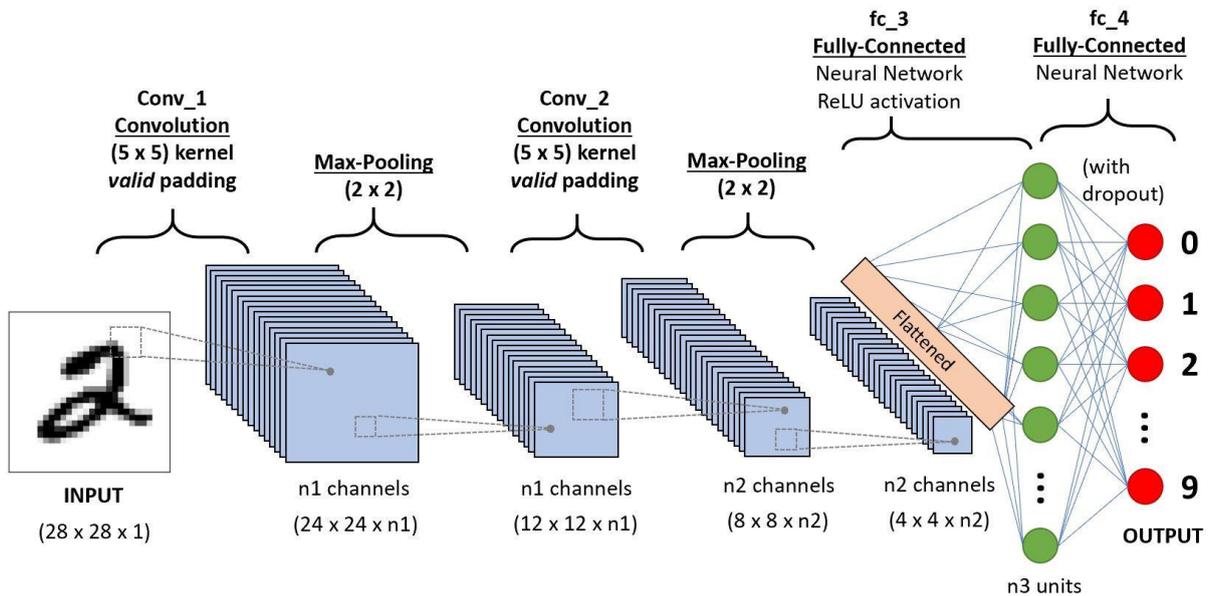


Figure 17: architecture des CNN. [F17]

3.3.1 Couche d'entrée

Elle représente l'image qui sera traitée par le modèle.

3.3.2 Couches de convolution

Souvent appelées couches d'extraction, car elles servent à extraire les caractéristiques de l'image de taille $[I \times J]$. D'abord l'image est connectée à cette couche pour être convoluée par un filtre de taille $[N \times M]$ (inférieur de la taille de l'image) servant à détecter les formes, les bords et les textures. Résultant une carte d'activation de même taille que l'image utilisée. Le filtre parcourt l'image jusqu'à ce qui atteigne la totalité de celle-ci. [33].

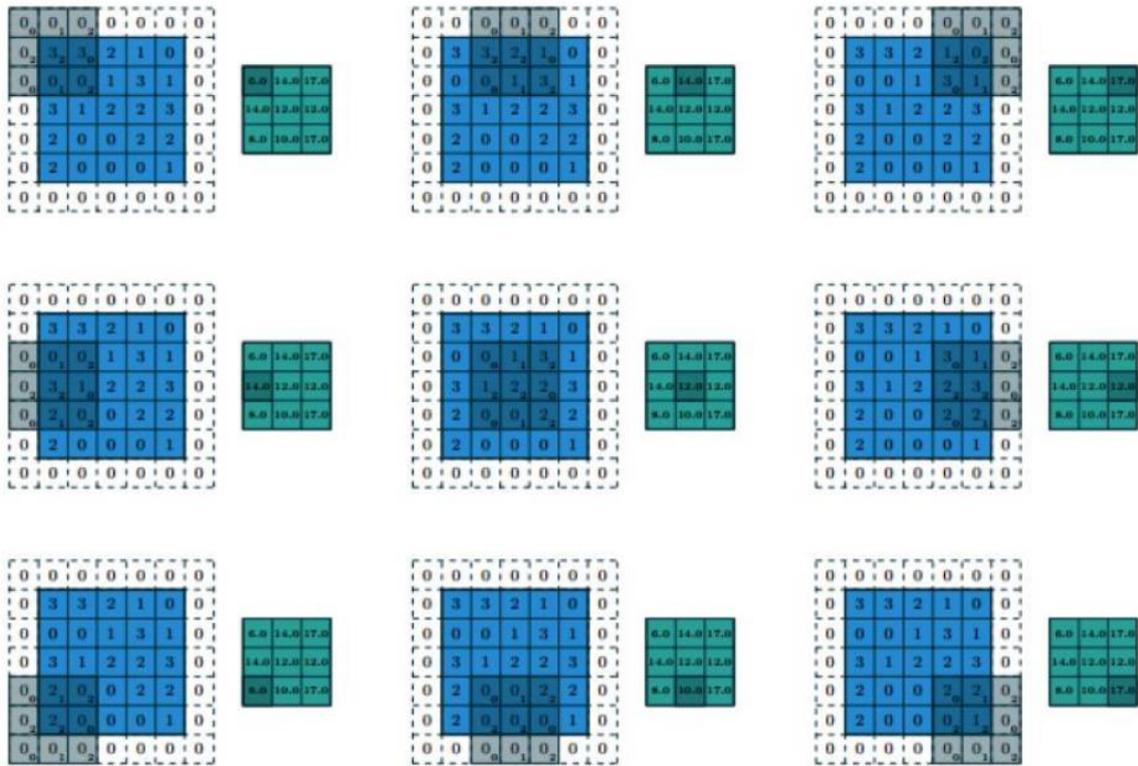


Figure 18: la couche de convolution. [F18]

La couche convolution contient également l'activation ReLU pour que toutes les valeurs négatives soient mises à zéro.

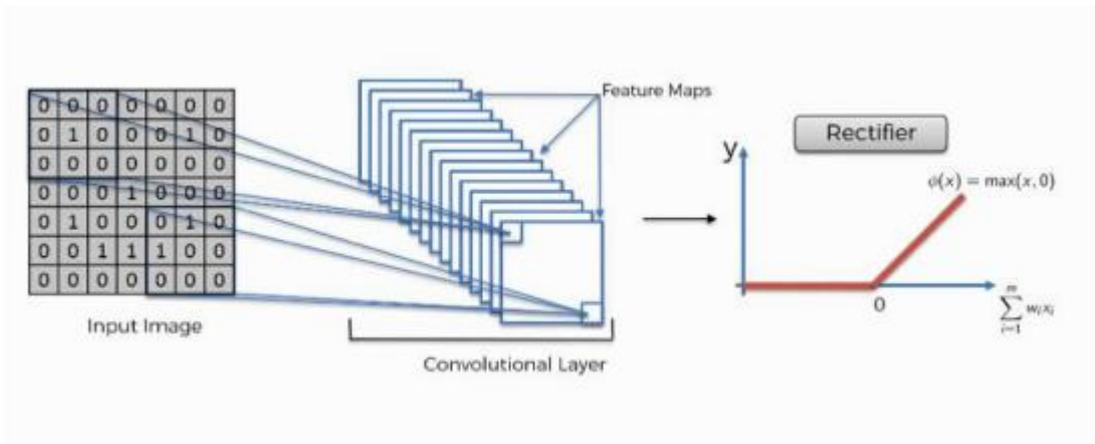


Figure 19: principe de la fonction Relu. [F19]

3.3.3 Couches de pooling

Elles réduisent la dimension spatiale des caractéristiques qui ont été extrait par les couches de convolution elle attache les valeurs voisines avec des opération telles que le max pooling ou le average pooling, cela permet de réduire le nombre de paramètre et amélioré le résultat, elle est généralement utilisée après deux couches de convolutions.

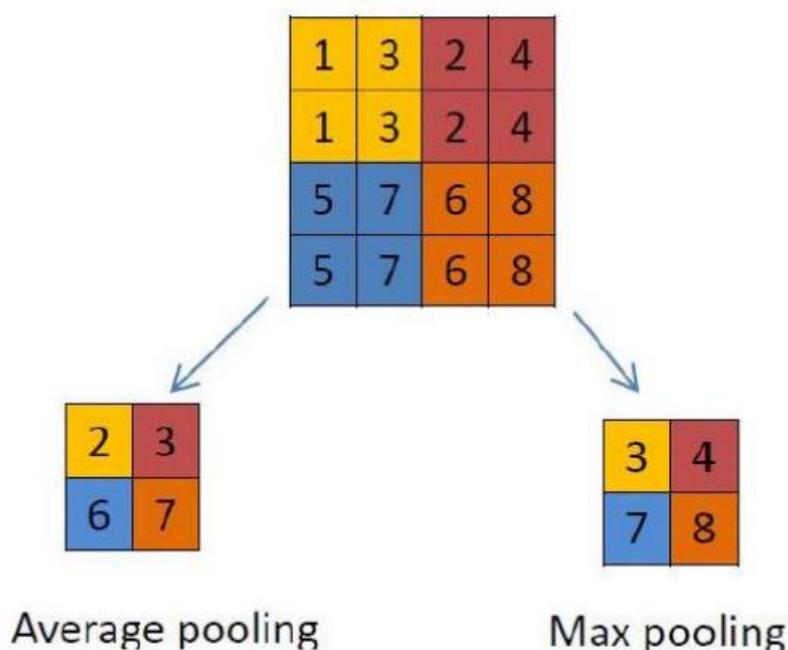


Figure 20: exemple de couche pooling (average et max pooling) [F20].

3.3.4 Couche entièrement connectée (fully connected)

Appelée aussi couche de produit matriciel, après plusieurs couches de convolution et de pooling les caractéristiques sont compressées et passent par des couches entièrement connectées, elles sont similaires aux couches de neurones artificielles, elles prennent en entrée les caractéristiques extraites et les transforment pour produire les prédictions finales. Elles impliquent des poids et des neurones et les connectent les neurones d'une couche à une autre, elle est utilisée pour classer les images entre différentes catégories [30].

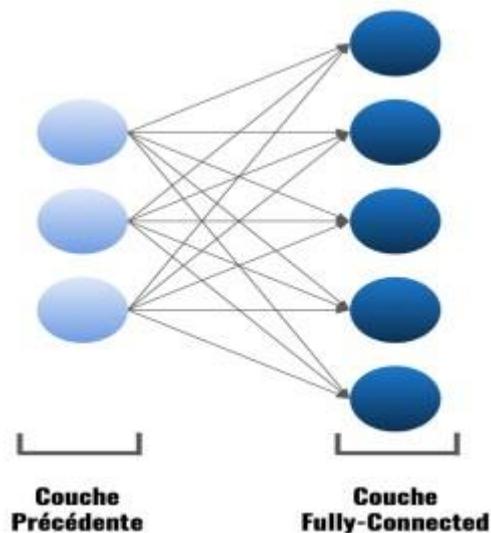


Figure 21: couche entièrement connectée [F21].

✓ Couches de softmax

Cette couche est précédée toujours par une couche entièrement connectée, son rôle est d'attribuer des probabilités à chaque classe du problème étudié en fonction des données fournis par les couches supérieures du réseau.

✓ Couche de sorties

La couche de sortie, c'est la dernière couche du réseau qui contient les neurones qui identifient les classes du modèle, donc le nombre de neurones à cette couche dépend du nombre de classes [31].

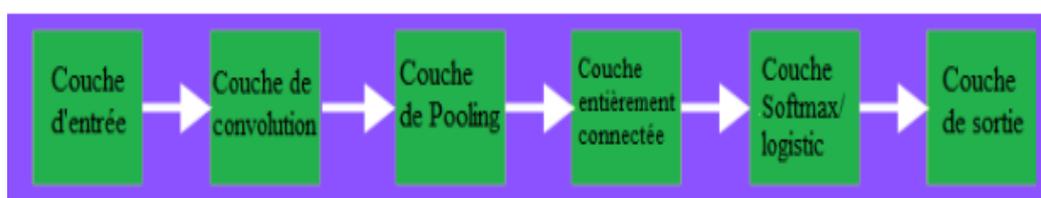


Figure 22: les couches de CNN [F22].

