

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique
Université A. Mira de Béjaïa
Faculté des Sciences Exactes
Département d'Informatique



Mémoire de Fin de Cycle

En vue de l'obtention du diplôme de Master Recherche en Informatique

Option :

Intelligence Artificielle

Thème

Proposition d'une approche de sûreté des trains autonomes

Réalisé par :

OUAZINE Mouna
MOHAMADI Loubna

Devant le jury composé de :

Président :	HAMZA	Lamia	Université de Béjaïa
Encadrante :	ZAMOUCHE	Djamila	Université de Béjaïa
Examineur :	BOUCHEBBAH	Fatah	Université de Béjaïa
Examinatrice :	CHERIFI	Feriel	Université de Béjaïa

Promotion 2023/2024

Remerciements

Notre remerciement s'adresse en premier lieu à Allah pour la volonté, la santé et la patience qu'il nous a donnée durant toutes ces longues années.

Ce travail n'aurait pas pu être réalisé sans l'aide considérable, le soutien et la relecture critique de notre encadrante, **Mme Djamilia Zamouche**. Sa précieuse contribution sur le fond et la forme de ce mémoire nous a guidés sur le chemin du savoir.

Nous remercions également **Mme Djamilia Boulahrouz** chef du département d'informatique, pour ses remarques et son suivi tout au long de nos études.

Nous souhaitons remercier chaleureusement tous les enseignants qui ont contribué à notre formation.

Nous adressons un grand merci à tous nos proches, amis et collègues pour leur soutien moral et encouragements.

En conclusion, nous souhaitons exprimer notre immense gratitude envers toutes les personnes qui ont participé de près ou de loin, à l'achèvement de ce mémoire.

Dedicace

Je dédie ce travail à :

Mes très chers parents qui ont toujours été là pour moi merci pour vos sacrifices permanent durant toutes mes études ,votre soutien dans les moments difficiles , votre reconfort pour me voir réussir un jour, je vous prie de bien vouloir trouver en ce modeste travail le couronnement de vos multiples efforts , le temoignage de mon profonde affection et de mon attachement indéfectible .

Que dieu vous garde!

A toute ma familles ,mes amis et proches.

Mlle Ouazine Mouna

Dedicace

Je dédie ce travail à :

Ma famille pour leur soutien constant et leurs presence durant les periodes les plus difficiles de ma vie : A mes parents pour leurs encouragements et leurs confiance en moi. A mon frere et a mes soeurs , pour leur patience et leurs comprehension . A mes amis proches , merci pour votre soutien moral et encouragements qui m'ont aidé a rester motivée.

Ce travail est le resultat de nos efforts communs , Merci a tous!

Mlle MOHAMADI Loubna

Table des Matières

Table des Matières

Table des Figures

Liste des Tableaux

Introduction générale	2
1 NOTIONS FONDAMENTALES	4
1.1 Introduction	4
1.2 Système de transport intelligent	4
1.2.1 Technologies des STI	5
1.2.1.1 Technologies de calcul avancées	5
1.2.1.2 Technologies de capteurs	5
1.2.1.3 Technologies de localisations	5
1.3 Véhicules autonomes	5
1.3.1 Niveaux d'automatisation ferroviaires	6
1.4 Sûreté de fonctionnement	7
1.5 L'Intelligence Artificielle	8

1.5.1	Apprentissage automatique	8
1.5.1.1	Apprentissage supervisé	8
1.5.1.2	Apprentissage non-supervisé	8
1.5.1.3	Apprentissage semi-supervisé	8
1.5.1.4	Apprentissage par renforcement	9
1.5.2	Apprentissage profond	9
1.5.3	Réseaux de neurones artificiels	9
1.5.4	Réseaux de neurones convolutifs	10
1.6	Chaînes de Markov	12
1.7	Algorithme YOLOV5	12
1.8	Conclusion	12
2	Mécanismes de sûreté pour la conception des trains autonomes : Revue de la littérature	13
2.1	Introduction	13
2.2	Critères de comparaison	13
2.2.1	Précision	14
2.2.2	Temps de réponse	14
2.2.3	Complexité	14
2.2.4	coût	14
2.3	Classification	14
2.3.1	Approches basées sur la vision par ordinateur et apprentissage profonds	15
2.3.2	Approches basées sur les réseaux de pétri	15

2.3.3	Approches basées sur des agents logiciels	15
2.3.4	Approches basées sur les techniques Delphi et ANP	15
2.4	Etude critique	16
2.4.1	Application of Computer Vision and Deep Learning in the railway domain for autonomous train	16
2.4.2	Well-Formed Petri Net Based Patterns For Modeling Logic Controllers For Autonomous Trains	16
2.4.3	Autonomous driving trains to pass in bidirectional crossing loop preventing stops	17
2.4.4	Determinants of autonomous train operation adoption in rail freight :knowledge-based assessment with Delphi-ANP approach	17
2.4.5	Autonomous Train Operational Safety assurance by Accidental Scenarios Searching	18
2.4.6	Model-based safety engineering for autonomous train map	18
2.4.7	Full Automation in Driverless Trains : A Microcontroller-Based Prototype	18
2.4.8	Train-centric Communication based Autonomous Train Control System	19
2.4.9	A framework for risk-awareness and dynamic risk assessment for autonomous trains	19
2.4.10	A2CPS : A Vehicle-Centric Safety Conceptual Framework for Autonomous Transport Systems	20
2.5	Comparaison et Synthèse	20
2.6	Conclusion	22
3	RailSmart : An intelligent and highly reliable platform for safe autonomous railway driving	23
3.1	Introduction	23

3.2	Motivation	23
3.3	Solution proposée	24
3.3.1	Phase de perception de l'environnement	24
3.3.2	Phase de détection d'objets	25
3.3.3	Phase de prédiction du taux de risque	27
3.3.4	Phase de prise de décision	28
3.4	Conclusion	33
4	Evaluation de Performances	34
4.1	Introduction	34
4.2	Evaluation de performances	34
4.3	Environnement de développement	35
4.4	Langage de programmation et bibliothèques	36
4.5	Dataset	36
4.5.1	Udacity Self-Driving Car	36
4.5.2	Railway Track Fault Detection	37
4.6	Prétraitement des données	37
4.6.1	Nettoyage des données	38
4.6.2	Normalisation des données	39
4.6.3	Combinaison des données	39
4.6.4	Division du dataset	39
4.7	Entraînement et test du modèle	39
4.8	Métriques de simulation	40

4.8.1	Précision	40
4.8.2	Exactitude	40
4.8.3	Le rappel	41
4.8.4	Le F1 –score	41
4.9	Resultats obtenus	41
4.9.1	Rapport de classification	41
4.10	Conclusion	42
	Conclusion Générale et Perspectives	44

Table des figures

1.1	Définition des grades d'automatisation ferroviaires GoA [5].	7
1.2	La différence entre l'intelligence artificielle, apprentissage automatique et l'apprentissage profond [11].	9
1.3	Architecture d'un réseau de neurone artificiel [13].	10
1.4	Analogie entre neurones artificiels et un véritable neurone du cerveau humain [13].	11
1.5	Exemple d'une opération de convolution a) et une opération de deconvolution b) [18].	11
3.1	Schéma récapitulatif de la solution proposée.	25
3.2	le réseau de neurones profond avec deux couches cachées	27
3.3	Processus de prise de décision	28
4.1	schema recapitulatif des etapes de l'experimentation	35
4.2	Attributs du dataset udacity self driving car.	37
4.3	Rails défectueux.	38
4.4	Rails non défectueux.	38
4.5	Résultats de l'évaluation de l'entraînement du modèle YOLOV5.	42
4.6	Résultats de l'évaluation du test du modèle YOLOV5.	42
4.7	Résultats de l'évaluation des performances du modèle à différents seuils . .	43

Liste des tableaux

2.1	Tableau comparatif	21
-----	------------------------------	----

Introduction générale

Ces dernières années, les demandes de mobilité et de transport sont devenues de plus en plus complexes, passant du simple fait de permettre aux gens d'atteindre leurs destinations à celui de les transporter de manière sûre et fiable . Le transport ferroviaire constitue actuellement l'un des moyens les plus importants et les plus performants du transport terrestre de passagers et de marchandises. Son développement a atteint un niveau tel qu'il le place en sérieux concurrent au transport par avion. Cette évolution, qui s'est produite sur plus d'un siècle, se traduit par une augmentation régulière des vitesses, des charges et du trafic que les voies de chemins de fer doivent supporter. Ces croissances continues, enregistrées dans les chemins de fer, sont accompagnées d'un progrès parallèle dans les technologies de conception et de fabrication, intégrant les technologies numériques et l'information technique

Malgré ces avancées, le système de transport ferroviaire doit encore relever plusieurs défis majeurs. Parmi eux, la nécessité d'améliorer la sécurité et l'efficacité du trafic ferroviaire devient primordiale. La détection rapide et précise des obstacles ainsi que la prise de décision autonome sont des aspects cruciaux pour atteindre cet objectif. Actuellement, la majorité des systèmes de conduite des trains repose sur une supervision humaine, ce qui limite leur capacité à réagir instantanément et efficacement aux situations imprévues. Dans ce contexte, de nombreuses méthodes ont été proposées dans la littérature pour résoudre le problème de la conduite autonome des trains. Bien que ces solutions offrent des avantages considérables, elles présentent également des limitations significatives les rendent plus complexes et moins efficaces, ce qui nécessite des révisions ou le développement de nouvelles solutions.

Dans ce travail, notre objectif est de concevoir un système de conduite autonome des trains. La solution proposée est conçue pour détecter les obstacles dans l'environnement du train et lui permettre de prendre des décisions de manière autonome. Pour y parvenir, nous nous appuyons sur l'utilisation de l'algorithme YOLO (You Only Look Once), des réseaux de neurones profonds, des chaînes de Markov et de l'apprentissage par renforcement. La résolution de ce problème apportera des avantages considérables, non seulement en améliorant la circulation ferroviaire mais aussi en permettant une gestion plus efficace de l'infrastructure.

Notre travail est structuré en quatre chapitres :

Chapitre I : Donne une vue d'ensemble des Systèmes de Transport Intelligents (STI), ainsi que de leur impact sur les systèmes de transport modernes, nous avons également inclus des définitions générales sur les composantes de notre modèle. En somme, ce chapitre offre une lecture approfondie sur les STI, cruciale pour la compréhension de ce manuscrit.

Chapitre II : Approfondit notre compréhension de la conduite autonome des trains en examinant les différentes méthodes proposées dans la littérature pour répondre à ce défi.

Chapitre III : Présente notre approche pour la conception d'un système de conduite autonome des trains en utilisant les réseaux de neurones, les chaînes de Markov et l'apprentissage par renforcement. Nous détaillons les différentes étapes de la construction du modèle.

Chapitre IV : Évalue la performance de notre modèle en mesurant la précision, le rappel, la fonction de perte et la F1-mesure. Nous discutons également des limites de notre modèle et des pistes pour son amélioration future.