Un exemple de l'architecture du CNN

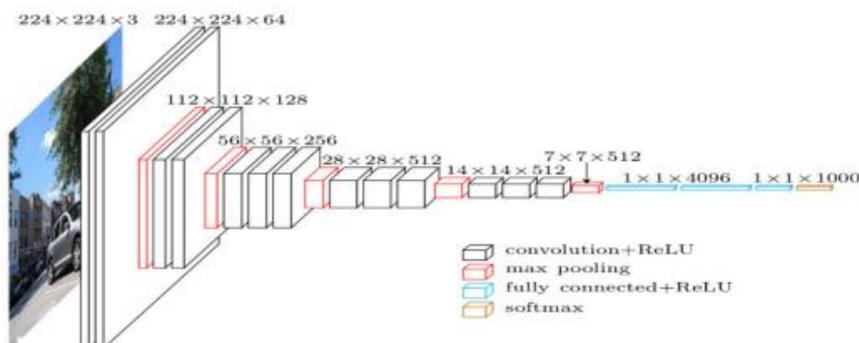


Figure 23: exemple de l'architecture CNN [F23].

3.4 Conception de réseaux de neurones à convolution

L'apprentissage profond est le fruit de l'évolution des capacités de traitement des machines actuelles (cartes graphiques très performantes et disque de stockage) ainsi que de la disponibilité de bases de données labellisées très larges. Malgré ça, la conception d'un réseau de neurones à convolution n'est pas une tâche simple, plusieurs contraintes se présentent :

- L'architecture du réseau : aucune règle n'existe pour concevoir un réseau CNN (Nombre de couches, nombre de filtres de convolution, ..., etc.).
- Le temps d'apprentissage : qui est très grand dans le cas des réseaux CNN larges, tel que le cas de traitement vidéo (l'apprentissage peut prendre des semaines).
- Un temps de conception très grand à cause du temps d'apprentissage ainsi que des multitudes de simulations à réaliser pour trouver la bonne architecture.
- Le coût : la nécessité de machines de calculs très performantes équipées d'une ou plusieurs cartes graphiques dont le prix peut atteindre quelques milliers de dollars, ainsi que des disques de stockage volumineux pour stocker des bases de données ayant une dimension qui va jusqu'à 10 To.

3.4.1 Base de données utilisées pour l'apprentissage des réseaux de neurones CNN

Comme précisé précédemment, un modèle est constitué de l'architecture et des poids qui sont les résultats d'apprentissage du réseau sur une base de données, il est donc primordial de bien connaître cette base de données, parce que les performances du modèle dépendent directement de cette dernière, par exemple un modèle qui a été entraîné sur la base de données ImageNet de Google qui contient plus de 15 millions d'images labellisées en 22000 catégories donne de meilleurs résultats que lors de l'utilisation d'autres bases de données moins large tel que COCO qui contient 80000

images pour l'apprentissage et 40000 pour la validation, catégorisées en 80 classes. D'autres bases de données sont adaptées à des problèmes précis comme la segmentation, tel que la base de données Pascal database [30].

Il y'a plusieurs domaines qui utilisent le modèle CNN pour résoudre certains problèmes et parmi ces domaines, on a la détection d'objets, voici un exemple des modèles de détection d'objets qui utilisent le CNN :

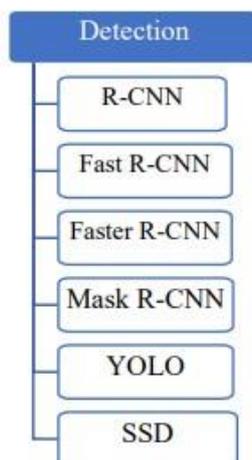


Figure 24: exemple de modèles de détection d'objets [F24].

Le modèle qui nous intéresse le plus dans ce travail, c'est le modèle YOLO, plus précisément YOLOV3.

3.5 La présentation du modèle YOLO

YOLO (You Only Look Once), "vous ne regardez qu'une seule fois", est un modèle de détection d'objets en temps réel basé sur un réseau de neurones convolutifs (CNN, il est l'un des algorithmes populaires de détection d'objets et se distingue par sa capacité à prédire simultanément toutes les boîtes englobantes et les classes pour l'ensemble de l'image. Contrairement à d'autres méthodes telles que les R-CNN qui nécessitent plusieurs passages sur l'image, YOLO applique directement le même réseau CNN à l'ensemble de l'image en une seule fois. L'architecture de YOLO divise l'image en plusieurs régions et prédit les classes et les boîtes englobantes pour chaque région. Les régions ayant des probabilités élevées sont alors sélectionnées comme appartenant à une certaine classe. Cette approche permet une détection rapide des objets, avec des performances 1000 fois plus rapides que les R-CNN et 100 fois plus rapides que les fast R-CNN. En utilisant l'image entière pour prédire les boîtes englobantes et les classes, YOLO adopte une approche globale qui prend en compte tous les objets présents dans l'image. Cette conception permet un apprentissage de bout en bout et offre des performances en temps réel avec une précision moyenne élevée. [27] [29].

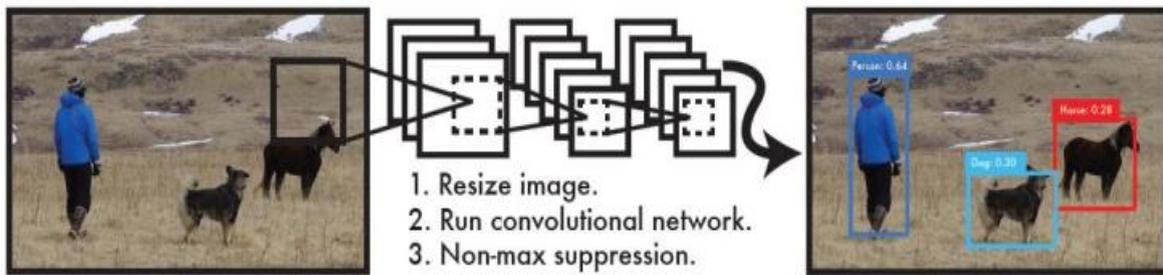


Figure 25: principe du modèle YOLO.[25].

Les sorties de l'architecture YOLO sont les coordonnées des zones englobantes (bounding boxes) et les probabilités des classes de chaque zone.

3.5.1 L'architecture du modèle YOLO

L'architecture du YOLO est composée de plusieurs couches de convolutions suivies des couches entièrement connectées, le principe du modèle est basé sur l'utilisation d'une succession de couches de convolution avec différentes tailles et nombreux filtres, elle permet de diviser l'image en plusieurs zones qui englobent les différents objets ou portions d'objets pour extraire les caractéristiques des images, l'application d'un seuillage des probabilités de chaque classe dans chaque zone permet de conserver uniquement les zones englobantes représentatives qui limitent les objets [27] [28].

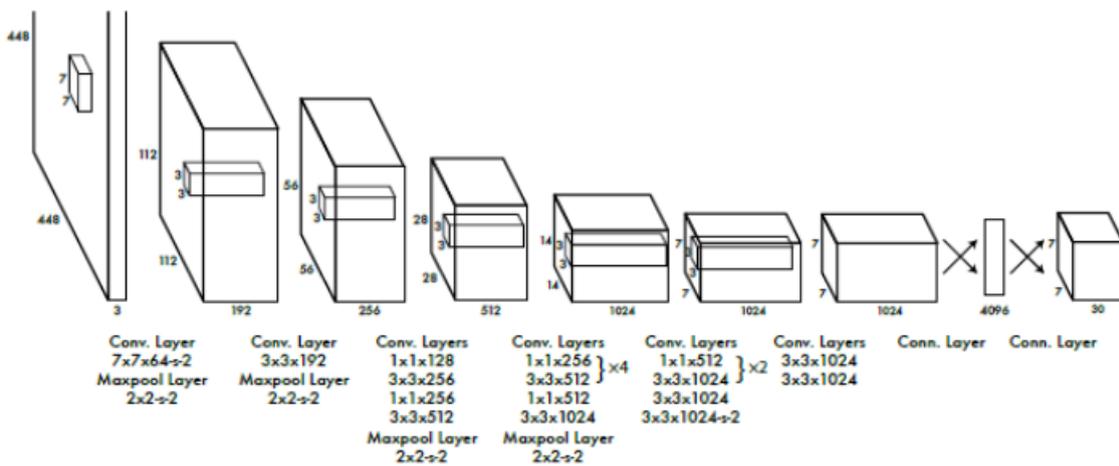


Figure 26: Architecture du modèle YOLO. [F26]

Voici un exemple de fonctionnement de l'architecture YOLO :

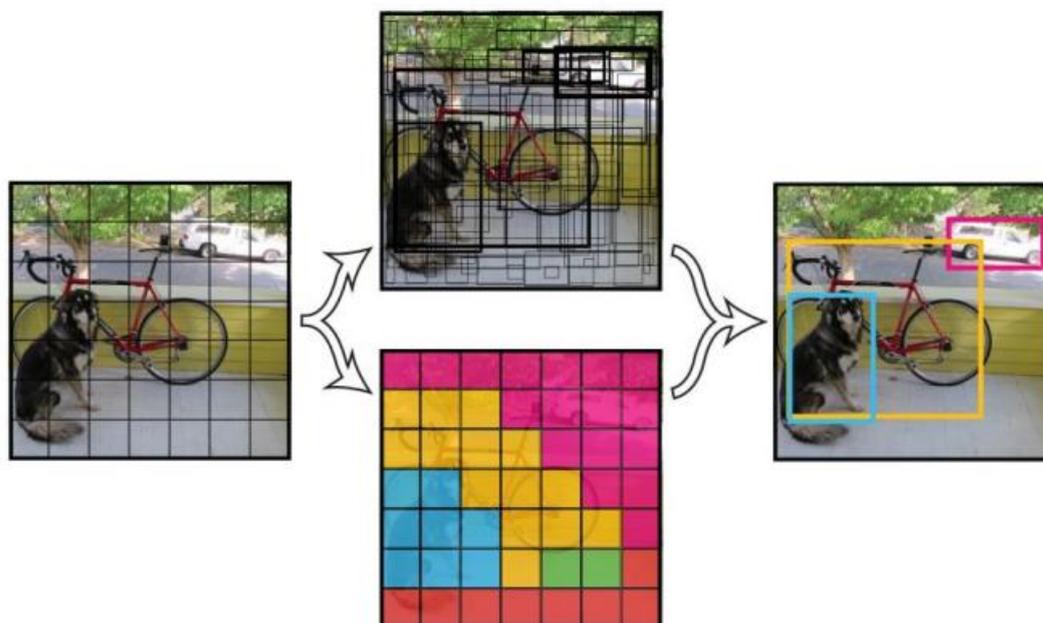


Figure 27: Principe de fonctionnement de l'architecture YOLO [F27].

Ce réseau comporte 24 couches convolutives suivies de 2 couches entièrement connectées

Plusieurs versions du YOLO ont été proposées à ce jour, on trouve : YOLO V1, YOLO V2, YOLO V3, YOLO V4.... Jusqu'à YOLO V8 qui est développé récemment. Chaque version a pour but d'améliorer les performances du modèle en matière de rapidité et taux de classification. Dans ce document, nous allons travailler sur la version « 3 » du modèle YOLO. Tous les modèles de base de YOLO ont été entraînés sur la base de données de COCO, mais il existe dans la littérature d'autres modèles entraînés sur d'autres bases de données telles que ImageNet de Google.

3.5.2 YOLO V3

YOLOV3 (You Only Look Once, Version 3) est un algorithme de détection d'objets en temps réel qui identifie des objets spécifiques dans des vidéos, des flux en direct ou des images. Il s'agit d'un réseau de neurones convolutifs (CNN) intelligent pour la détection d'objets utilisé en temps réel, développé par Joseph Redmon, Ali Farhadi.

Voici une figure qui représente l'architecture du modèle YOLOV3 [17] [18] [19].

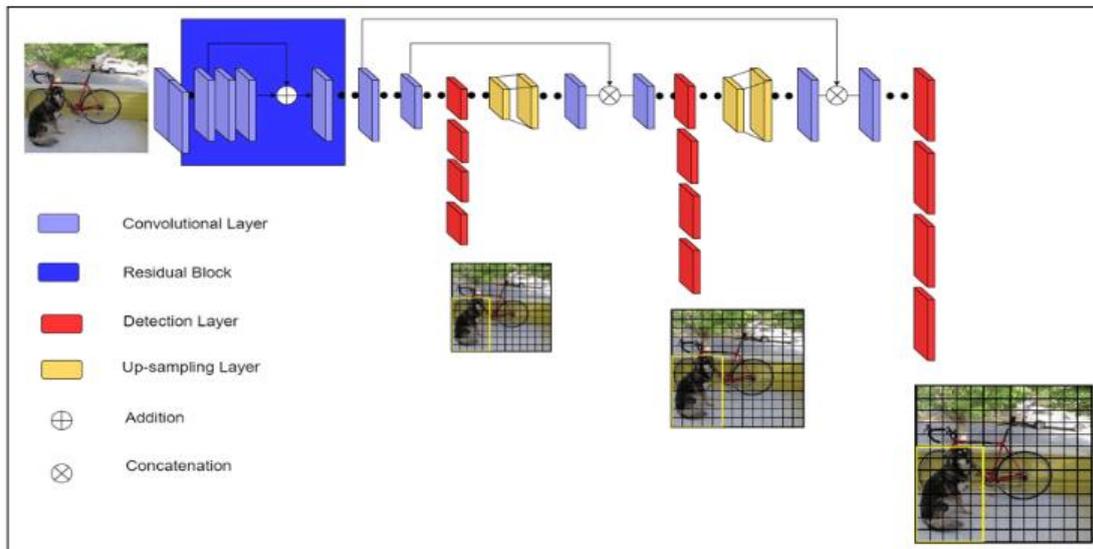


Figure 28: architecture du modèle YOLOV3 [F28].

3.5.3 Intégration du modèle YOLO V3 dans le véhicule autonome

Intégrer le modèle YOLO sur un véhicule autonome requiert une combinaison de compétences en matière de matériel et de logiciel pour permettre une détection d'objets en temps réel et une prise de décision basée sur ces détections.

Sur le plan matériel, il est essentiel d'avoir un système de calcul suffisamment puissant pour exécuter le modèle YOLO avec une faible latence. Cela peut impliquer l'utilisation de processeurs multicœurs ou de processeurs graphiques (GPU) capables de gérer efficacement les calculs complexes nécessaires à la détection d'objets en temps réel. De plus, des capteurs tels que des caméras, des lidars et des radars sont nécessaires pour fournir les données d'entrée au modèle YOLO.

En ce qui concerne le logiciel, il est primordial d'intégrer le modèle YOLO dans le système de traitement du véhicule autonome. Cela implique d'adapter le modèle YOLO aux spécifications du véhicule et aux formats de données des capteurs utilisés. Il est également crucial de synchroniser les données d'entrée avec les autres composants du système, tels que les systèmes de localisation, de cartographie et de planification.

Une fois que le modèle YOLO est intégré, il peut être utilisé pour effectuer une détection d'objets en temps réel à partir des données collectées par les capteurs du véhicule. Les résultats de cette détection sont ensuite utilisés pour prendre des décisions en temps réel, comme l'évitement d'obstacles, la reconnaissance de piétons et la détection des panneaux de signalisation. [15] [16] [17].

Il est important de noter que l'intégration du modèle YOLO sur un véhicule autonome ne se limite pas seulement à la détection d'objets. Elle nécessite également la mise en place

d'autres composants matériels et logiciels pour permettre une conduite autonome complète et sûre.

Voici un exemple d'équipement qu'on peut utiliser pour intégrer le modèle YOLO sur le véhicule autonome.

3.5.4 L'intégration de YOLO et la puissance de la technologie 5G pour une conduite autonome avancée

L'intégration du modèle YOLO, combinée à la puissance de la technologie 5G, présente des avantages significatifs pour les applications de conduite autonome. La technologie 5G offre des débits de données élevés, une faible latence et une capacité de connexion massive, qui renforcent les performances et les fonctionnalités du modèle YOLO sur le véhicule autonome [25] [26].

3.6 Conclusion

Ce chapitre présente l'architecture YOLO pour la détection d'objets en temps réel. Il explique les réseaux de neurones artificiels et les réseaux neuronaux convolutifs. YOLOV3 est introduit comme une version améliorée de YOLO, offrant une détection rapide et précise. L'intégration de YOLOV3 dans les véhicules autonomes est abordée. Ce chapitre souligne l'importance de la précision, de la rapidité et de l'intégration pour la détection d'objets en temps réel.

Chapitre 4 : Simulation et résultats.

4.1 Introduction

Ce chapitre aborde la création de la base de données, élément crucial de notre projet de simulation. Nous avons parcouru Bejaïa pour collecter des photos et vidéos des routes, intersections, feux de signalisation, panneaux, véhicules et personnes. La détection de 10 objets constitue notre objectif. Nous avons utilisé le site en ligne <https://www.cvat.ai/> pour la labellisation des images. Ensuite, nous avons divisé la base de données en deux parties (test et train). Les formats XML des étiquettes ont été convertis en format YOLO. Le fichier `configs.py` a été modifié pour l'entraînement. Enfin, nous avons lancé l'entraînement du modèle et obtenu des résultats montrant la détection des différentes classes.

4.2 Logiciels utilisés :

- **Python :**

Python est un langage de programmation populaire, polyvalent et convivial. Il est largement utilisé dans le domaine de l'intelligence artificielle et du développement de logiciels en raison de sa syntaxe claire et expressive. Python offre une vaste gamme de bibliothèques et de frameworks d'IA, tels que TensorFlow, PyTorch et Open-cv, qui facilitent la mise en œuvre de modèles d'apprentissage automatique et de réseaux de neurones.

- **Anaconda :**

Anaconda est une distribution de Python très appréciée pour le développement scientifique et l'IA. Elle est livrée avec un gestionnaire de packages conçu spécifiquement pour faciliter l'installation et la gestion des bibliothèques populaires utilisées dans le domaine de l'IA, telles que NumPy, pandas et Matplotlib. En plus de cela, Anaconda fournit également un environnement de développement virtuel appelé "conda" qui permet de créer des environnements Python isolés, facilitant la gestion des dépendances entre les projets. L'utilisation d'Anaconda simplifie le processus de configuration d'un environnement de développement complet pour le développement de logiciels d'IA.

- **VSCoDe (Visual Studio Code) :**

VSCoDe est un éditeur de code source léger et puissant développé par Microsoft. Il est devenu l'un des choix les plus populaires pour les développeurs Python en raison de ses fonctionnalités avancées, de son extensibilité et de son intégration avec de nombreux outils et langages. VSCoDe offre des fonctionnalités pratiques telles que la complétion automatique, le débogage, la gestion des environnements virtuels et la prise en charge de Git, ce qui facilite le développement de projets Python, y compris ceux liés à l'intelligence artificielle.

- Package utilisés :

Tableau 2: Les Package utilisés.

NumPy	Permet de manipuler et effectuer des opérations sur des tableaux numériques.
SciPy	Offre des fonctionnalités avancées pour le calcul scientifique et l'analyse de données.
Wget	Facilite le téléchargement de fichiers à partir d'Internet.
Seaborn	Permet de créer des graphiques attrayants pour la visualisation de données statistiques.
TensorFlow	Une bibliothèque d'apprentissage automatique puissante pour la création et l'entraînement de modèles.
OpenCV-Python	Permet de manipuler et traiter des images et des vidéos
TQDM	Ajoute des barres de progression dans les boucles itératives pour suivre l'avancement.
Pandas	Facilite la manipulation et l'analyse de données tabulaires
AWS CLI	Fournit une interface en ligne de commande pour interagir avec les services AWS.
Urllib3	Permet d'effectuer des requêtes HTTP pour récupérer des données à partir de ressources en ligne.
MSS	Capture des captures d'écran à partir d'un écran d'ordinateur.

Avant d'installer les packages il faut créer un environnement de travail sur Python, pour la création de l'environnement dans notre exemple on a travaillé avec Conda on utilise le code :

```
conda create --name nom_de_lenvironnement .
```

Après on active l'environnement avec le code : `conda activate nom_de_lenvironnement`

Pour l'installation de packages, on utilise le code : `pip install nom_du_package`

Quand l'environnement est prêt et les packages sont installés on commence notre travail.

4.3 Schéma de conception

Notre système se compose de 3 modules principales :

- Prétraitement de données
- Apprentissage de model yolov3 sur nos données choisies
- Test et résultat

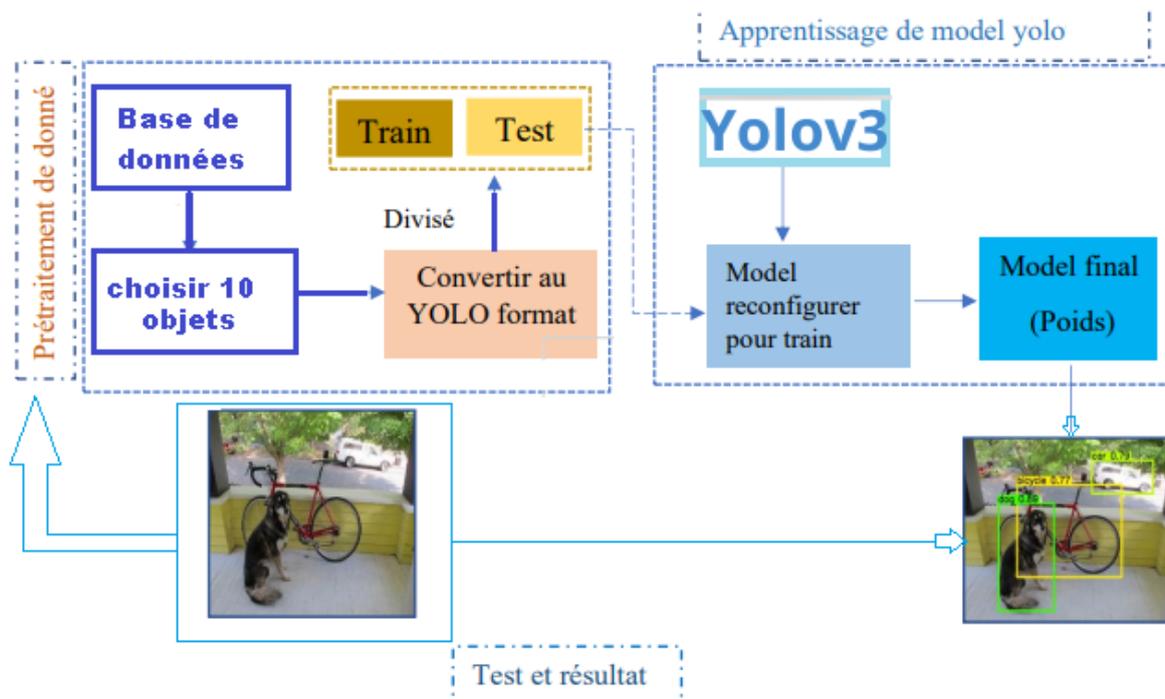


Figure 29 : schéma test et résultat

4.4 Création du projet

Avant de commencer à créer notre jeu de données, nous allons cloner le projet yolov3 suivant : <https://github.com/pythonlessons/TensorFlow-2.x-YOLOv3>.

Une fois le projet a été cloné, on va créer notre base de données constituée d'images de notre base de données, dont 80% seront dédiées à l'entraînement et les 20 qui restent pour le test du modèle.