1

NOTIONS FONDAMENTALES

1.1 Introduction

La croissance technologique a joué un rôle crucial dans la révolution des systèmes de transport. Une application clé est l'utilisation des systèmes de détection d'obstacles et de prises de décision dans le transport ferroviaire, ce qui nécessite des moyens plus sophistiqués pour un fonctionnement efficace et sûr. Cette nécessité est particulièrement critique dans le contexte des systèmes ferroviaires, qui ont un haut potentiel pour des accidents catastrophiques dans la détection ou l'évitement d'obstacles. L'IA, spécifiquement l'apprentissage profond, a été identifié comme une solution potentielle à ces défis. Les récentes avancées de cette technologie offrent la possibilité d'apprendre des motifs complexes, de s'adapter à de nouveaux scénarios et de faire des prédictions précises, ce qui peut améliorer considérablement l'efficacité et la sécurité des opérations ferroviaires [1]. Dans ce premier chapitre, nous allons présenter les Systèmes de Transport Intelligent, pour mettre en avant le background sur lequel nous travaillons. Nous examinerons également les technologies qui sous-tendent les STI, notamment les réseaux de neurones profonds, l'apprentissage par renforcement, les chaînes de Markov.

1.2 Système de transport intelligent

Le système de transport intelligent (STI) est un système complet de gestion des services de transport qui intègre des fonctions liées à l'intelligence, telles que le traitement

de l'information. Ce système permet ainsi de traiter, d'analyser et de communiquer des informations relatives aux services de transport en utilisant une large gamme de technologies, notamment la télématique, l'électronique embarquée ou fixe, les télécommunications, les bases de données et d'information, les systèmes de régulation [2].

1.2.1 Technologies des STI

Les STI utilisent une variété de technologies pour répondre à des problèmes de transport spécifiques. Les technologies utilisées peuvent aller des systèmes de gestion de base comme les feux de signalisation et les panneaux à messages variables, jusqu'à des applications plus avancées qui intègrent des données en temps réel provenant de nombreuses sources, telles que les informations météorologiques et les systèmes de navigation embarqués [3].

1.2.1.1 Technologies de calcul avancées

Les STI sont également équipés de technologies de calcul avancées, telles que des processeurs informatiques plus performants et des plates-formes informatiques embarquées capables d'exécuter des applications logicielles sophistiquées comme l'intelligence artificielle qui est particulièrement importante pour les STI, car elle permet de traiter des données massives et complexes en temps réel.

1.2.1.2 Technologies de capteurs

Les STI sont équipés de technologies de capteurs, telles que les capteurs vidéo, les boucles électromagnétiques et les réseaux de capteurs sans fil, qui permettent de collecter des données sur les caractéristiques des véhicules.

1.2.1.3 Technologies de localisations

Les STI utilisent également des technologies de localisation, telles que la géolocalisation par système de positionnement par satellite comme le GPS et la téléphonie mobile.

1.3 Véhicules autonomes

Les véhicules autonomes, également connus sous le nom de véhicules auto-conduits, sont des véhicules capables de percevoir leur environnement et de naviguer sans inter-

vention humaine. Ils utilisent une combinaison de capteurs, de caméras, de radars et de technologies de communication pour détecter les objets, interpréter les signaux et prendre des décisions en temps réel. Les systèmes d'intelligence artificielle (IA) intégrés permettent à ces véhicules d'analyser les données collectées, de planifier des itinéraires et d'éviter les obstacles, assurant ainsi une conduite sûre et efficace sans la nécessité d'un conducteur humain. Ils constituent sans doute la première avancée majeure sur la voie d'un système de transport efficace [4]. Dans notre mémoire, nous nous focaliserons sur les trains autonomes.

Les trains autonomes, sont des trains capables de fonctionner sans intervention humaine. Ces trains utilisent une combinaison de technologies avancées telles que des capteurs, des radars, des caméras, des systèmes de communication et des algorithmes d'intelligence artificielle (IA) pour percevoir leur environnement, interpréter les signaux ferroviaires et prendre des décisions en temps réel. Ils sont capables de planifier des itinéraires, de contrôler leur vitesse, de freiner et d'éviter les obstacles de manière autonome. Les trains autonomes visent à améliorer la sécurité, l'efficacité et la fiabilité des systèmes de transport ferroviaire tout en réduisant les coûts opérationnels et l'impact environnemental [5].

1.3.1 Niveaux d'automatisation ferroviaires

dans le secteur ferroviaire, le degré d'automatisation Grade of Automation (GoA), défini par la norme internationale IEC 62290-1, propose 5 niveaux allant d'un train entièrement géré par l'homme (GoA0) à un train totalement autonome (GoA4) [5]. Cette classification est illustrée dans la figure 1.1 Le Grade of Automation (GoA) est un indicateur utilisé pour évaluer et classer le degré d'automatisation d'un véhicule ferroviaire. Ce niveau s'étend d'une absence d'automatisation à une automatisation complète. GoA 0 se réfère à une absence totale d'automatisation, où toutes les actions et décisions sont prises par un conducteur humain. Le GoA 1, quant à lui, évoque un niveau d'automatisation minimal où certaines fonctions, telles que l'assistance au freinage ou la régulation de la vitesse, peuvent être automatisées, mais l'essentiel des tâches de conduite reste sous le contrôle de l'opérateur. À l'échelon GoA 2, bien que l'automatisation englobe plusieurs aspects de la conduite, le conducteur demeure essentiel pour surveiller l'environnement et reprendre le contrôle face à des situations imprévues ou dangereuses. Au niveau GoA 3, la surveillance constante de l'environnement par l'homme n'est plus requise. C'est le système qui assume cette fonction en identifiant les aléas potentiels et en les communiquant à l'opérateur, lequel doit toutefois demeurer à bord pour intervenir en cas d'urgence. Enfin, le GoA 4 représente une automatisation totale, où la présence humaine à bord n'est plus nécessaire et où la prise de décision, tout comme la perception de l'environnement, est intégralement gérée par le système automatisé. Il est intéressant de noter que même si cette classification peut s'appliquer à différents types de véhicules (trains, tramways, métros).






Tâches GoAs	Accélération/ Décélération	Départ/Arrêt aux stations/	Surveillance de l'environnement de conduite	Fermeture/ Ouverture des portes	Détection et gestion des urgences
GoA0 	Conducteur	Conducteur	Conducteur	Conducteur	Conducteur
GoA1 	Conducteur/ Système	Conducteur	Conducteur	Conducteur	Conducteur
GoA2 	Système/ Conducteur	Conducteur/ Système	Conducteur	Conducteur	Conducteur
GoA3 	Système	Système	Système	Contrôleur de train	Contrôleur de train
GoA4 	Système	Système	Système	Système	Système/ Personnel

FIGURE 1.1 – Définition des grades d'automatisation ferroviaires GoA [5].

1.4 Sûreté de fonctionnement

La sûreté de fonctionnement des trains est essentielle dans le développement et l'exploitation des systèmes complexes, tels que les trains autonomes. Elle englobe l'ensemble des mesures et des pratiques visant à garantir la sécurité des personnes et des biens, ainsi que la protection de la vie privée et des données personnelles dans le contexte de l'utilisation de technologies intelligentes pour le transport. Les STI comprennent divers systèmes tels que la navigation, la communication entre véhicules et avec les infrastructures, la gestion de flotte, l'assistance à la conduite et les véhicules autonomes. La sûreté de fonctionnement nécessite la prise en compte de nombreux facteurs tels que la fiabilité des capteurs et des systèmes de communication, la sûreté des données. Pour garantir la sûreté des systèmes de transport intelligents (STI) de manière générale, et spécifiquement pour les trains autonomes, il est important de mettre en place des processus de développement rigoureux, de tester les systèmes dans des conditions réelles [5].

1.5 L'Intelligence Artificielle

une notion originellement introduite par John McCarthy lors de la Conférence de Dartmouth en 1955 [5], a considérablement évolué depuis ses origines modestes. Elle se manifeste par la capacité d'une machine à simuler l'intelligence humaine, comprenant des branches telles que l'apprentissage automatique et l'apprentissage profond [6,7]. Ces techniques constituent un élément essentiel dans le progrès de l'IA.

1.5.1 Apprentissage automatique

L'apprentissage automatique est une sous-catégorie de l'IA. L'IA englobe tout algorithme qui permet aux ordinateurs de reproduire le comportement humain comme on peut le voir dans la figure . Des exemples de ces algorithmes sont les systèmes basés sur des règles [8] ou des systèmes experts. La capacité à apprendre sans être explicitement programmé était la suite des algorithmes de l'IA et est ce que nous appelons l'apprentissage automatique [9].

1.5.1.1 Apprentissage supervisé

Il s'agit d'une méthode où un modèle apprend à partir de données étiquetées. C'est-à-dire que chaque exemple de l'ensemble de données d'entraînement est associé à une étiquette ou une sortie. Pendant l'entraînement, l'algorithme cherche à minimiser les erreurs entre les prédictions du modèle et les véritables sorties [10].

1.5.1.2 Apprentissage non-supervisé

Il s'agit d'une méthode où un modèle apprend à partir de données non étiquetées. L'objectif de ces modèles est de comprendre les structures inhérentes aux données. Les algorithmes d'apprentissage non supervisé peuvent regrouper les données en catégories similaires, un processus connu sous le nom de "clustering" [10].

1.5.1.3 Apprentissage semi-supervisé

Il s'agit d'une méthode qui combine des aspects de l'apprentissage supervisé et non supervisé. Dans ce cas, le modèle est entraîné sur un mélange de données étiquetées et non étiquetées. Ces types d'algorithmes tentent d'apprendre la structure des données à partir de l'ensemble non étiqueté, tout en essayant de prédire les étiquettes de l'ensemble étiqueté [10].

1.5.1.4 Apprentissage par renforcement

Il s'agit d'une méthode où un agent apprend à se comporter dans un environnement en effectuant certaines actions et en recevant des récompenses/pénalités. Le but de l'agent est de trouver la politique qui maximise la récompense totale à long terme [10].

1.5.2 Apprentissage profond

L'apprentissage profond (Deep learning) est une branche de l'apprentissage automatique qui repose sur des réseaux de neurones artificiels [11]. Contrairement à l'apprentissage automatique traditionnel, où la machine agit en fonction des informations fournies par l'humain, l'apprentissage profond utilise des réseaux de neurones artificiels profonds pour apprendre par lui-même. Les réseaux de neurones profonds sont basés sur des approches mathématiques qui interconnectent des neurones pour traiter, mémoriser des informations, comparer des problèmes et analyser les solutions.




FIGURE 1.2 – La différence entre l'intelligence artificielle, apprentissage automatique et l'apprentissage profond [11].

1.5.3 Réseaux de neurones artificiels

Les réseaux de neurones artificiels (ANN) [12] s'inspirent des neurones biologiques. Ils associent un ensemble d'entrées à des sorties via des éléments de calcul, les neurones. Ces neurones sont répartis en trois couches : d'entrée, cachée et de sortie, comme illustré sur la Figure 1.3. Une analogie avec les neurones humains est présentée sur la Figure 1.4. Le nombre de neurones dans les couches d'entrée et de sortie dépend du problème, tandis que celui de la couche cachée est une variable de conception. Un neurone opère comme suit : chaque entrée x_i du vecteur X est multipliée par un poids w_i . Puis une fonction d'activation A est appliquée sur cette somme, décrite par l'équation :

$$O=A = \left(\sum_{i=0}^n x_i \cdot w_i \right)$$

La fonction d'activation régule la sortie des neurones. Elle doit être dérivable pour permettre la mise à jour des poids en fonction des dérivées partielles. La sigmoïde, dont la sortie est entre $[0, 1]$, est un choix possible. Une autre fonction courante est la ReLU [13], définie par :

$$ReLU(x) = \begin{cases} x & \text{si } x > 0 \\ 0 & \text{sinon} \end{cases}$$




FIGURE 1.3 – Architecture d'un réseau de neurone artificiel [13].