4.5 La base de données

C'est la partie la plus importante du projet, pour avoir nos résultats dans la simulation, donc il faut créer une base de données personnelle et pour cela nous fait le tour de toute la ville de Bejaïa et prenant en photos et vidéos les différentes routes et intersection, feu (verts, rouge et orange) et panneaux de signalisations (stop, passage piéton), êtres humains, véhicules (bus, camions, voitures et moto). Nos résultats sont basés sur la détection de 10 objets. On a pris environ 500 photos de la ville de Bejaia.

Et pour parvenir à la détection des objets on procède à l'application des étapes suivantes :

4.6 Labellisation

Pour labelliser les images on a utilisé un site en ligne <https://www.cvat.ai/>
D'abord on crée un nouveau projet sur le site :
On donne un nom au projet et puis on ajoute les labels qu'on veut utiliser (dans notre exemple on a utilisé 10 objets) (voiture, moto, bus, personne, feux rouge, feux vert, feux orange, stop, et passage piéton).

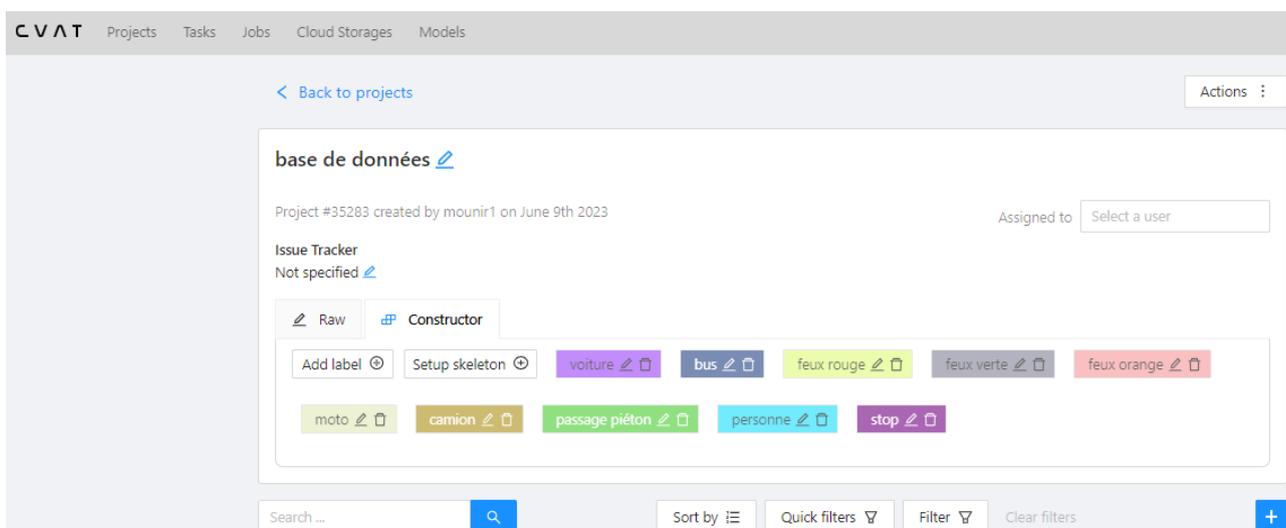


Figure 30: création du projet et ajouts des labels

On ouvre le projet et après on va sur Task :

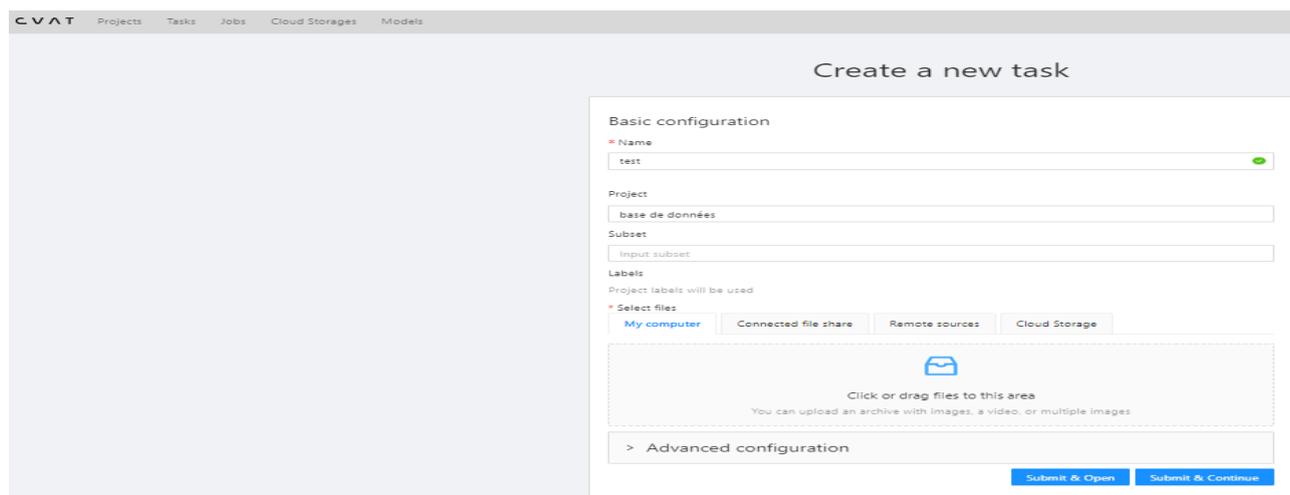


Figure 31: importation des images qu'on veut labéliser

On importe les images dans l'environnement de cet outil et on ouvre avec Submit & Open
Ensuite en cliquant sur Draw new rectangle :

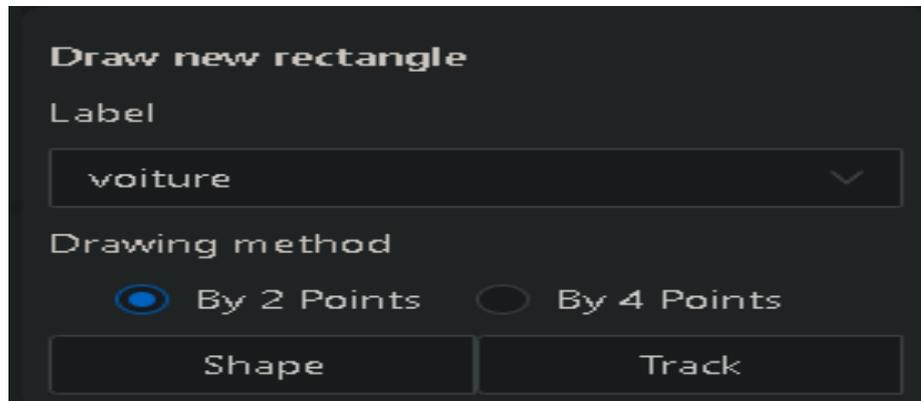


Figure 32: dessiner les rectangles sur les objets

Pour tracer des rectangles autour des régions d'intérêts qu'on souhaite prédire avec le modèle.

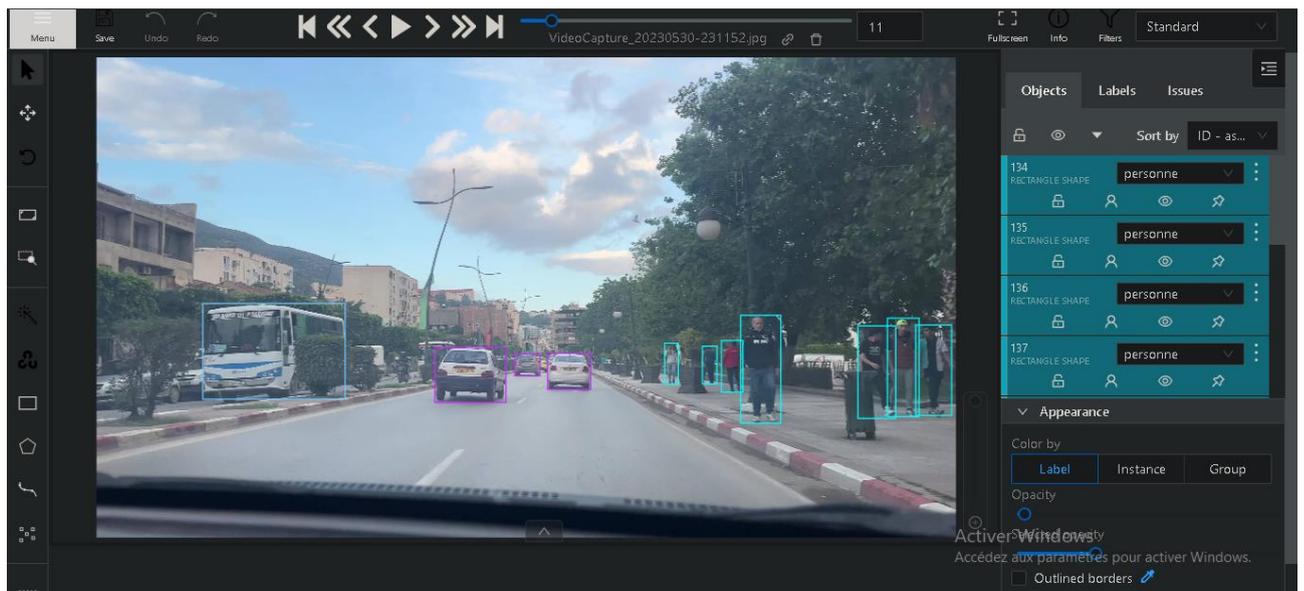


Figure 33: exemple d'un label crée à partir d'une image de la base de données.

Enfin, on sauvegarde notre travail pour les images traitées, le résultat généré est sous format XML.

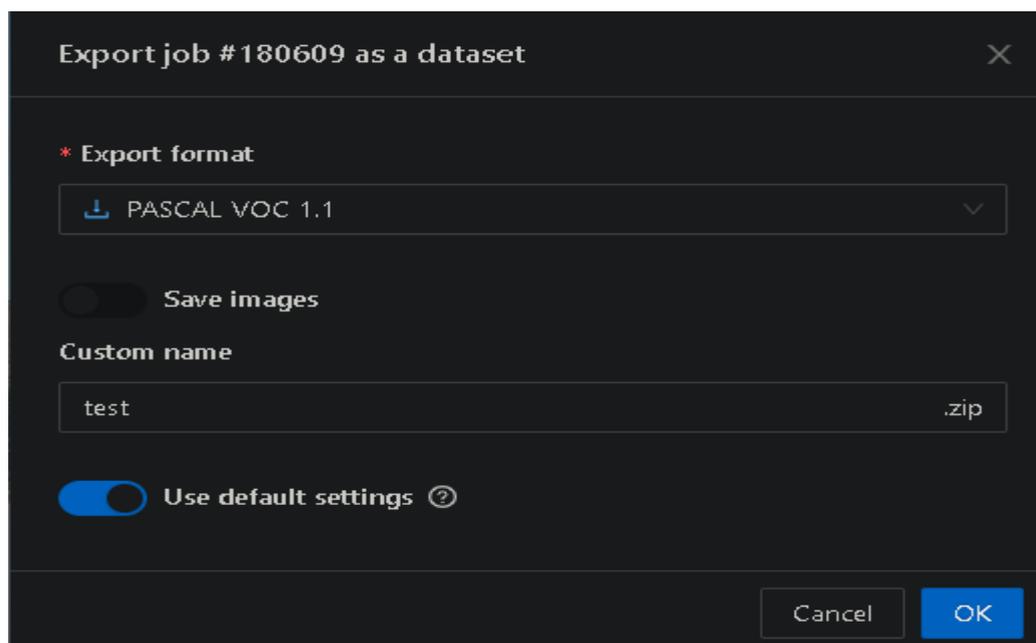


Figure 34: exportation des résultats XML

On divise la base de données (images et leurs labels) en deux parties

Une partie (test) qui contient 20% de la base de données et une autre partie (train) qui contient 80% de la base de données.