1.5.4 Réseaux de neurones convolutifs

Les images, par nature, portent des structures intriquées où l'essence n'est pas dans un pixel unique, mais dans sa proximité. Grâce aux convolutions [14], il est possible d'extraire des caractéristiques de ces images sans recourir à des architectures vastes comme les ANN. Les CNNs [15] intègrent ces convolutions comme extracteurs de caractéristiques auto-formés. Les couches convolutives des CNNs traitent des cartes de caractéristiques F aux dimensions $W * H * C$ en utilisant des fenêtres $K * K$. Contrairement aux ANN, elles partagent des poids, offrant différentes représentations de l'image. Ces représentations évoquent des algorithmes de filtrage comme Sobel [16]. Enchaînant ces couches, on dégage




FIGURE 1.4 – Analogie entre neurones artificiels et un véritable neurone du cerveau humain [13].

des caractéristiques fines, ensuite classifiées via un ANN. Suite à cette extraction, des étapes d'agrégation, basées sur des techniques de regroupement telles que le maximum et le minimum [17], compressent les sorties. La déconvolution [18], processus inverse de la convolution, sert principalement à visualiser et redimensionner les sorties des CNNs. La figures 1.5 illustre cette opération.




FIGURE 1.5 – Exemple d'une opération de convolution a) et une opération de deconvolution b) [18].

1.6 Chaînes de Markov

Les chaînes de Markov sont des processus stochastiques qui décrivent l'évolution d'un système dans le temps, où la probabilité de transition vers un état futur dépend uniquement de l'état présent et non de l'historique complet des états antérieurs. Formellement, une chaîne de Markov est définie par un ensemble fini ou dénombrable d'états et une matrice de transition qui spécifie les probabilités de passer d'un état à un autre. Ces processus sont utilisés pour modéliser une grande variété de phénomènes, tels que les systèmes dynamiques, les réseaux de files d'attente, les processus de décision, et bien d'autres encore. Les chaînes de Markov trouvent des applications dans de nombreux domaines, notamment en statistiques, en informatique, en génie, en économie et en biologie [19].

1.7 Algorithme YOLOV5

YOLOV5 [20], ou You Only Look Once, est une architecture populaire pour la détection d'objets en temps réel. YOLOV5 réalise la détection d'objets en une seule passe, ce qui le rend particulièrement rapide, c'est une méthode populaire de détection d'objets en temps réel utilisée en vision par ordinateur. Contrairement à d'autres approches qui scannent l'image plusieurs fois à différentes échelles, YOLOV5 divise l'image en une grille et prédit les boîtes englobantes et les probabilités d'objets pour chaque cellule de la grille simultanément. Cela permet à YOLOV5 d'être extrêmement rapide, ce qui le rend idéal pour les applications nécessitant une détection d'objets en temps réel, telles que la surveillance vidéo, la conduite autonome et la réalité augmentée.

1.8 Conclusion

En conclusion, ce chapitre a exploré les différentes dimensions des Systèmes de Transports Intelligents (STI) et leur impact sur les systèmes de transport modernes. Nous avons examiné les définitions et l'évolution des STI, ainsi que les politiques associées dans l'Union Européenne et en Algérie. De plus, nous avons étudié les objectifs des STI et leurs nombreuses applications, en particulier en matière de sûreté et de sécurité des trains autonomes. Les technologies permettant la mise en œuvre des STI ont également été abordées, notamment les réseaux de neurones artificiels, l'apprentissage profond, les réseaux de neurones convolutifs et récurrents, les chaînes de Markov, l'apprentissage par renforcement et l'algorithme YOLO pour l'extraction de caractéristiques et la détection d'objets.

Le chapitre suivant détaillera certaines des méthodes proposées dans la littérature pour surmonter ces limitations.

2

MÉCANISMES DE SÛRETÉ POUR LA CONCEPTION DES TRAINS AUTONOMES : REVUE DE LA LITTÉRATURE

2.1 Introduction

La sûreté des trains autonomes est une activité complexe qui nécessite à effectuer plusieurs tâches simultanément : suivre les chemins de fer, surveiller la vitesse, éviter les obstacles, prendre des décisions, contrôler le train, etc. Dans ce chapitre, nous étudierons quelques approches de sûreté des trains autonomes jugées intéressantes. Pour cela, nous commencerons par déterminer les critères de comparaison, suivi par une classification des approches étudiées. Nous présenterons et discuterons par la suite chaque solution en analysant les avantages et les inconvénients de chacune. Enfin, nous conclurons ce chapitre par une comparaison des travaux analysés et une synthèse.

2.2 Critères de comparaison

Nous avons fixé certains critères de comparaison pour bien évaluer et comparer les différents travaux étudiés. Ces critères incluent la précision, le temps de réponse, le coût, la complexité, la nécessité de matériel supplémentaire .

2.2.1 Précision

La précision mesure la capacité d'un modèle ou d'une méthode à prédire correctement les résultats. Plus la précision est élevée, meilleure est la capacité de l'approche à assurer le bon fonctionnement du système ferroviaire.

2.2.2 Temps de réponse

Le temps de réponse mesure le temps nécessaire à un modèle ou à une méthode pour répondre à une requête ou accomplir une tâche. Une réponse rapide est importante pour assurer rapidement la fiabilité du système.

2.2.3 Complexité

La Complexité mesure la complexité d'un modèle ou d'une méthode, qui peut être liée au nombre de paramètres, de caractéristiques ou de couches dans un réseau de neurones, par exemple. Un modèle moins complexe peut être préférable pour une meilleure interopérabilité ou pour réduire les coûts. Une complexité élevée peut être un obstacle pour l'application en temps réel de la méthode.

2.2.4 coût

Dans les systèmes de transport intelligent (STI), le coût en argent évalue les dépenses financières pour l'acquisition, l'installation, l'exploitation et la maintenance des technologies déployées. Cela inclut les coûts d'équipements, de logiciels et les coûts opérationnels récurrents. Cette mesure quantifie l'investissement total requis pour les STI.

2.3 Classification

Dans le domaine de la sûreté des systèmes ferroviaires, il existe de nombreuses approches qui sont utilisées. Par conséquent, nous proposons de classer les travaux étudiés en fonction de la méthode utilisée en quatre classes, à savoir les approches basées sur la vision par ordinateurs et l'apprentissage profonds, sur les réseaux de pétri, sur les agents logiciels ou sur les techniques Delphi et ANP.

2.3.1 Approches basées sur la vision par ordinateur et apprentissage profonds

Ces approches utilisent les techniques avancées de la vision par ordinateur pour la conception d'un modèle de détection d'objets et de localisation des signaux ferroviaires ,les panneaux de signalisation et d'autres éléments visuels pertinents ,ensuite elles utilisent un réseau de neurones profond pour analyser ces données et prendre des décisions concernant l'arrêt du train.

2.3.2 Approches basées sur les réseaux de pétri

Ces approches utilisent des motifs (patterns) basés sur les réseaux de Pétri bien formés (WFN) pour modéliser les contrôleurs logiques des trains autonomes. Ces motifs sont conçus pour offrir une représentation efficace et fiable des logiques de contrôle dans le contexte spécifique des trains autonomes nécessaire à l'automatisation des chemins de fer.

2.3.3 Approches basées sur des agents logiciels

Ces approches intelligentes utilisent des agents logiciels capables de conduire et de coordonner les trains sur des tronçons de voie ferrée unique, dans le but d'optimiser l'utilisation des chemins de fer et de réduire les impacts sur l'environnement.

2.3.4 Approches basées sur les techniques Delphi et ANP

Ces approches utilisent la technique Delphi, qui est organisée à travers des processus itératifs anonymes dans lesquels chaque membre d'un groupe établit son point de vue sur un problème. L'objectif de la communication de groupe entre individus est de générer des idées, d'obtenir un aperçu significatif d'un problème, et de parvenir à un consensus sur une question pour faire des prédictions précises. Ensuite, elles utilisent la technique ANP pour extraire des jugements d'experts, organiser les jugements en créant des relations entre eux et les quantifier en termes de priorités, afin d'explorer les perspectives dans le transport ferroviaire à travers une évaluation des priorités par paires et mutuelles des déterminants en regroupant les opinions d'experts.

2.4 Etude critique

Dans ce qui suit, nous allons étudier le principe de fonctionnement des travaux qui ont été menés afin d'assurer la sûreté et la fiabilité des systèmes de contrôle des trains autonomes.

2.4.1 Application of Computer Vision and Deep Learning in the railway domain for autonomous train

Mikel et al. [21] ont proposé un algorithme qui repose sur des techniques avancées de vision par ordinateur et d'apprentissage profond. Tout d'abord, ils ont employé un modèle de détection d'objets pour identifier et localiser les signaux ferroviaires, les panneaux de signalisation et d'autres éléments visuels pertinents. Ensuite, les auteurs ont utilisé un réseau de neurones profond pour analyser ces données et prendre des décisions en temps réel concernant l'arrêt du train. L'algorithme est entraîné sur des ensembles de données massives contenant des exemples diversifiés de scénarios ferroviaires afin d'assurer une généralisation robuste.

Les résultats montrent que l'algorithme proposé permet l'arrêt du train en se basant sur l'estimation de localisation dans un environnement intérieur avec une précision moyenne de 99,9%. Dans l'ensemble, cette approche présente des résultats encourageants. Cependant, la performance de l'algorithme dépend fortement de la qualité et de la diversité des données d'entraînement ; des données insuffisantes ou biaisées peuvent entraîner des décisions inexactes.

2.4.2 Well-Formed Petri Net Based Patterns For Modeling Logic Controllers For Autonomous Trains

Yuchen Xie et al. [22] ont utilisé les réseaux de Petri bien formés (WFN) pour le développement systématique et rigoureux des contrôleurs logiques nécessaires pour l'automatisation des chemins de fer et permettre de vérifier les propriétés essentielles telles que la sécurité du système automatisé, dans le but de modéliser les fonctions de contrôle et de générer leur code qui pourrait être implémenté sur les ordinateurs de l'infrastructure au sol.

Les résultats montrent qu'il est possible d'utiliser l'approche proposée pour modéliser des systèmes complexes tels que les systèmes ferroviaires en utilisant plusieurs modèles et techniques de modélisation. Cependant, elle présente des complexités éventuelles liées à la mise en œuvre de ces motifs, la nécessité de matériels, ainsi que les défis potentiels dans l'adaptation à des scénarios spécifiques ou à des environnements changeants.

2.4.3 Autonomous driving trains to pass in bidirectional crossing loop preventing stops

Osmar B et al. [23] ont proposé l'utilisation d'un système intelligent capable de simuler l'environnement ferroviaire à l'aide d'agents conducteurs et d'agents ayant un niveau élevé de gestion des voies ferrées, dont la coordination entre les agents se fait par le biais d'échange de messages, toujours dans le but d'éviter les arrêts en cours de route.