4.7 Convertir les formats XML en format YOLO

Nous devons maintenant convertir `.xml` les étiquettes au format de formation YOLO approprié. Pour le faire il faut exécuter le script `XML_to_YOLOv3.py`. Au début du code, nous devons rajouter les lignes de code suivantes :

- `data_dir` est l'emplacement de notre dossier d'images, nous le définissons sur `/custom_dataset/`;
- `Dataset_names_path` est un emplacement où le chemin des classes générées sera enregistré, nous le définissons sur `model_data/Dataset_names.txt`;
- `Dataset_train` est un emplacement où le chemin d'annotation de train généré sera enregistré, nous le définissons sur `model_data/Dataset_train.txt`;
- `Dataset_test` est un emplacement où le chemin d'annotation de test généré sera enregistré, nous le définissons sur `model_data/Dataset_test.txt`;
- la dernière ligne est `is_subfolder`, cela est changé lorsque nous n'avons pas de sous-dossiers `train` ou `test` de chemins. Dans un didacticiel précédent, nous avons utilisé des sous-dossiers lors du téléchargement de l'ensemble de données personnalisé. Maintenant, nous n'avons plus de sous-dossiers, nous l'avons donc défini sur `is_subfolder = False`.

- Voici à quoi cela devrait ressembler entièrement changé :

```
data_dir = '/custom_dataset/'
Dataset_names_path = "model_data/Dataset_names.txt"
Dataset_train = "model_data/Dataset_train.txt"
Dataset_test = "model_data/Dataset_test.txt"
is_subfolder = False
```

Figure 35: Modifications de lignes de code

4.8 Modifier le fichier configs.py de l'entraînement

Lorsque nous avons préparé notre jeu de données personnalisé et déjà généré des annotations et des fichiers de classe, nous devons modifier les configurations selon nos besoins. Dans le dossier des outils, vous pouvez voir le `configs.py` fichier ; ouvrez-le. Nous devons changer les lignes suivantes :

- TRAIN_CLASSES à `"/model_data/Dataset_names.txt"`;
- TRAIN_ANNOT_PATH vers `"/model_data/Dataset_train.txt"`;
- TEST_ANNOT_PATH vers `"/model_data/Dataset_test.txt"`.

Assurez-vous que `TRAIN_DATA_AUG` c'est vrai et `TRAIN_TRANSFER` c'est aussi vrai.

L'époque d'entraînement et le taux d'apprentissage changent en fonction de vos besoins pour votre ensemble de données personnalisé.

4.9 Lancer l'entraînement du modèle

Cette étape est l'une des plus simples. Effectuez les étapes suivantes :

- Allez dans le dossier principal ;
- Borne ouverte (terminal) ;
- Écrire le code : `python train.py`
- On lance l'entraînement.

4.10 Evaluation de l'entraînement

Voici les résultats obtenue lors de l'entraînement :

Tableau 3: résultat des Précision moyenne par classe.

La classe	Percentage
Voiture	76.476%
Camion	63.636%
Bus	49.444%
Moto	92.347%
Passage piéton	8.333%
Stop	100.000%
Feux rouge	24.856%
Feux vert	87.895%
Feux orange	15.385%
Homme	77.764%
mAP	60.614 %

AP per class (Précision moyenne par classe)

$$AP = (P(1) * R(1) + P(2) * R(2) + \dots + P(n) * R(n)) / n$$

mAP of all classes

$$MAP = (AP(1) + AP(2) + \dots + AP(n)) / n$$

- AP est la précision moyenne,
- P(i) est la précision pour la classe (i),
- n est le nombre totale de classe .
- R rappelle pour la classe

4.11 Résultat

Pour détecter les obstacles sur les photos après l'entraînement on lance le code suivant :

```
python detection_custom.py
```

Sur le fichier : detection_custom.py on lui donne l'emplacement de l'image et l'emplacement de la sortie ou on veut trouver l'image détectée.

```
image_path='C:/Users/Moi/Desktop/YOLO_TEST/TensorFlow-2.x-YOLOv3_v1/IMAGES/15.jpg'  
output_path='C:/Users/Moi/Desktop/YOLO_TEST/TensorFlow-2.x-YOLOv3_v1/IMAGES/detect15.jpg'
```

A chaque fois on répète ça sur toutes les images qu'on veut détecter.

Voici les resultst concernant notre simulation a propos de la detection des classes utilisées, vu qu'on a dix classes, donc on va monter un exemple sur chacune.

Vehiclues: Ce titre concerne tout type de vehicule de la classe ,c'est à dire voitures,bus, camions et motos. Chaque type sera defni en description de l'image

Détection d'un Bus:

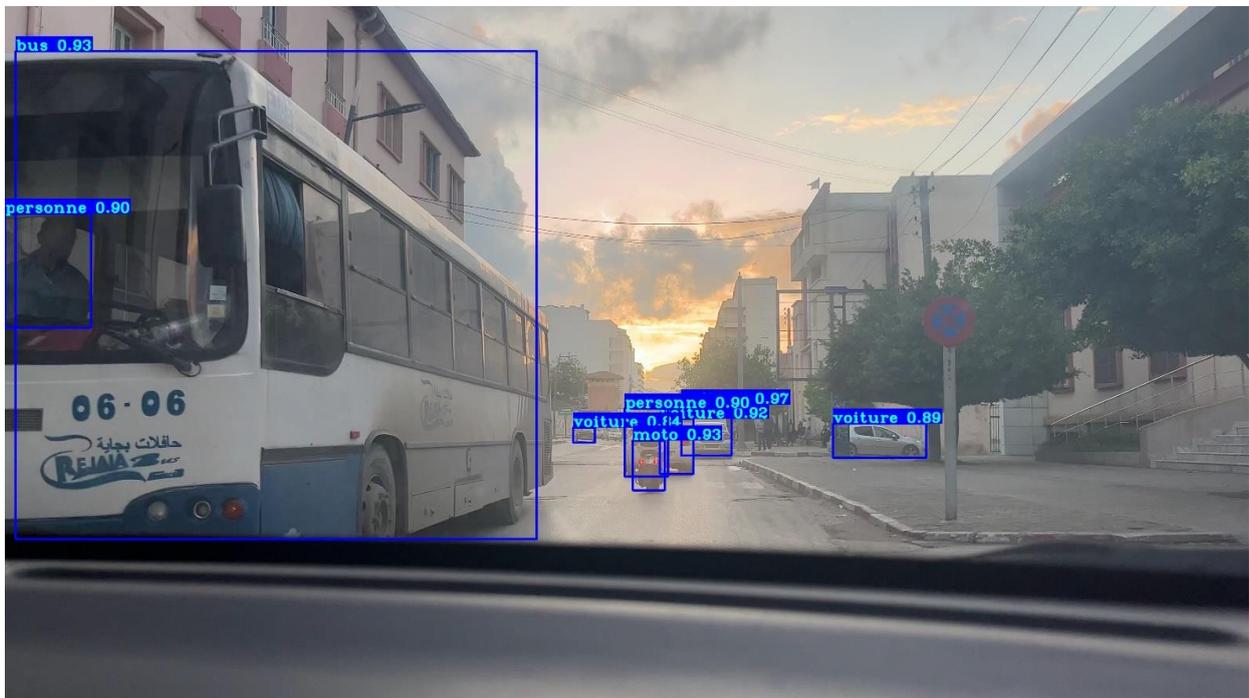


Figure 36: L'image représente principalement la détection d'un bus en premier plan, ainsi que des voitures et une moto en arrière-plan.

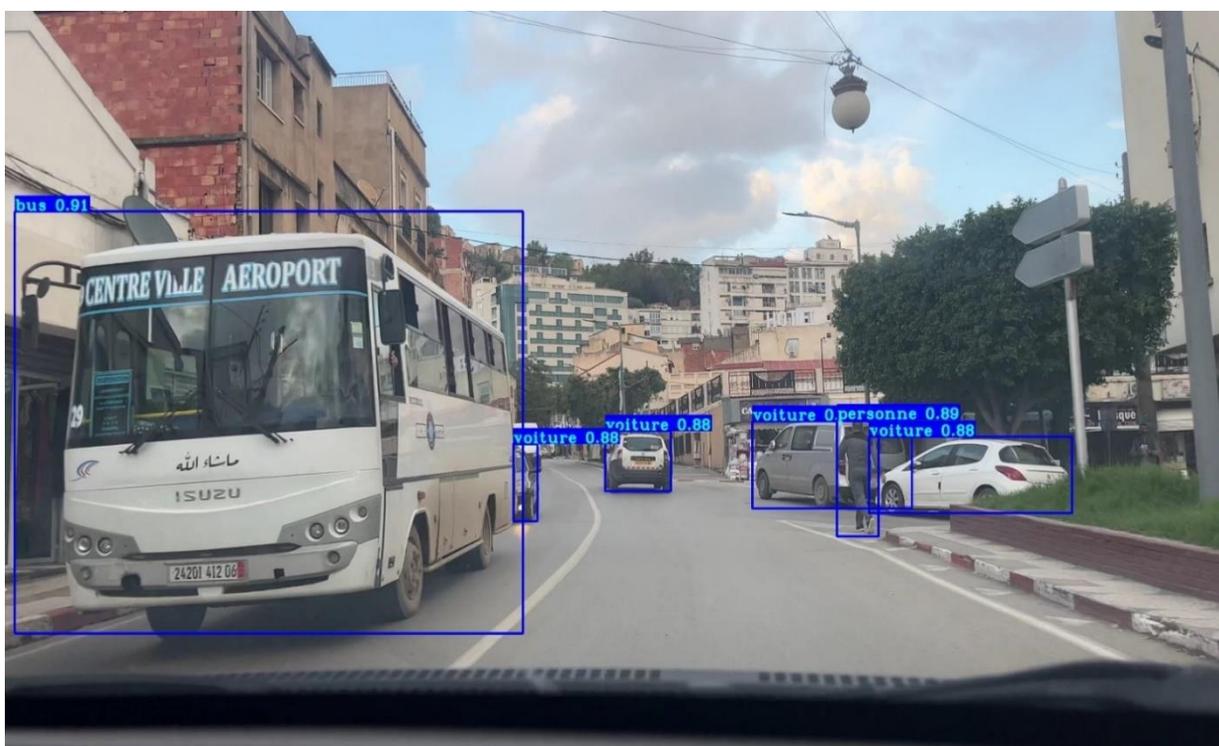


Figure 37: L'image représente la même situation que celle d'avant.

Détection d'une Motos : Cette classe est dédiée au motos.

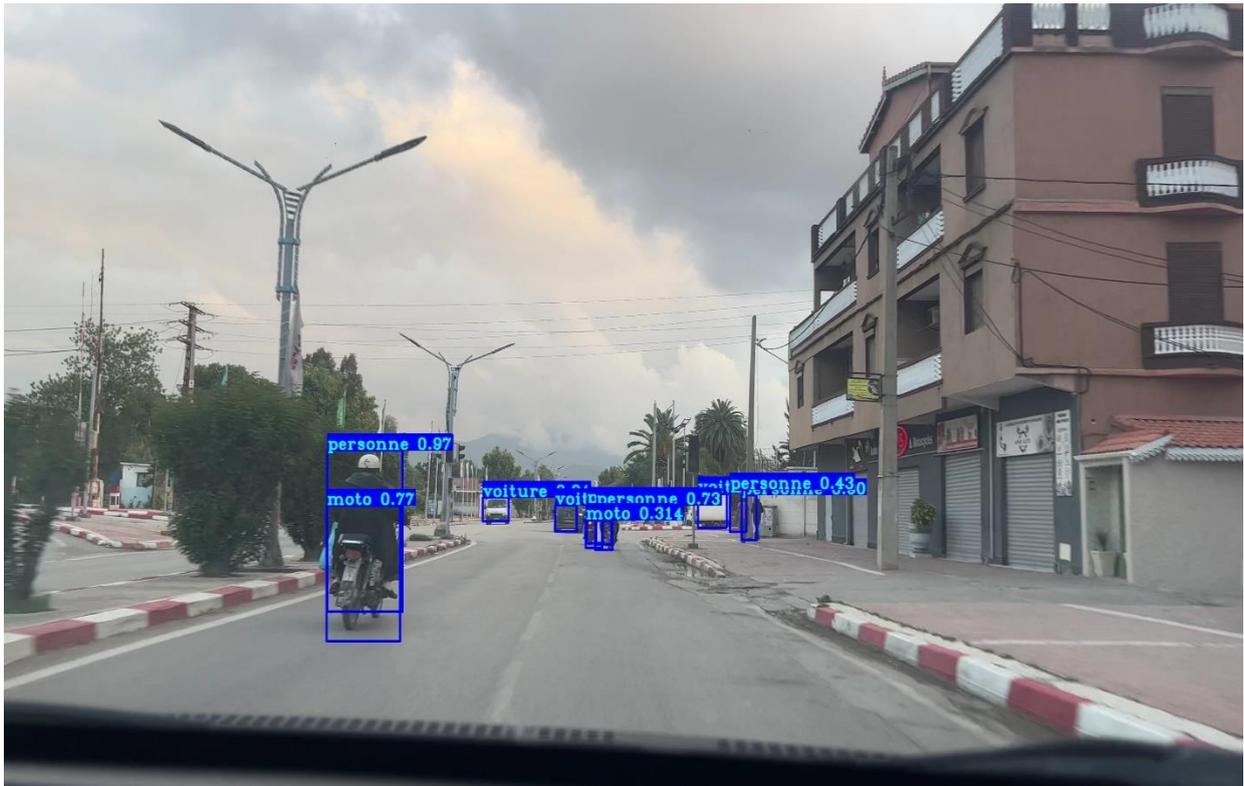


Figure 38: l'image représente la détection d'une moto ainsi que la personne qui la conduit.

Détection d'une voiture : Cette classe concernant notre simulation a propos de la detection d'une voiture

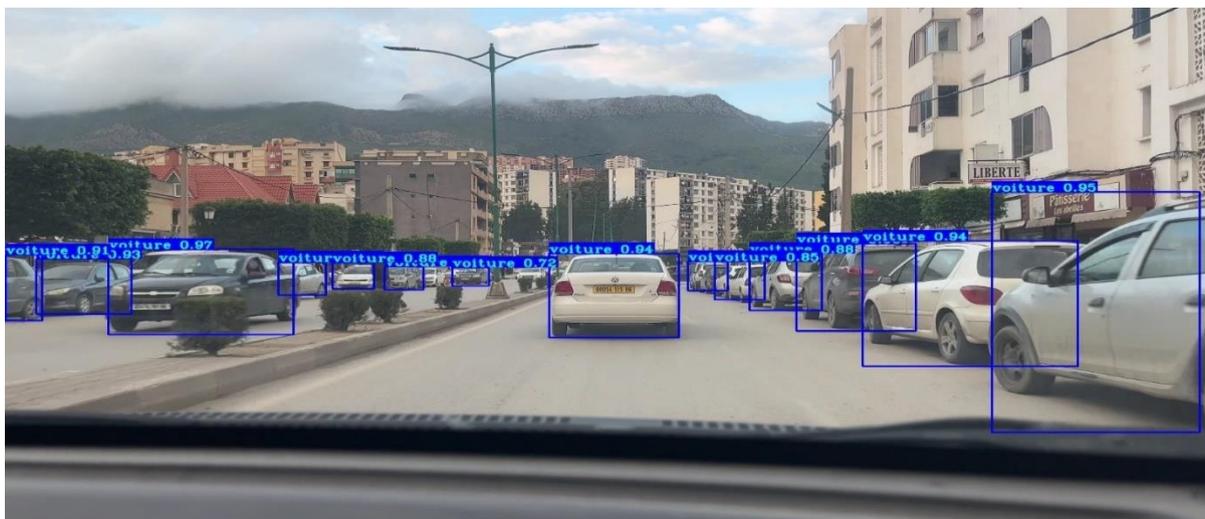
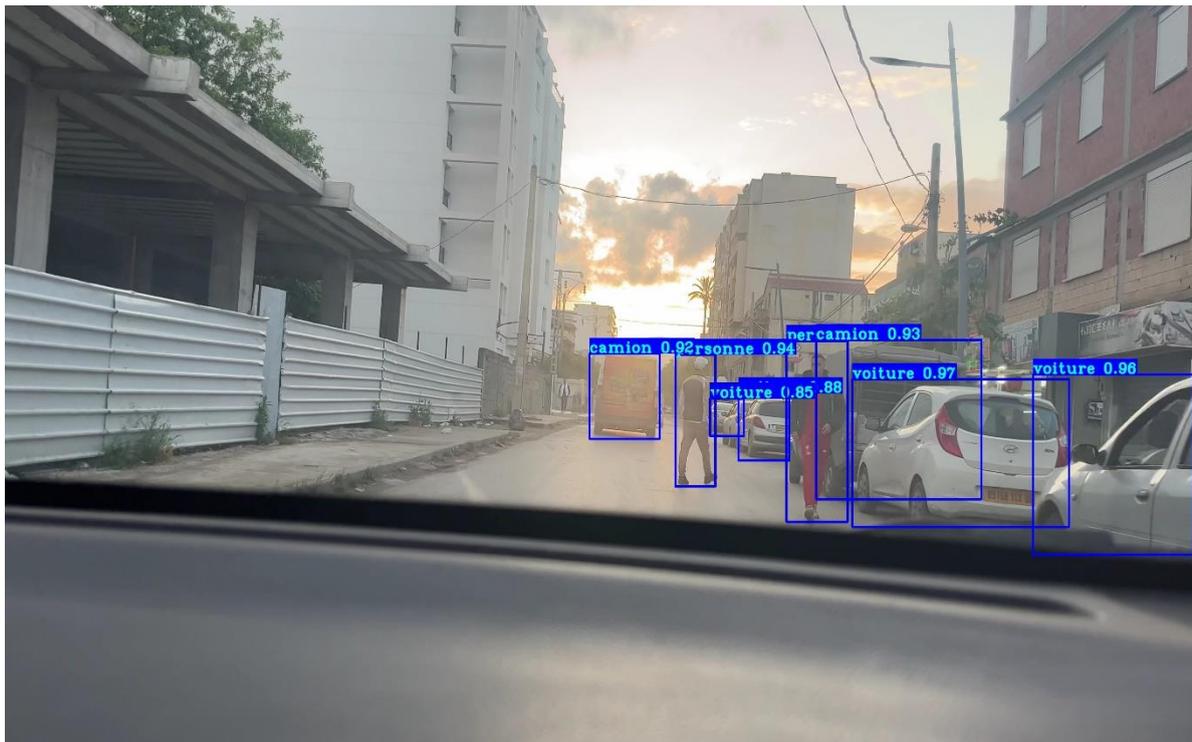
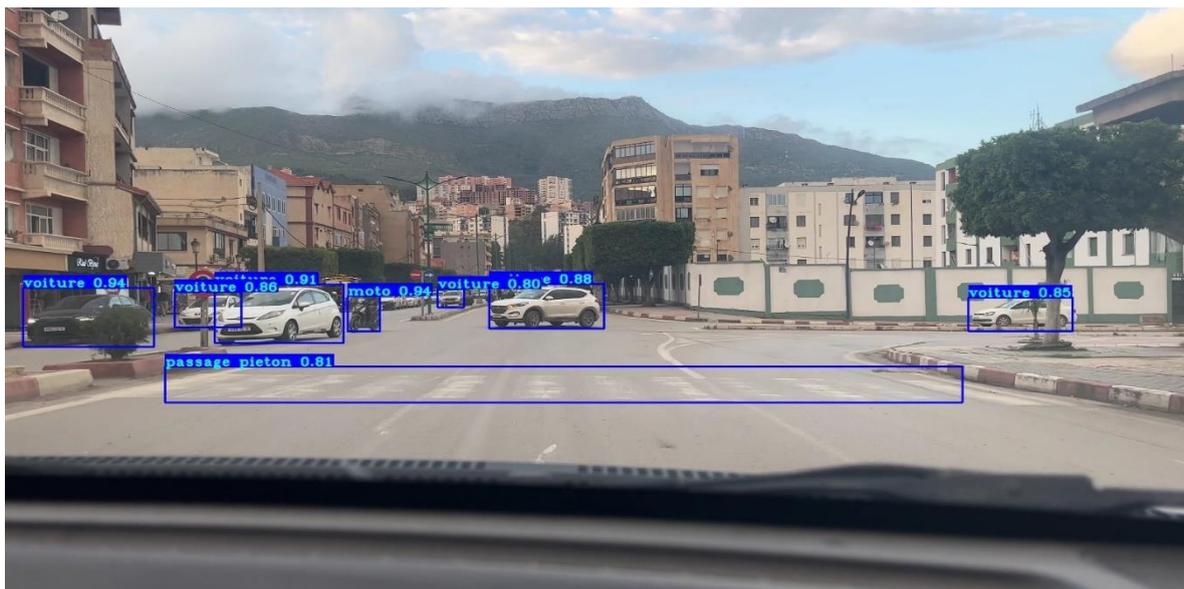


Figure 39: Image représentative de la détection de la classe voiture.

Détection d'un Camion :**Figure 40:** détection d'un camion.

Panneaux de signalisations : cette classe concerne les panneaux de signalisation.

Détection d'un Passage Piétons : on remarque qu'avec même avec la dégradation de ce dernier, l'application le détecte.

**Figure 41:** Passage piétons.

Détection d'un Panneau de stop :

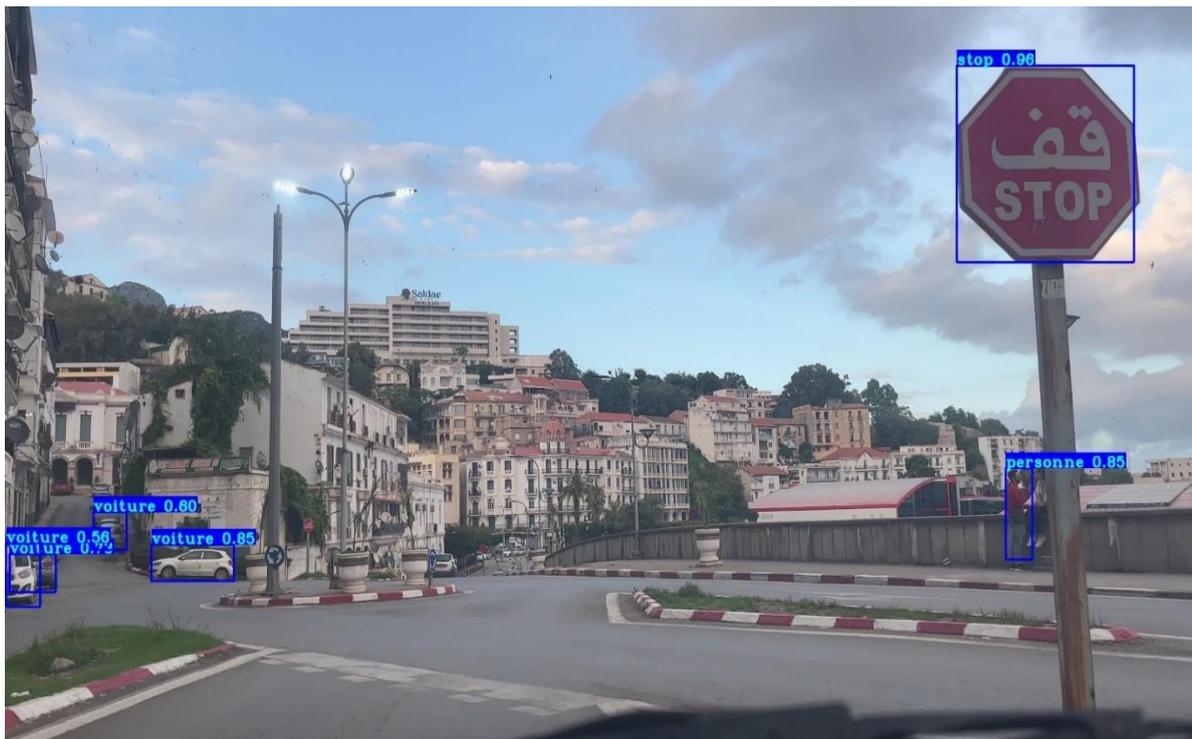


Figure 42: Panneau de stop.