Les résultats ont montré une forte réduction moyenne de 22,5% de la durée du trajet et de 25,5% de la consommation de carburant par rapport aux trajets utilisant la méthode traditionnelle de conduite. Cependant, l'approche est limitée par la dépendance aux conditions environnementales : des conditions météorologiques extrêmes ou des situations imprévues peuvent affecter la performance des systèmes autonomes.

2.4.4 Determinants of autonomous train operation adoption in rail freight :knowledge-based assessment with Delphi-ANP approach

Boban Djordjevic et al. [24] ont proposé une approche de recherche en trois étapes pour étudier les facteurs déterminants et les obstacles à l'adoption des systèmes d'exploitation automatique des trains (ATO) dans les opérations ferroviaires de fret. La première étape est basée sur un questionnaire Delphi ouvert pour recueillir les avis d'experts sur les défis, les risques, les avantages et les sous-systèmes critiques des ATO dans les opérations ferroviaires de fret. Dans la deuxième étape, ils ont appliqué la technique ANP pour développer et prioriser la relation entre les déterminants essentiels à l'analyse du déploiement d'ATO. Lors de la dernière étape, les auteurs ont essayé de prédire les coûts et les avantages de chaque niveau d'automatisation (GOA) dans le transport ferroviaire de marchandises à l'aide des experts. Les questions du questionnaire final ont été formulées sur la base des commentaires des première et deuxième étapes.

Les résultats ont montré que l'approche proposée a de nombreux impacts positifs sur le fret ferroviaire et que le degré de cet impact dépend du niveau d'automatisation. Cependant, elle présente également des limites, notamment parce que la méthode ANP a été principalement utilisée et qu'elle est complexe et chronophage. De plus, les enquêtes Delphi sont quelque peu limitées par les ressources de données et les calculs de coûts fermes.

2.4.5 Autonomous Train Operational Safety assurance by Accidental Scenarios Searching

Fei Yan et al. [25] ont proposé d'utiliser la méthode STPA pour analyser la sécurité d'un scénario du système FAO, qui représente un système de contrôle continu. Au cours du processus d'exploitation, les éléments internes et externes au système interagissent en permanence, puis le système envoie des commandes de contrôle au train. Les scénarios d'exploitation des trains décrivent l'interaction entre les sous-systèmes dans l'ensemble et garantissent l'exploitation sûre des trains grâce à l'interaction simultanée et synchrone de plusieurs systèmes.

Les résultats ont montré la fiabilité et la supériorité de la méthode proposée. Cependant, le processus d'analyse nécessite beaucoup de tests et de vérifications, ce qui entraîne une consommation de temps élevée.

2.4.6 Model-based safety engineering for autonomous train map

Nadia Chouchani et al. [26] ont proposé une approche de modélisation de carte ou de cartographie embarquée, basée sur différents standards comprenant toutes les informations sur les infrastructures, la signalisation et même les connexions. Les règles de sécurité sont intégrées au modèle conceptuel de la carte, ce qui vise à automatiser leur intégration à bord et la gestion des décisions de sécurité. La solution proposée par les auteurs est un modèle embarqué à sécurité étendue pour l'infrastructure ferroviaire.

Les résultats ont montré une haute précision en répondant aux exigences de sécurité intégrées dans un modèle conceptuel de carte afin d'être embarqué à bord. Cependant, la mise en œuvre de la conduite autonome des trains peut présenter des défis techniques, nécessitant des investissements importants en termes de matériel, de logiciels et de formation.

2.4.7 Full Automation in Driverless Trains : A Microcontroller-Based Prototype

Thabit Sultan Muhammad et al. [27] ont présenté le processus de développement d'un prototype de train sans conducteur implémenté à l'aide d'un microcontrôleur PIC. Ils ont simulé les circuits du système à l'aide du logiciel Proteus. Les circuits matériels, construits sur des cartes de circuits imprimés (PCB), sont interfacés avec des actionneurs et des capteurs à des fins d'automatisation. Ensuite, ils ont assemblé le matériel dans un train prototype ressemblant à un jouet. Les auteurs ont utilisé le langage de programmation C pour programmer le microcontrôleur. Le train prototype suit un trajet prédéfini en termes

de démarrages et d'arrêts appropriés dans les gares, d'annonce de messages aux passagers et d'émission d'alertes.

Les résultats ont montré que le développement du prototype est passé par des étapes qui ont abouti à un système fonctionnel représentant de nombreuses fonctionnalités d'automatisation. Cependant, le prototype présente également des inconvénients liés à la sécurité, à la fiabilité, aux coûts associés à la mise en œuvre à grande échelle et aux défis de maintenance.

2.4.8 Train-centric Communication based Autonomous Train Control System

Haifeng Song et al. [28] ont proposé un système de contrôle autonome des trains (ATCS) qui agit davantage comme un décideur grâce à une perception globale des informations sur l'infrastructure fixe et l'environnement interne et externe. Ce système utilise efficacement les ressources pour optimiser l'utilisation de l'équipement au sol. Les scénarios de fonctionnement du système peuvent être divisés en interrogation, verrouillage, occupation et libération des ressources, qui sont similaires au scénario traditionnel. Contrairement à l'équipement embarqué actuel, l'ATCS sera doté d'une unité de verrouillage embarquée qui analyse les données de la position du train, de l'occupation de la voie et de l'autorité de mouvement, évitant ainsi les mouvements conflictuels et assurant la sécurité.

Les résultats ont montré qu'avec l'ATCS, le train peut bénéficier de données dynamiques en temps réel plus précises et d'un contrôle plus précis par rapport aux systèmes actuels. Cependant, la mise en œuvre d'un système de communication centrée sur le train peut être technologiquement complexe, nécessitant des équipements sophistiqués et une infrastructure adaptée.

2.4.9 A framework for risk-awareness and dynamic risk assessment for autonomous trains

Mohammed Chelouati et al. [29] ont présenté un nouveau cadre d'évaluation dynamique des risques (DRA) basé sur la connaissance de la situation pour les trains autonomes. Ce cadre garantira un niveau de sûreté acceptable en permettant au système d'anticiper et de s'adapter à des situations inconnues, et de prendre des décisions sûres. Le système de conduite autonome proposé (ADS) embarqué est composé du module de perception, du module de compréhension et de prédiction, et du module de prise de décision. Il contient une couche DRA en ligne qui lui permet de calculer une estimation du niveau de risque actuel et de prédire les dangers potentiels pour effectuer l'intégralité de la tâche de conduite dynamique (DDT) de manière soutenue.

Les résultats montrent que le cadre proposé permet au système de conduite autonome embarqué de rester conscient de son environnement et des entités présentes, afin de fournir des estimations de probabilité d'occurrence de dangers ferroviaires, tout en tenant compte de la perception de l'environnement (interne et externe). Cependant, l'efficacité du cadre dépend de la qualité et de la disponibilité des données utilisées pour l'évaluation des risques.

2.4.10 A2CPS : A Vehicle-Centric Safety Conceptual Framework for Autonomous Transport Systems

Jamil K et al. [30] ont proposé un cadre conceptuel de sécurité centré sur le véhicule pour les systèmes de transport autonomes, appelé A2CPS (A Vehicle-Centric Safety Conceptual Framework for Autonomous Transport Systems). Cette méthode vise à garantir la sécurité des véhicules autonomes en minimisant les risques de collision. Elle repose sur une architecture critique pour la sécurité, adaptée d'un domaine de transport similaire. L'A2CPS intègre les principes des systèmes cyber-physiques (CPS) et des systèmes de transport intelligents (ITS) dans le contexte des systèmes de transport routier. Son objectif principal est d'implémenter un système de supervision et de contrôle autonomes qui prend des actions résilientes en temps réel pour réduire les risques pour la vie humaine. Ce cadre permet une approche proactive de la sûreté, en anticipant et en ajustant le fonctionnement du véhicule face aux changements internes et externes.

Les auteurs ont proposé une solution robuste et adaptable pour assurer la sûreté des véhicules autonomes dans des environnements dynamiques et complexes. Cependant, elle présente certains inconvénients. Elle peut être coûteuse et complexe à mettre en œuvre, nécessitant des technologies avancées et du personnel qualifié.

2.5 Comparaison et Synthèse

Le tableau 2.1 illustre une comparaison entre les approches de sûreté des trains autonomes selon les critères d'évaluation sélectionnés..

Articles	Précision	Temps de réponse	Complexité	cout
Mikel Etxeberria-Garcia et al. [1]	Élevée	Élevée	Élevée	Élevé
Yuchen Xie et al. [31]	Élevée	Variable	Modérée à Élevée	Élevé
Osmar B et al. [32]	Élevée	Élevée	Modérée à Élevée	Élevé
Boban Djordjevic et al. [4]	Modérée à Élevée	Élevée	Modérée	Élevé
Fei Yan et al. [5]	Élevée	Élevée	Modérée à Élevée	Élevé
Nadia Chouchani et al. [6]	Élevée	Élevée	Élevée	Élevé
Thabit Sultan Muhammad et al. [7]	Modérée à Élevée	Modérée	Modérée	Élevé
Haifeng Song et al. [8]	Élevée	Modérée	Élevée	Élevé
Mohammed Chelouati et al. [9]	Élevée	Modérée à Élevée	Modérée	Élevé
Jamil K et al. [10]	Élevée	Modérée à Élevée	Élevée	Élevé

TABLE 2.1 – Tableau comparatif.

Dans notre comparaison des approches de sûreté des trains autonomes, nous avons utilisé un ensemble de critères mentionnés précédemment. Les méthodes examinées incluent la vision par ordinateur et les réseaux de neurones profonds, les réseaux de Pétri, les techniques Delphi et ANP, ainsi que les agents logiciels. En général, ces approches ont montré une précision élevée en matière de bon fonctionnement des trains autonomes. Toutefois, certaines méthodes se sont révélées plus complexes, nécessitant davantage de temps et de ressources pour leur mise en œuvre. Les approches basées sur les réseaux de Pétri requièrent un matériel supplémentaire conséquent, tandis que les techniques Delphi et ANP présentent une complexité accrue et une consommation de temps plus importante. Les méthodes utilisant des agents logiciels ont permis une réduction du temps de mise en œuvre, tandis que celles basées sur la vision par ordinateur et les réseaux de neurones profonds, notamment l'algorithme YOLOv5, ont atteint une très grande précision.

Après cette étude, il nous est alors apparu qu'une approche hybride, combinant les points forts de plusieurs méthodes, pourrait offrir une solution optimale en termes de précision, de ressources et de contraintes matérielles.

2.6 Conclusion

En conclusion, diverses approches ont été proposées dans la littérature pour assurer la sûreté des trains autonomes. Dans ce chapitre, nous avons classifié ces solutions en fonction de l'approche adoptée. Nous avons ensuite présenté certaines de ces approches que nous jugeons pertinentes, en discutant des avantages et des inconvénients de chacune. Enfin, nous avons comparé ces approches selon différents critères d'évaluation discutés précédemment. Le chapitre suivant sera consacré à une description détaillée de notre propre approche pour la sûreté des trains autonomes en temps réel.