Détection d'une personne : Elle détecte les personnes environnantes.



Figure 43: Détection d'une personne.

Classe feux de signalisation : Celle-ci permet de cerner les différents feux possibles, c'est à dire rouge, orange et vert. Voici les images qui les décrivent respectivement.

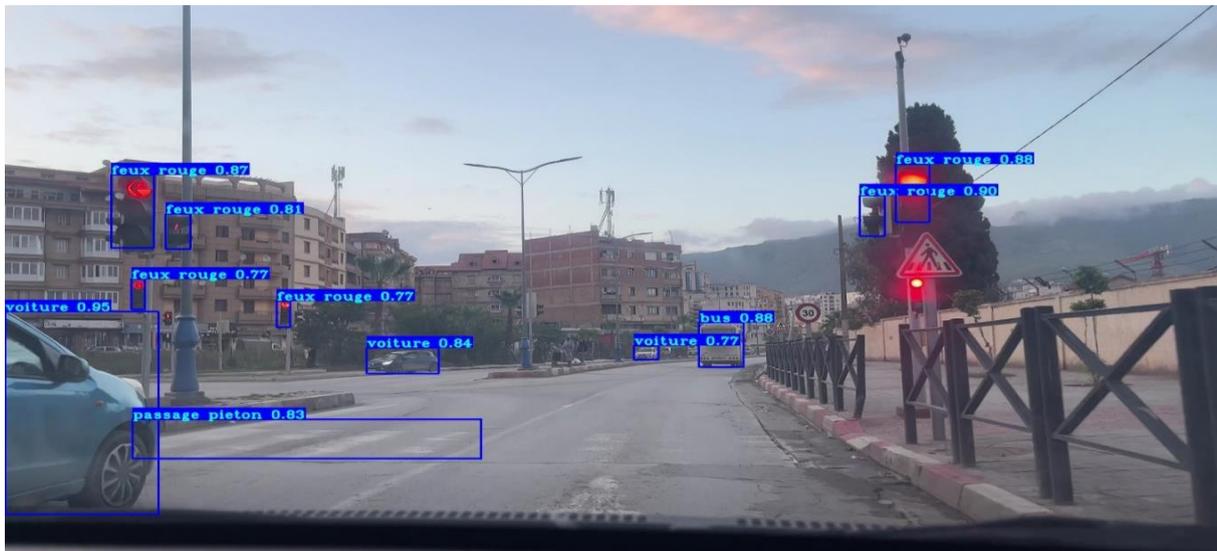


Figure 44: Feu rouge.

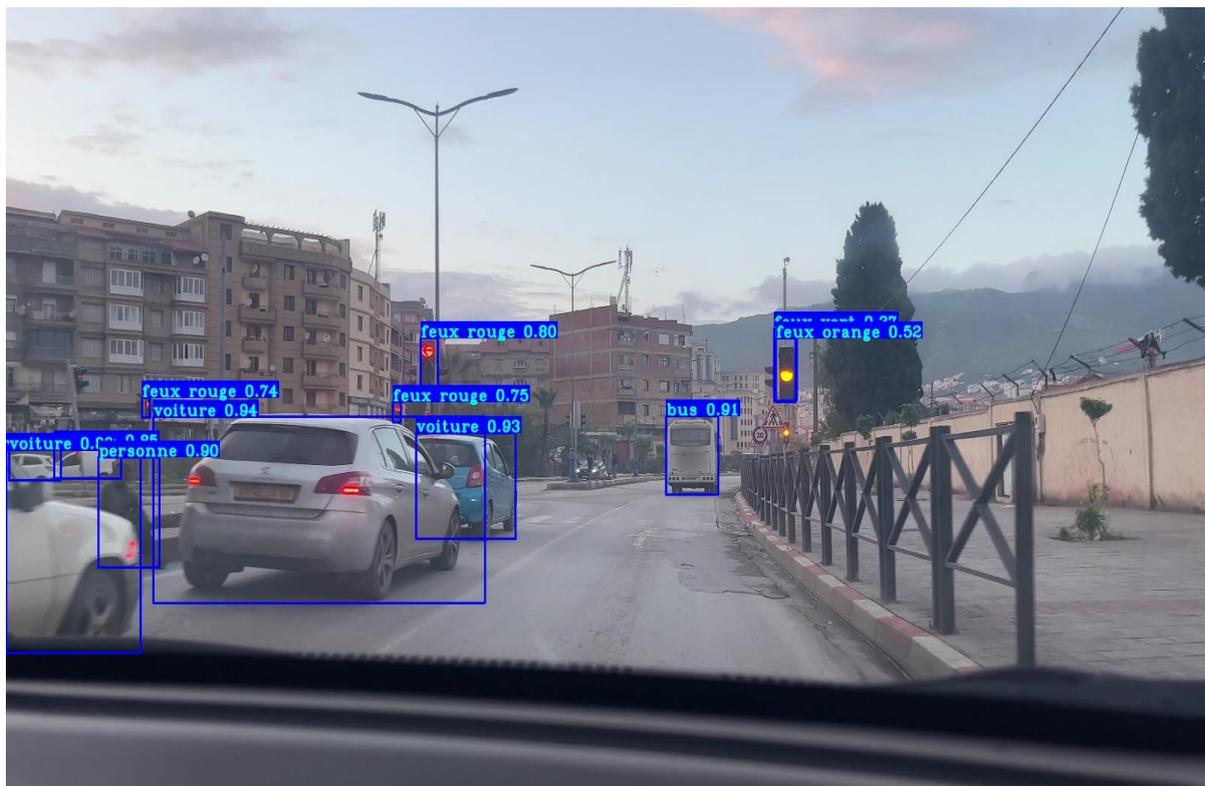


Figure 45: Feu orange.



Figure 46: Feu vert.

Voici un exemple de détection regroupant plusieurs classes au même moment, que ce soit les feux, les personnes ou bien les véhicules. Mais tout dépend du scénario donc chaque moment peut varier donc la détection des classes aussi.

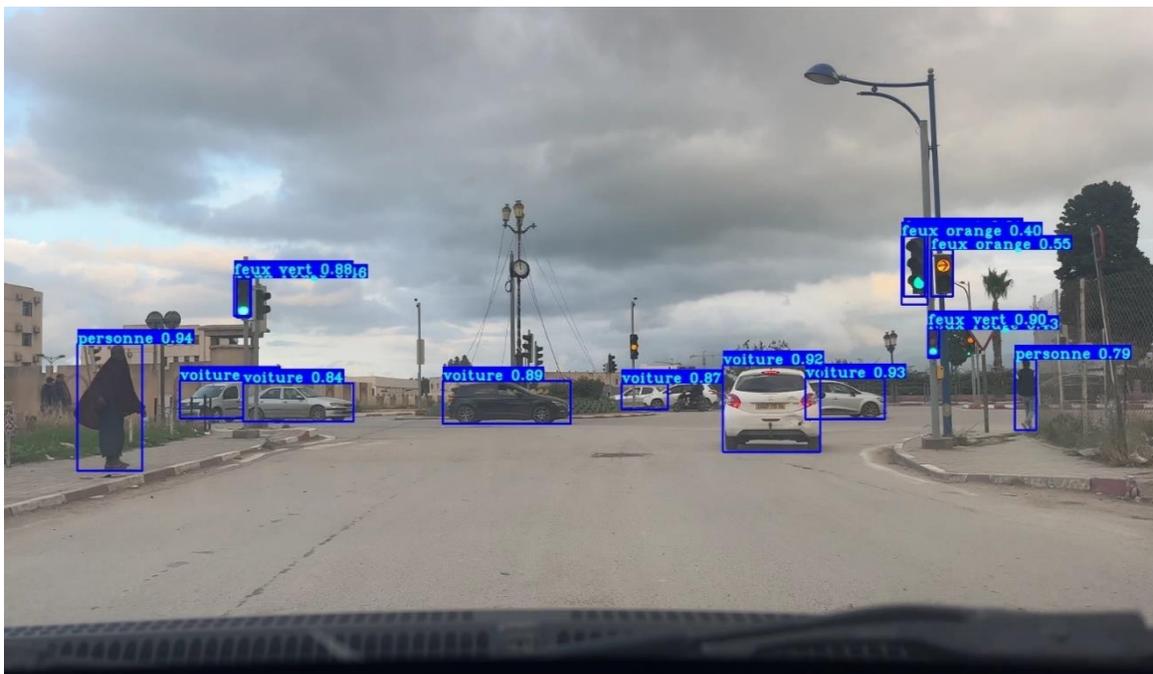


Figure 47: détection plusieurs.

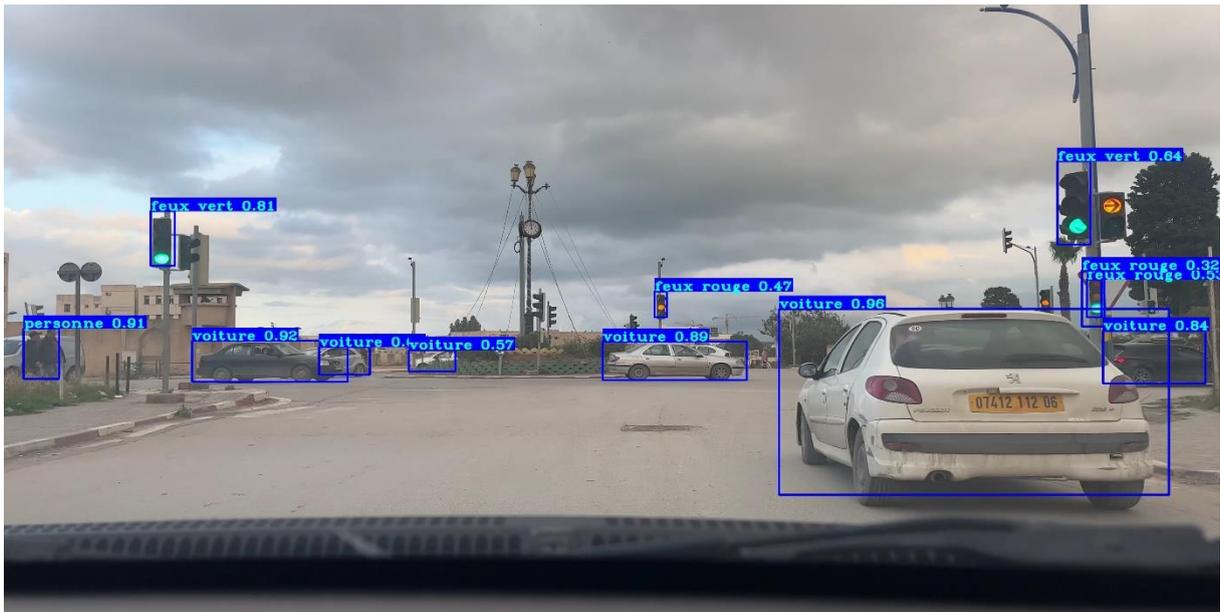


Figure 48: détection d'une erreur.

4.12 Discussions

D'après les résultats obtenus nous avons vu que la performance de model yolo on détection de diffèrent objet dans l'image est plus précis surtout dans les classes avec un mAP élevée tels que les personnes, les voitures, stop, moto, bus. Aussi nous avons vu que portant la précision des feux verts est de 87% dans le résultat de train mais dans le test elle confond des fois avec les autres feux (orange et rouge) vu que leurs prédictions sont faibles, et on remarque que les passage piétons aussi est faibles (8%).

- **Point fort :**
 - La Plupart des boites englobantes cadrent bien les objets avec une précision élevé
 - La fiabilité du model est généralement très intéressante par apport aux modèles de détection en temps réel
 - Vitesse d'exécution élevée pour une détection d'objets en temps réel.
- **Points faibles :**
 - Nécessite un grand ensemble de données d'entraînement annotées pour atteindre des performances optimales.
 - Consommation de ressources informatiques plus importante en raison de la complexité du modèle. (GPU).
 - L'Apprentissage prend beaucoup de temps (des jours).

4.13 Conclusion

Dans ce chapitre, nous soulignons l'importance de la base de données pour notre projet de simulation. Nous collectons des images et des vidéos de la ville de Bejaïa pour créer une base de données personnelle. Nous utilisons un site en ligne pour labelliser les images et divisons la base de données en parties de test et d'entraînement. Les fichiers XML sont ensuite convertis en format YOLO, et nous modifions les configurations pour l'entraînement du modèle. En lançant l'entraînement, nous obtenons des résultats de détection pour les 10 classes d'objets.

Cependant, la détection des classes peut varier selon les scénarios et les moments spécifiques. En conclusion, la création de la base de données et l'entraînement du modèle constituent une étape cruciale pour le développement et l'amélioration de la précision de la simulation et pour avoir une détection précise et la fiabilité augmente faut augmenter la base de données avec plusieurs photos et être précis dans l'étape de labélisation pour avoir des bons résultats.

Conclusion générale :

La combinaison de la technologie 5G et du modèle YOLOv3 pour la détection d'obstacles dans le trafic urbain offre des perspectives prometteuses pour l'amélioration de la sécurité et de l'efficacité des véhicules autonomes. Au cours de cette étude, nous avons examiné les avantages de la 5G en tant qu'infrastructure de communication, offrant une connectivité rapide et fiable avec une faible latence, ce qui est essentiel pour les applications en temps réel des véhicules autonomes.

Nous avons également exploré les caractéristiques spécifiques des véhicules autonomes, tels que les capteurs utilisés pour la perception de l'environnement, et avons constaté que la détection précise d'obstacles dans le trafic urbain est cruciale pour assurer la sécurité des passagers et des autres usagers de la route. C'est là que le modèle YOLOv3 entre en jeu, offrant une détection en temps réel et précise des objets dans des scènes complexes.

À travers des simulations et des résultats expérimentaux, nous avons pu évaluer les performances de la combinaison 5G et YOLOv3 dans la détection d'obstacles dans le trafic urbain. Ces résultats ont montré que cette approche peut fournir des informations essentielles pour la navigation des véhicules autonomes, contribuant ainsi à améliorer leur sécurité et leur efficacité.

Cependant, il convient de noter que des défis subsistent, tels que la détection de petits objets et d'objets de forme allongée. Des recherches supplémentaires sont nécessaires pour améliorer les performances de la détection d'obstacles dans des environnements urbains complexes et pour optimiser l'intégration de la 5G et du modèle YOLOv3.

En conclusion, la combinaison de la technologie 5G et du modèle YOLOv3 offre de nouvelles opportunités pour améliorer la détection d'obstacles dans le trafic urbain pour les véhicules autonomes. Cela ouvre la voie à des avancées significatives dans le domaine de la conduite autonome, contribuant ainsi à une mobilité plus sûre et plus efficace dans les environnements urbains de demain.

Bibliographie

- [F2] Documentation officielle ZTE
- [F5] Mojtaba Vaezi · Zhiguo Ding, H. Vincent Poor Editors "Multiple Access Techniques for 5G Wireless Networks and Beyond" Springer
- [2] Réseau 5g. L'ARCHITECTURE 5G. url : <http://www.reseau5g.info/le-deploiement-d>
- [3] Harald Remmert. Qu'est-ce que l'architecture de réseau 5G ? url :
- [5] 5g-indonesia. Penjelasan Lengkap Massive MIMO 5G. url : <https://www.5g-indonesia.com/penjelasan-lengkap-massive-mimo-5g.html>.
- [6] Metaswitch. What is 5G beamforming, beam steering and beam switching with massive MIMO. url : <https://www.metaswitch.com/knowledge-center/reference/what-is-beamforming-beam-steering-and-beam-switching-with-massive-mimo>.
- [7] Robin Chataut et Robert Akl. « Massive MIMO systems for 5G and beyond networks—overview, recent trends, challenges, and future research direction ». In : *Sensors* 20.10 (2020), p. 2753.
- [8] Noha Hassan et Xavier Fernando. « Massive MIMO wireless networks : An overview ». In : *Electronics* 6.3 (2017), p. 63.
- [13] Faisal, Asif, et al. "Understanding Autonomous Vehicles: A Systematic Literature Review on Capability, Impact, Planning and Policy." *Journal of Transport and Land Use*, vol. 12, no. 1, 2019, pp. 45–72. JSTOR, <https://www.jstor.org/stable/26911258>.
- [14] DUPUY Gabriel, « Voiture autonome : la fin des territoires de l'automobile ? », *Flux*, 2020/1-2 (N° 119-120), p. 185-191. DOI : 10.3917/flux1.119.0185. URL : <https://www.cairn.info/revue-flux-2020-1-page-185.htm>
- [15] Real-Time Object Detection for Autonomous Vehicles Using YOLO" par Yunyi Zhang, Yanming Zhan et Dali Wang. Cet article présente une étude sur l'utilisation de YOLO pour la détection d'objets en temps réel dans le contexte des véhicules autonomes. [Référence : *International Journal of Advanced Robotic Systems*, 2019]
- [16] Real-Time Object Detection on Autonomous Vehicles Using YOLO" par Chenglong Wang, Chenglei Wu, Xi Zhou, et Zhigang Cao. Cette étude explore l'intégration de YOLO pour la détection d'objets en temps réel sur des véhicules autonomes, en mettant l'accent sur les aspects de performance et de précision. [Référence : 2018 IEEE International Conference on Robotics and Automation (ICRA)]

- [17] "OLO-based Object Detection System for Autonomous Vehicles" par Yinghua Wang, Changhao Sun et Xintong Fan. Cet article présente une approche d'intégration de YOLO pour la détection d'objets sur des véhicules autonomes, en mettant en évidence les avantages de la vitesse de traitement et de la précision. [Référence : 2019 5th International Conference on Control, Automation and Robotics (ICCAR)]
- [18] "You Only Look Once : Unified, Real-Time Object Detection" par Joseph Redmon, Santosh Divvala, Ross Girshick et Ali Farhadi. Article publié à la Conférence sur la reconnaissance des objets et le traitement des images (CVPR) en 2016.
- [19] Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. arXiv preprint arXiv:1804.02767.
- [22] Zhao, M., Li, X., & Ma, X. (2020). Real-time object detection based on improved YOLOv3 model. IOP Conference Series: Earth and Environmental Science, 474(1), 012067.
- [23] NVIDIA. CUDA Toolkit. [En ligne]. Disponible sur : <https://developer.nvidia.com/cuda-toolkit>
- [24] OpenCV. OpenCV Library. [En ligne]. Disponible sur : <https://opencv.org/>
- [25] Zhang, X., Lin, Z., & Wang, J. (2021). Intelligent vehicle object detection system based on YOLOv4 and 5G network. IEEE Access, 9, 59024-59034.
- [26] Liu, L., Ota, K., & Dong, M. (2020). 5G and Internet of Things (IoT): A Tutorial Overview. IEEE Access, 8, 41186-41203.
- [30] CNN et Couche de Convolution, ce que tu dois savoir maintenant (inside-machinelearning.com) <https://inside-machinelearning.com/cnn-couche-de-convolution/>
- [31] Convolutional Neural Network. Learn Convolutional Neural Network from... | by dshahid380 | Towards Data Science
- [35] Tahir MN, Leviäkangas P, Katz M. Connected Vehicles: V2V and V2I Road Weather and Traffic Communication Using Cellular Technologies. Sensors (Basel). 2022 Feb 2;22(3):1142. doi: 10.3390/s22031142. PMID: 35161886; PMCID: PMC8838867.

WEBOGRAPHIE

- [1] https://www.itu.int/en/ituNews/Documents/2017/2017-02/2017_ITUNews02-fr.pdf
- [4] <https://fr.digi.com/blog/post/5g-network-architecture>.
Anfr. Evaluation de l'exposition du public aux ondes électromagnétiques 5G. url : <https://www.anfr.fr/fileadmin/mediatheque/documents/expace/CND/Rapport-ANFR-presentation-generale-5G.pdf>.
- [9] <https://www.rs-online.com/designspark/lidar-radar-digital-cameras-the-eyes-of-autonomous-vehicles-fr>
- [12] <https://blog.irt-systemx.fr/tag/vehicules-autonomes/>
- [F1] https://www.researchgate.net/figure/the-evaluation-of-cellular-networks_fig1_342174425
- [F3] https://www.itu.int/dms_pub/itu-d/opb/pref/D-PREF-BB.5G_01-2018-PDF-F.pdf
- [F4] <https://techblog.comsoc.org/2019/08/02/t-mobile-claim-1st-standalone-5g-data-session-on-a-multi-vendor-radio-and-core-network/>
- [F6] https://www.itu.int/dms_pub/itu-d/opb/pref/D-PREF-BB.5G_01-2018-PDF-F.pdf
- [F7] <https://www.qorvo.com/design-hub/blog/our-five-most-popular-blogs-of-2019>
- [F8] <https://www.edn.com/the-top-5-5g-wireless-technologies/>
- [F9] <https://fr.digi.com/blog/post/introduction-to-smart-transportation-benefits>
- [F10] <https://blog.irt-systemx.fr/machine-learning-et-conduite-autonome/>
- [F11] <https://www.mobilityits.eu/vehicule-infrastructureits>
- [F12] <http://www.univ-bejaia.dz/xmlui/bitstream/handle/123456789/12174/Techniques%20de%20co>

ntre%20de%20congestion%20dans%20les%20r%C3%A9seaux%20v%C3%A9hiculaires.pdf?sequence=1&isAllowed=y

- [F14] <https://itsocial.fr/actualites/vehicules-autonomes-comprendre-detection-dobstacle-selon-apple/>
- [F15] <https://openclassrooms.com/fr/courses/4470406-utilisez-des-modeles-supervises-non-lineaires/4730716-entraenez-un-reseau-de-neurones-simple>
- [F16] https://www.researchgate.net/figure/Representation-graphique-des-fonctions-dactivation-sigmoide-et-ReLU-7_fig9_327882341
- [F17] <https://www.analyticsvidhya.com/blog/2020/10/what-is-the-convolutional-neural-network-architecture/>
- [F18] https://www.researchgate.net/figure/Processus-de-convolution-sur-une-feature-map-en-entree-en-bleu-donnant-un-pour-resultat_fig4_343268354
- [F19] https://mohameddhaoui.github.io/deeplearning/CNN_tuto11/
- [F20] <https://towardsdatascience.com/a-deeper-understanding-of-nnets-part-1-cnns-263a6e3ac61>
- [F21] <https://inside-machinelearning.com/cnn-couche-de-convolution/>
- [F22] <https://towardsdatascience.com/covolutional-neural-network-cb0883dd6529>
- [F23] <https://towardsdatascience.com/covolutional-neural-network-cb0883dd6529>
- [F25] <https://medium.com/@ankushsharma2805/yolo-v1-v2-v3-architecture-1ccac0f6206e>
- [F26] <https://medium.com/@ankushsharma2805/yolo-v1-v2-v3-architecture-1ccac0f6206e>

- [F27] <https://medium.com/@ankushsharma2805/yolo-v1-v2-v3-architecture-1ccac0f6206e>
- [F28] <https://arxiv.org/pdf/2005.06089.pdf>
- [10] <https://arxiv.org/pdf/1511.01643.pdf>
- [11] <https://arxiv.org/ftp/arxiv/papers/2101/2101.04539.pdf>
- [27] <https://medium.com/analytics-vidhya/understanding-yolo-and-implementing-yolov3-for-object-detection-5f1f748cc63a>
- [28] <https://pjreddie.com/darknet/yolo/>
- [29] https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/Redmon_You_Only_Look_CVPR_2016_paper.pdf
- [32] <https://scilogs.fr/intelligence-mecanique/architecture-des-reseaux-de-neurones-reseaux-de-neurones-artificiels-classiques-2-3/>
- [33] https://www.researchgate.net/figure/Representation-graphique-des-fonctions-dactivation-sigmoide-et-ReLU-7_fig9_327882341
- [34] analyticsvidhya.com/blog/2020/10/what-is-the-convolutional-neural-network-architecture/