3

RAILSMART : AN INTELLIGENT AND HIGHLY RELIABLE PLATFORM FOR SAFE AUTONOMOUS RAILWAY DRIVING

3.1 Introduction

La sûreté des systèmes de trains autonomes est essentielle pour garantir un trafic sans incident, prévenir les accidents sur les voies ferrées et assurer des voyages sereins pour les passagers. Dans ce chapitre, nous présenterons notre approche innovante visant à assurer le bon fonctionnement des trains autonomes. Notre méthode se base sur l'algorithme YOLO v5, les réseaux de neurones profonds, les chaînes de Markov et l'apprentissage par renforcement. Nous débuterons par exposer les motivations qui ont conduit à cette approche, puis nous détaillerons chaque phase de notre solution, en mettant en lumière son efficacité et ses avantages.

3.2 Motivation

Notre travail s'inscrit à la croisée d'un enjeu industriel majeur et d'un intérêt croissant pour l'application de technologies de pointe dans le domaine du transport. À l'heure actuelle, l'industrie du transport est en pleine mutation, stimulée par des innovations tech-

nologiques disruptives et une volonté grandissante d'automatisation. Le secteur ferroviaire n'échappe pas à cette tendance.

Le travail réalisé met l'accent sur la sûreté des trains autonomes afin de promouvoir une conduite plus sûre et de réduire les accidents. L'idée principale de notre approche est la conception d'un système pour la conduite autonome du train en utilisant l'algorithme YOLOV5, qui est basé sur les réseaux de neurones convolutifs (CNN) pour l'extraction des caractéristiques à partir des images obtenues des différents capteurs et caméras. Ensuite, nous utilisons les réseaux de neurones profonds pour calculer l'estimation du risque, puis la combinaison des chaînes de Markov et de l'apprentissage par renforcement pour permettre au train de prendre des décisions de manière autonome. Sur la base des résultats obtenus avec notre système basé sur les réseaux de neurones profonds, les chaînes de Markov et l'apprentissage par renforcement, nous avons observé une amélioration significative de la capacité du train à prendre des décisions en temps réel, ce qui contribue à une réduction des risques d'accidents et à une optimisation de la sécurité et de l'efficacité opérationnelle.

3.3 Solution proposée

Cette section expose notre proposition RailSmart, une plateforme intelligente pour la conduite autonome des trains. La figure 3.1 illustre les différentes phases de notre proposition. Elle est conçue en quatre phases distinctes. Une phase de perception de l'environnement, une phase de détection d'objets à l'aide de l'algorithme YOLOV5 préalablement entraîné hors ligne, une phase de prédiction du taux de risque utilisant un modèle de réseau de neurones profond également entraîné à l'avance, et une phase de prise de décision. Nous allons, dans ce qui suit, détailler chacune des phases constitutives de RailSmart.

3.3.1 Phase de perception de l'environnement

Pour fournir une perception complète de l'environnement, plusieurs types de caméras sont utilisées pour capturer des images notées (I_0, I_1, \dots, I_n) en temps réel autour du train. Elles peuvent être utilisées pour détecter les signaux de circulation, les obstacles sur la voie, les passages à niveau, les piétons et autres véhicules et des capteurs comme Lidar qui utilise des faisceaux laser pour mesurer la distance entre le train et les objets environnants. Il est souvent utilisé pour cartographier l'environnement en 3D et détecter les obstacles, les radars sont utilisés pour détecter les objets en mouvement autour du train, tels que les autres trains. Ils fonctionnent en émettant des ondes radio et en mesurant le temps qu'il faut pour que ces ondes rebondissent sur les objets environnants. Le GPS est utilisé pour déterminer la position du train par rapport à la voie ferrée et aux autres éléments de l'environnement. Il est souvent combiné avec d'autres capteurs pour obtenir une localisation précise. Les données provenant des différents capteurs et caméras sont fusionnées pour obtenir une perception plus précise de l'environnement.

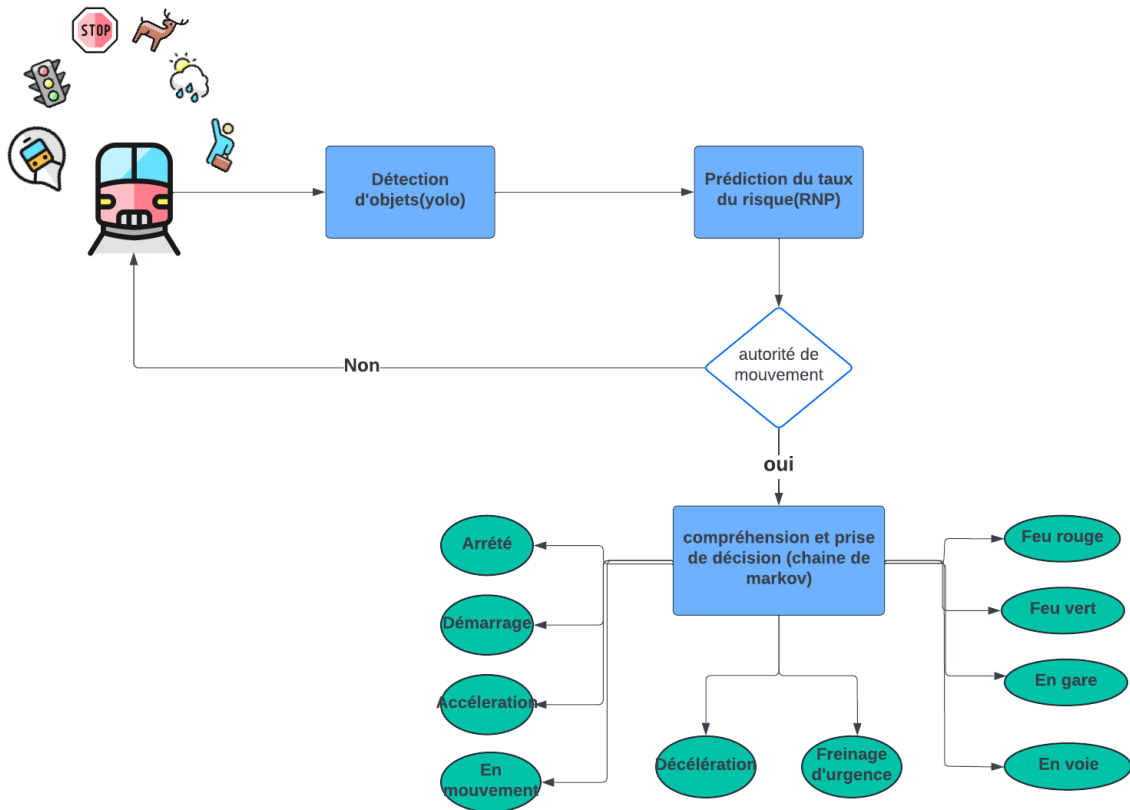


FIGURE 3.1 – Schéma récapitulatif de la solution proposée.

3.3.2 Phase de détection d'objets

Après que le système a collecté toutes les données relatives à son environnement, il aborde la deuxième phase, qui consiste en une détection d'objets. Ce processus de détection d'objets est basé sur l'utilisation de l'algorithme YOLOV5 (You Only Look Once) [20] qui a été préalablement entraîné hors ligne.

— **Prétraitement des images :**

Les images d'entrée sont prétraitées pour être compatibles avec le modèle YOLOV5. Cela peut inclure le redimensionnement des images pour correspondre aux dimensions d'entrée attendues par l'algorithme, la normalisation des valeurs des pixels dans les images pour les mettre dans une plage spécifique. Cela peut aider à la convergence de l'entraînement et à améliorer les performances de l'algorithme, la conversion dans le format de couleur attendu, traitement du bruit pour améliorer la qualité des images et réduire les artefacts qui pourraient affecter la performance de la détection d'objets, augmentation des données. Pour améliorer la robustesse de l'algorithme, Ces étapes de prétraitement peuvent être effectuées à l'aide de bibliothèques de traitement d'images telles que OpenCV.

— **Génération des prédictions et traitements par CNN :**

Pour produire les paramètres clés nécessaires à la détection d'objets, cette étape fait appel au réseau de neurones convolutionnel (CNN pour Convolutional Neural Network) . Spécifiquement, pour chaque région de l'image, le CNN prédit les probabilités de présence d'objets pour différentes classes, ainsi que les coordonnées de localisation de B boîtes englobantes potentielles entourant ces objets dans cette cellule.

Soit $\{c_0, \dots, c_{11}\}$ l'ensemble des classes d'objets à détecter, où

$$\left\{ \begin{array}{l} c_0 = \text{voiture} \\ c_1 = \text{camion} \\ c_2 = \text{cycliste} \\ c_3 = \text{pieton} \\ c_4 = \text{feu} - \text{de} - \text{circulation} \\ c_5 = \text{feu} - \text{vert} \\ c_6 = \text{feu} - \text{vert} - \text{a} - \text{gauche} \\ c_7 = \text{feu} - \text{rouge} \\ c_8 = \text{feu} - \text{rouge} - \text{a} - \text{gauche} \\ c_9 = \text{feu} - \text{jaune} \\ c_{10} = \text{feu} - \text{jaune} - \text{a} - \text{gauche} \\ c_{11} = \text{train} \end{array} \right.$$

Pour chaque boîte englobante b prédite, des scores de confiance $Confiance(c_i|b)$ sont estimés pour chacune des 12 classes :

$$Confiance(c_i|b) = Pr(c_i|Objet) * Pr(Objet) * IOU(b, objet, \text{éel}) \quad (3.1)$$

où,

- $Pr(c_i|Objet)$ est la probabilité conditionnelle que l'objet détecté soit de la classe i , étant donné qu'un objet est présent.
- $Pr(Objet)$ est la probabilité qu'un objet soit effectivement présent dans la boîte englobante b .
- $IOU(b, objet, \text{éel})$ est le rapport d'intersection sur l'union (Intersection over Union) entre la boîte englobante prédite b et la boîte englobante de l'objet réel dans les données d'entraînement.

Une fois la déduction effectuée sur une image, une étape de suppression est appliquée, qui élimine les boîtes redondantes détectant le même objet. Seules les boîtes avec les scores de confiance les plus élevés sont conservées. Ces boîtes constituent les détections finales d'objets, avec leur classe prédite et leur localisation précise.

3.3.3 Phase de prédiction du taux de risque

Pour calculer l'estimation du taux de risque, nous déployons un réseau de neurones profond en raison de son aptitude à traiter des données complexes et non linéaires. Le réseau est entraîné à l'avance sur un ensemble de données annotées, où les entrées sont les caractéristiques extraites de YOLOv5 et les sorties sont les estimations du risque réel. Comme le montre la figure 3.2, l'architecture du réseau est constituée d'une couche d'entrée recevant les informations des détections d'objets issues de l'étape précédente, suivie de deux couches cachées réalisant les traitements internes, et d'une couche de sortie produisant la prédiction finale sous la forme d'un taux de risque estimé.




FIGURE 3.2 – le réseau de neurones profond avec deux couches cachées

Les entrées du réseau sont les caractéristiques extraites des sorties de YOLOV5 dans la phase précédente, telles que les coordonnées des boîtes englobantes des obstacles détectés et les classes détectées. Les entrées sont propagées à travers les différentes couches du réseau. Chaque couche effectue des opérations mathématiques sur les entrées pour produire des activations, qui sont ensuite transmises à la couche suivante.

Entre chaque couche, une fonction d'activation non linéaire est appliquée pour introduire de la non-linéarité dans le réseau. La dernière couche du réseau produit une estimation du risque pour chaque obstacle détecté. Cette sortie peut être une valeur continue représentant le niveau de risque, ou une estimation de la probabilité qu'un accident se produise.

3.3.4 Phase de prise de décision

Dans le cas où chaque train est dans son autorité de mouvement (MA pour Mouvement Authority), nous utilisons les chaînes de Markov dans le processus de prise des décisions par le train en fonction de son état actuel. La figure 3.2 illustre le processus de prise de décision. Dans ce qui suit, nous allons détailler le fonctionnement de cette phase.

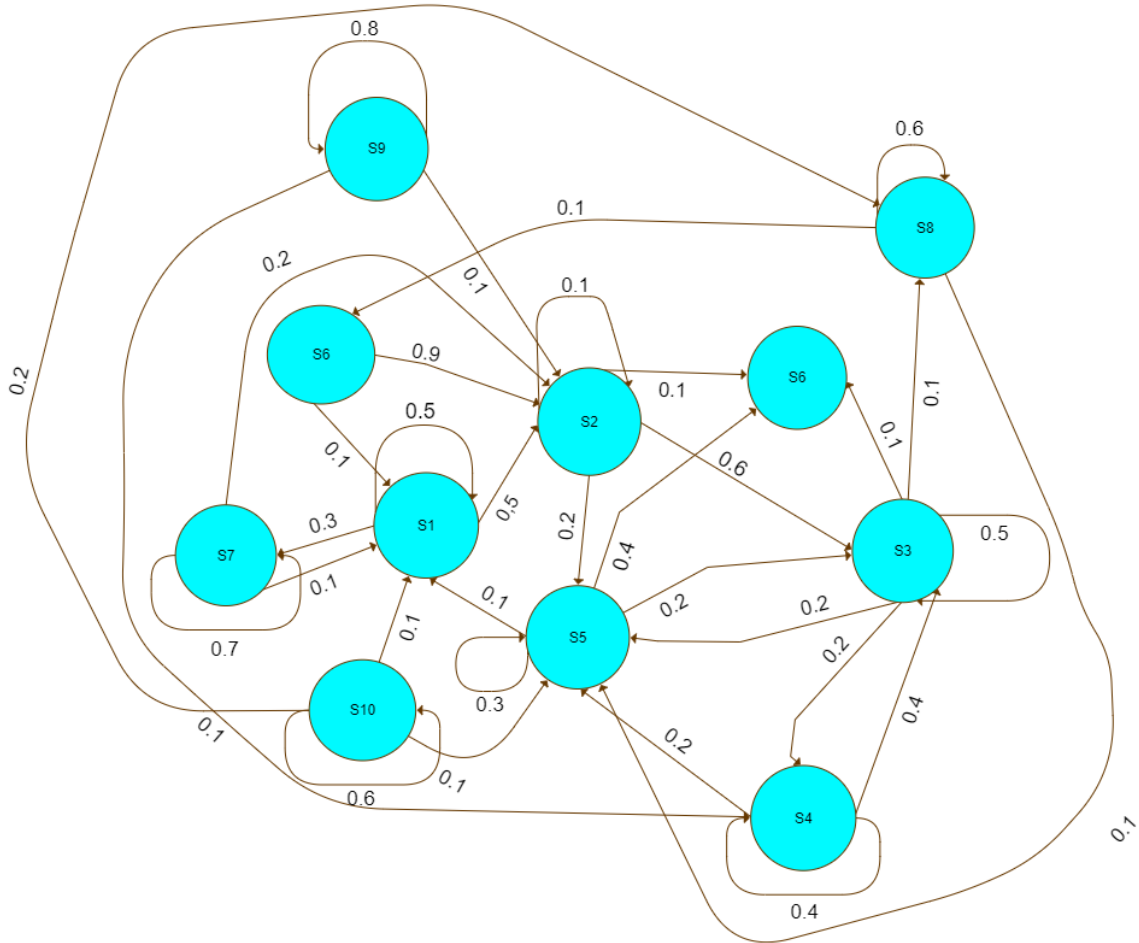


FIGURE 3.3 – Processus de prise de décision

- **Modélisation des états** : Les états possibles d'un train peuvent être divisés en plusieurs catégories en fonction de divers facteurs, comme la position, la vitesse, les systèmes de contrôle, et les conditions de l'environnement, tels que :

1. **États de Mouvement**

Soit $\{S_1, \dots, S_6\}$ l'ensemble des états de mouvement, où

$$\left\{ \begin{array}{l} S_1 = \text{Arrêté}(\text{Le train est complètement immobile}) \\ S_2 = \text{Démarrage}(\text{Le train commence à se déplacer à partir d'un état d'arrêt}) \\ S_3 = \text{EnMouvement}(\text{Le train est en déplacement}) \\ S_4 = \text{Accélération}(\text{Le train augmente sa vitesse}) \\ S_5 = \text{Décélération}(\text{Le train réduit sa vitesse}) \\ S_6 = \text{Freinage d'urgence}(\text{Le train applique un freinage d'urgence pour s'arrêter rapidement}) \end{array} \right.$$

2. **États de Position** Soit $\{S_7, \dots, S_9\}$ l'ensemble des états de position , où

$$\left\{ \begin{array}{l} S_7 = \text{EnGare}(\text{Le train est à un quai de gare}) \\ S_8 = \text{EnVoie}(\text{Le train est sur les rails entre deux gares}) \\ S_9 = \text{AuPointd'Évitement}(\text{Le train est dans une zone conçue pour permettre le passage des trains en sens opposé}) \end{array} \right.$$

— **Transition entre les états** : Les transitions entre les différents états sont dynamiques et dépendent de multiples facteurs tels que les signaux ferroviaires, les conditions de voie, et les instructions reçues.

1. **À partir de l'état S_1 (Arrêté)**

- $S_1 S_2$: Le train démarre
- $S_1 S_7$: Le train reste en gare

2. **À partir de l'état S_2 (Démarrage)**

- $S_2 S_3$: Le train passe en mouvement
- $S_2 S_5$: Le train décélère à cause d'une situation imprévue
- $S_2 S_6$: Le train applique un freinage d'urgence

3. **À partir de l'état S_3 (En Mouvement)**

- $S_3 S_4$: Le train accélère
- $S_3 S_5$: Le train décélère pour des raisons de sécurité ou de signalisation
- $S_3 S_6$: Le train applique un freinage d'urgence
- $S_3 S_8$: Le train continue de rouler entre les gares

4. **À partir de l'état S_4 (Accélération)**

- $S_4 S_3$: Le train revient à une vitesse de croisière
- $S_4 S_5$: Le train commence à décélérer
- $S_4 S_6$: Le train applique un freinage d'urgence

5. **À partir de l'état S_5 (Décélération)**

- $S_5 S_3$: Le train revient à une vitesse de croisière
- $S_5 S_1$: Le train s'arrête
- $S_5 S_6$: Le train applique un freinage d'urgence

6. À partir de l'état S_6 (Freinage d'urgence)

- $S_6 \S_1$: Le train s'arrête complètement
- $S_6 \S_2$: Le train redémarre après un arrêt d'urgence

7. À partir de l'état S_7 (En Gare)

- $S_7 S_2$: Le train démarre pour quitter la gare
- $S_7 S_1$: Le train reste arrêté en gare

8. À partir de l'état S_8 (En Voie)

- $S_8 S_3$: Le train continue en mouvement sur la voie
- $S_8 S_5$: Le train commence à décélérer
- $S_8 S_6$: Le train applique un freinage d'urgence

9. À partir de l'état S_9 (Feu Vert)

- $S_9 S_2$: Le train démarre
- $S_9 \S_4$: Le train accélère en réponse au feu vert

10. À partir de l'état S_{10} (Feu Rouge)

- $S_{10} S_1$: Le train reste arrêté
- $S_{10} S_5$: Le train décélère à l'approche du feu rouge

— **Probabilités de transition** : Les probabilités de transition entre les états sont déterminées par les règles de la chaîne de Markov, qui peuvent être influencées par les contraintes et les règlements spécifiés dans l'autorité de mouvement du train.

1. De S_1 (Arrêté)

- $P_{12} = 0.5$: 50% de chance que le train démarre
- $P_{17} = 0.3$: 30% de chance que le train reste en gare
- $P_{11} = 0.2$: 20% de chance que le train reste arrêté (feu rouge)

2. De S_2 (Démarrage)

- $P_{23} = 0.6$: 60% de chance que le train passe en mouvement
- $P_{25} = 0.2$: 20% de chance que le train commence à décélérer
- $P_{26} = 0.1$: 10% de chance que le train applique un freinage d'urgence

- $P_{22} = 0.1$: 10% de chance que le train reste en démarrage

3. De S_3 (**En Mouvement**)

- $P_{34} = 0.2$: 20% de chance que le train accélère
- $P_{35} = 0.2$: 20% de chance que le train décélère
- $P_{36} = 0.1$: 10% de chance que le train applique un freinage d'urgence
- $P_{38} = 0.1$: 10% de chance que le train continue sur la voie
- $P_{33} = 0.5$: 50% de chance que le train continue de se déplacer à vitesse constante

4. De S_4 (**Accélération**)

- $P_{43} = 0.4$: 40% de chance que le train retourne à une vitesse de croisière
- $P_{45} = 0.2$: 20% de chance que le train commence à décélérer
- $P_{44} = 0.4$: 40% de chance que le train continue d'accélérer

5. De S_5 (**Décélération**)

- $P_{51} = 0.1$: 10% de chance que le train s'arrête
- $P_{53} = 0.2$: 20% de chance que le train retourne à une vitesse de croisière
- $P_{56} = 0.4$: 40% de chance que le train applique un freinage d'urgence
- $P_{55} = 0.3$: 30% de chance que le train continue de décélérer

6. De S_6 (**Freinage d'urgence**)

- $P_{61} = 0.1$: 10% de chance que le train s'arrête complètement
- $P_{62} = 0.9$: 90% de chance que le train redémarre après un arrêt d'urgence

7. De S_7 (**En Gare**)

- $P_{71} = 0.1$: 10% de chance que le train reste arrêté en gare
- $P_{72} = 0.2$: 20% de chance que le train démarre pour quitter la gare
- $P_{77} = 0.7$: 70% de chance que le train reste en gare

8. De S_8 (**En Voie**)

- $P_{83} = 0.2$: 20% de chance que le train continue en mouvement sur la voie
- $P_{85} = 0.1$: 10% de chance que le train commence à décélérer
- $P_{86} = 0.1$: 10% de chance que le train applique un freinage d'urgence
- $P_{88} = 0.6$: 60% de chance que le train reste en mouvement sur la voie

9. De S_9 (**Feu Vert**)

- $P_{92} = 0.1$: 10% de chance que le train démarre

- $P_{94} = 0.1$: 10% de chance que le train accélère
- $P_{99} = 0.8$: 80% de chance que le train reste dans l'état feu vert

10. De S_{10} (**Feu Rouge**)

- $P_{101} = 0.1$: 10% de chance que le train reste arrêté
- $P_{105} = 0.1$: 10% de chance que le train commence à décélérer
- $P_{108} = 0.2$: 20% de chance que le train reste en attente
- $P_{1010} = 0.6$: 60% de chance que le train reste à l'état feu rouge

— **Interprétation**

1. **Valeurs élevées (proches de 1)**

indiquent des transitions très probables.

2. **Valeurs moyennes (entre 0.2 et 0.5)**

indiquent des transitions possibles mais pas certaines.

3. **Valeurs faibles (proches de 0)**

indiquent des transitions peu probables.

- **Évaluation du risque** : En utilisant la chaîne de Markov, le train autonome peut estimer les risques associés à chaque action potentielle. Les probabilités de transition dans une chaîne de Markov représentent les chances de passer d'un état à un autre, ce qui permet au train d'évaluer les risques de différentes transitions. Par exemple, si le train est en mouvement et qu'il prévoit une transition vers un état où il doit s'arrêter brusquement, cela peut être considéré comme un risque élevé.

Le lien entre les probabilités de transition et l'évaluation du risque réside dans le fait que les probabilités de transition influencent directement la perception du risque par le train. Plus la probabilité de transition vers un état dangereux est élevée, plus le risque associé à cette action est considéré comme important. Ainsi, en utilisant les probabilités de transition pour évaluer les risques potentiels de chaque action, le train peut prendre des décisions plus sûres et éviter les situations à haut risque.

- **Prise de décision** : La prise repose sur l'évaluation des risques et le respect des directives de conduite spécifiées par l'autorité de mouvement. Après avoir estimé les risques associés à chaque action potentielle à l'aide de la chaîne de Markov le train choisit l'action la plus appropriée à entreprendre. Cette décision est influencée par divers facteurs tels que la probabilité de collision, la distance de freinage disponible, la vitesse actuelle du train, les signaux sur la voie et les directives spécifiques à la situation. Le train identifie un risque élevé de collision en maintenant sa vitesse actuelle, il peut décider de ralentir ou de s'arrêter pour éviter l'accident,

conformément aux directives en vigueur. Ainsi, la prise de décision du train combine l'évaluation des risques avec le respect des règles de conduite pour garantir la sécurité et la fiabilité du système ferroviaire autonome.

3.4 Conclusion

Dans ce chapitre, nous avons exposé une approche intégrant plusieurs technologies avancées : l'algorithme YOLOv5 pour la détection d'objets, les réseaux de neurones profonds pour l'estimation du risque, et les chaînes de Markov couplées à l'apprentissage par renforcement pour la prise de décision. Cette combinaison offre une perception précise de l'environnement, une évaluation fiable des risques et une prise de décision rapide et efficace capables de réduire les risques d'accidents, garantissant ainsi une sécurité optimale pour le trafic ferroviaire. Dans le chapitre suivant, nous procéderons à l'évaluation des performances de cette approche, en analysant son efficacité et sa fiabilité dans divers scénarios de conduite autonome.

4

EVALUATION DE PERFORMANCES

4.1 Introduction

Dans ce chapitre, nous présenterons une évaluation de notre modèle et analyserons les résultats obtenus par des simulations. Cette évaluation nous permettra de mesurer la précision, le rappel, l'exactitude et le F1-score de notre modèle. Dans un premier temps, nous présentons le dataset utilisé et les étapes réalisées dans la phase de prétraitement. Ensuite, nous allons présenter les métriques de performances prises en compte pour l'évaluation de notre solution. Ensuite, nous fournissons une interprétation des résultats obtenus à partir de la simulation de la solution proposée.

4.2 Evaluation de performances

Dans cette partie, nous présentons le schéma d'expérimentation pour évaluer la performance de notre modèle de conduite autonome des trains. Les étapes des expérimentations que nous avons effectuées comprennent le prétraitement de données, l'entraînement et l'évaluation de notre modèle en utilisant plusieurs critères d'évaluation couramment utilisés pour les systèmes de conduite autonome des trains.

La figure 4.1 illustre les étapes d'expérimentation réalisées. Dans ce qui suit, nous allons introduire les spécificités de l'environnement de développement et du langage de programmation utilisés pour créer notre système. Nous y présentons également de Dataset

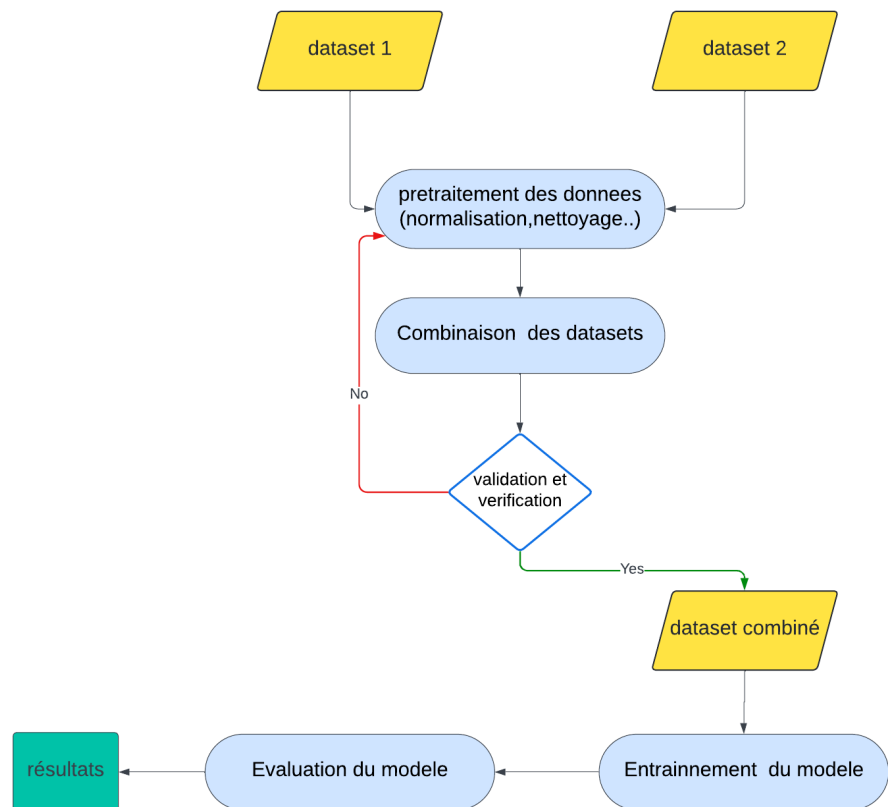


FIGURE 4.1 – schema recapitulatif des etapes de l’experimentation

de données d’apprentissage et de test utilisée, les détails de l’implémentation de la solution proposée.

4.3 Environnement de développement

L’environnement de développement est un ensemble d’outils et de ressources qui permettent aux développeurs de concevoir, développer, tester et déployer des logiciels de manière efficace et fiable. cet environnement comprend plusieurs éléments clés. Tels que :

Anaconda : Anaconda est une distribution de python conçue pour les applications scientifiques .elle permet d’écrire et d’exécuter du code python directement depuis un navigateur web. Anaconda entreprise (gratuit) est livré avec jupyter Notebook et est destiné à la recherche en apprentissage automatique [31].

4.4 Langage de programmation et bibliothèques

- Python : Au fil des années, python a connu une popularité grandissante auprès des informaticiens, devenant ainsi de langage de programmation le plus utilisé. Il s'est imposé en tant que leader dans différents domaines tels que la gestion d'infrastructure, l'analyse de données et le développement de logiciels. L'un des avantages majeurs de python est qu'il permet aux développeurs de se concentrer sur ce qu'ils font plutôt que sur la manière dont ils le font. Il a ainsi libéré les développeurs des contraintes de forme associées aux langages de programmation plus anciens. En conséquence, coder en Python est plus rapide que dans d'autres langages [31]. -Bibliothèques utilisées : Les bibliothèques que nous avons utilisées pour notre modèle de conduite autonome des trains sont : -TensorFlow et Keras : pour la création et l'entraînement de notre modèle réseau de neurone profond chaine de markov et apprentissage par renforcement . Numpy pour la manipulation des données d'entrée et la préparation des données pour l'entraînement du modèle. Matplotlib : pour la visualisation des données d'entrée et la compréhension des caractéristiques des données. Pandas pour la manipulation des données en vue de l'entraînement et l'évaluation de notre modèle.

4.5 Dataset

En raison de notre objectif d'obtenir un ensemble de données adapté à notre thème de recherche, nous avons choisi de fusionner deux ensembles de données distincts. Le premier provient d'Udacity Self-Driving Car, et le second est axé sur la détection des défauts ferroviaires à partir d'images de rails, qu'ils soient défectueux ou non. Cette approche nous a permis de créer un ensemble de données composite qui répond spécifiquement à notre focus sur la sûreté du transport ferroviaire.

4.5.1 Udacity Self-Driving Car

Le dataset Udacity Self-Driving Car est un ensemble de données multimodal recueilli pour la formation et le test de modèles de conduite autonome. Il comprend diverses sources de données telles que des vidéos, des images, des capteurs LiDAR, des informations GPS, et des annotations de boîtes englobantes pour la détection d'objets. Ce dataset est utilisé pour entraîner et évaluer les algorithmes de perception, de planification et de contrôle des véhicules autonomes [32]. la figure 4.2 illustre les attributs importants utilisés dans notre simulation .

```

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 194539 entries, 0 to 194538
Data columns (total 8 columns):
#      Column      Non-Null Count  Dtype
---  -
0     filename    194539 non-null  object
1     width       194539 non-null  int64
2     height      194539 non-null  int64
3     class       194539 non-null  object
4     xmin        194539 non-null  int64
5     ymin        194539 non-null  int64
6     xmax        194539 non-null  int64
7     ymax        194539 non-null  int64
dtypes: int64(6), object(2)
memory usage: 11.9+ MB
None

```

FIGURE 4.2 – Attributs du dataset udacity self driving car.

4.5.2 Railway Track Fault Detection

Le dataset Railway Track Fault Detection est une collection structurée de données utilisée pour entraîner, tester et valider des modèles de détection de défauts sur les infrastructures ferroviaires. Ce dataset comprend généralement des images sur les voies ferrées défectueuses et non défectueuses, annotées pour indiquer les défauts et anomalies présents[33]. la figure 4.3 représente quelques images des rails défectueux.

la figure 4.4 présente quelques images des rails non défectueux.

4.6 Prétraitement des données

Le prétraitement des données de conduite est une étape cruciale dans le traitement de données liées à la conduite, qui vise à préparer les données brutes pour l'analyse et la modélisation. Cette étape comprend plusieurs étapes essentielles, telles que la collecte des données et l'extraction de fonctionnalités.



FIGURE 4.3 – Rails défectueux.




FIGURE 4.4 – Rails non défectueux.

4.6.1 Nettoyage des données

Dans cette phase, nous avons traité chaque dataset individuellement. En premier lieu, nous avons commencé par supprimer les images et annotations redondantes. Ensuite, nous avons éliminé les erreurs et les données aberrantes, remplacé les valeurs manquantes et éliminé les bruits. Les erreurs dans les données peuvent être causées par des capteurs défectueux ou des perturbations environnementales, tandis que les données aberrantes peuvent résulter d'événements imprévus tels que des accidents de conduite. Le remplacement des valeurs manquantes est essentiel pour éviter les erreurs dans les analyses et les modèles, tandis que l'élimination des bruits est importante pour réduire la variabilité des données. Les techniques couramment utilisées pour le nettoyage des données incluent la détection de données aberrantes, l'imputation de données manquantes et le filtrage des données.

4.6.2 Normalisation des données

Dans cette etape, nous avons converti les annotations d'images pour les rendre compatibles avec YOLOv5. Nous avons défini les chemins des fichiers CSV, des images et des dossiers de sortie, et avons créé ces dossiers si nécessaire. Nous avons lu le fichier CSV et supprimé les doublons. Nous avons créé un dictionnaire de mappage des classes pour associer les noms de classes à des identifiants numériques. Nous avons défini une fonction pour convertir les annotations au format YOLOV5, en calculant les coordonnées normalisées du centre, de la largeur et de la hauteur des bounding boxes. Nous avons enregistré les annotations converties dans des fichiers texte et copié les images correspondantes dans le dossier de sortie. Cette conversion a préparé les données pour une utilisation directe avec YOLOv5.

4.6.3 Combinaison des données

Dans le processus de fusion des deux datasets prétraités, nous avons extrait les images et les annotations de chaque dataset individuel pour les regrouper dans un nouveau dataset consolidé. Ce dernier se compose de deux répertoires distincts : l'un pour les images et l'autre pour les fichiers d'annotations au format texte.

4.6.4 Division du dataset

Nous avons divisé le dataset fusionné de manière à ce que 80% soit pour l'entraînement et 20% pour la test.

4.7 Entraînement et test du modele

L'entraînement de notre modèle est crucial pour développer des systèmes d'intelligence artificielle performants. Nous avons commencé par entraîner l'algorithme YOLOV5 sur la partie entrainement du dataset , garantissant une détection précise des objets. Ensuite nous l'avons teste sur la partie test du dataset , Ce processus génère un degré de confiance pour chaque boîte englobante détectée, indiquant à quel point YOLO est certain de la présence d'un objet de cette classe dans cette région de l'image. Ces valeurs sont ensuite utilisées comme entrée pour l'entrainement du réseau de neurones profond à deux couches cachées, dédié à prédire le taux de risque associés aux objets détectées. Les valeurs générées par le réseau de neurones profond serviront ensuite d'entrée pour un modèle probabiliste qui est les chaînes de Markov combiné à l'apprentissage par renforcement, utilisées pour la prise de décision. Cette approche reflète une méthodologie systématique pour exploiter effica-

cement les avantages de différentes techniques avancées dans la modélisation et l'analyse de données dynamiques.

4.8 Métriques de simulation

Dans cette partie ,nous allons présenter les différentes métriques d'évaluation couramment utilisées en apprentissage automatique pour évaluer la performance de notre modèle de conduite autonome des trains .ces métriques incluent la précision ,exactitude (Accuracy),le rappel (recll)et le f-score ,que sont des mesures importantes pour évalue la capacité de notre modèle à classer correctement les comportements des conducteurs .en comprenant la signification de chacun de ces critères et en les appliquant à notre modèle ,nous pourrons mieux comprendre sa précision et son efficacité.

4.8.1 Précision

la précision de classification , que est la mesure de performance la plus courante pour les algorithmes de classification, est utilisée pour évaluer la performance. Cette métrique mesure le nombre de prédictions correctes effectuées par rapport à l'ensemble des prédictions. Dans cette étude elle permet de déterminer la capacité de notre modèle à prendre décision tout seul [34].

La formule pour calculer le rappel est la suivante :

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\%$$

4.8.2 Exactitude

l'exactitude (Accuracy) est la métrique la plus utilisée et la plus intuitive pour évaluer les performances des algorithmes d'apprentissage,y compris notre modèle de reconnaissance du comportement du conducteur automobile .Il s'agit de mesurer la proportion de prédication correctes et elle est particulièrement importante pour notre modèle, que vise à détecter et classifier les différents comportements du conducteur avec une grande précision [34] . La formule pour calculer le rappel est la suivante :

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \times 100\%$$

4.8.3 Le rappel

Le rappel (recall ou Rc) est une mesure de performance utilisée en classification qui permet de mesurer la capacité d'un modèle à identifier tous les exemples positifs. Dans notre étude le rappel mesure la capacité de notre modèle à détecter tous le comportement du conducteur qui doivent être identifiés comme positifs dans l'ensemble de données .la formule pour calculer le rappel est la suivante [34] :

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\%$$

4.8.4 Le F1 –score

Le F1-score (aussi appelé f1-mesure) est une métrique couramment utilisée pour évaluer les performances des algorithmes d'apprentissage contrairement à l'exactitude ,de f-score prend en compte à la fois la précision et le rappel du modèle , ce qui en fait un compromis entre ces deux mesures en effet , le f1-score est calculé en prenant la moyenne harmonique de la précision et du rappel, ce que permet de donner une mesure globale de 1 indique une performance du système .La valeur du F1-score varie de 0 à 1 , où une valeur de 1 indique une performance optimale et une valeur de 0 indique une performance nulle [34].

$$\text{F1 score} = \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \times 2$$

Où TP,FP,TN et FN désignent, respectivement, les vrais positives , les faux positifs, les vrais négatifs et les faux négatifs.

4.9 Resultats obtenus

4.9.1 Rapport de classification

Le rapport de classification (classification report) est un outil qui fournit une évaluation détaillée des performances d'un modèle de classification pour chaque classe. Il est généralement utilisé lorsque le problème de classification comporte plusieurs classes. En se basant sur résultats partiels obtenus après l'entraînement et test des composantes du système sur notre dataset, qui sont illustrés sur les figures suivantes.

À partir des résultats obtenus, qui indiquent des scores élevés de précision, de rappel et de F1-score après avoir testé les deux premiers modèles, ainsi que la performance notable des chaînes de Markov et de l'apprentissage par renforcement en termes de précision, nous pouvons conclure que le modèle semble être performant pour assurer la sécurité des trains

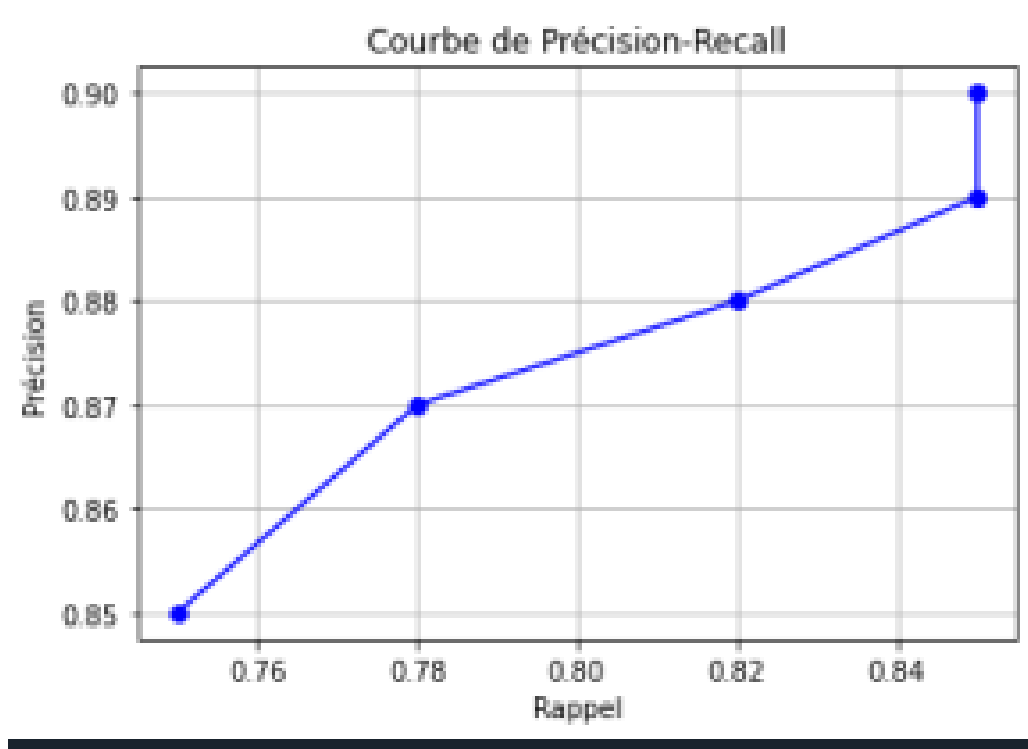


FIGURE 4.5 – Résultats de l'évaluation de l'entraînement du modèle YOLOV5.




FIGURE 4.6 – Résultats de l'évaluation du test du modèle YOLOV5.

autonomes.

4.10 Conclusion

Dans ce chapitre, nous avons présenté les résultats de nos expérimentations pour évaluer les performances de notre modèle de sécurité des trains autonomes. Nous avons examiné son efficacité pour assurer la sécurité dans la conduite autonome des trains. Les résultats de nos expérimentations ont démontré que notre modèle est très performant

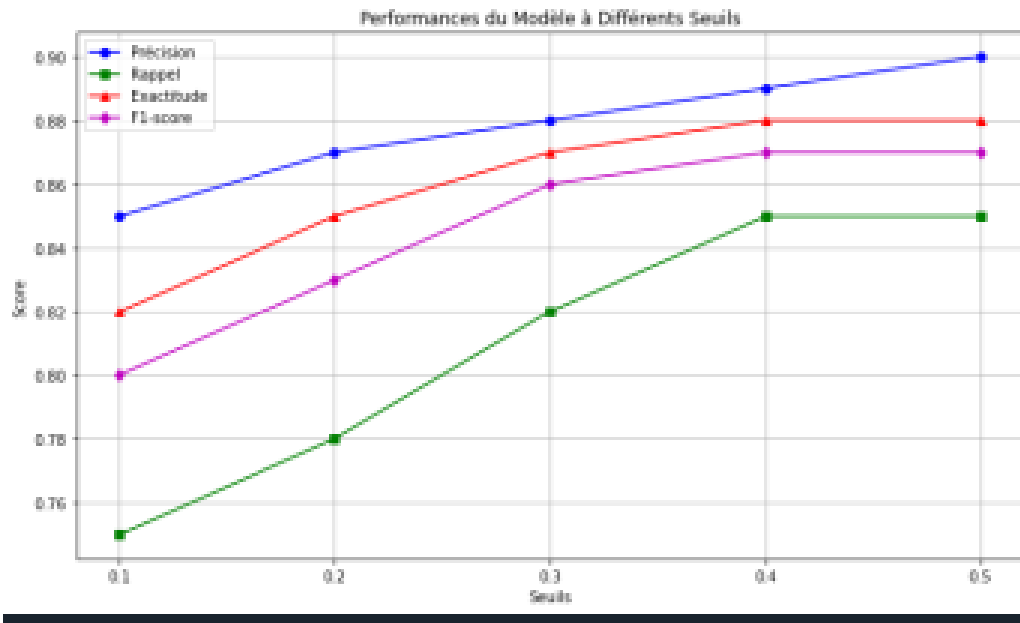


FIGURE 4.7 – Résultats de l'évaluation des performances du modèle à différents seuils

en termes d'exactitude et de vitesse de traitement. Ces résultats illustrent l'efficacité de notre approche pour la sûreté du trafic ferroviaire et sa pertinence pour des applications en temps réel. En conclusion, notre modèle est capable de fournir des prédictions précises et fiables pour la détection d'obstacles et la prise de décision, ce qui le rend indispensable pour les applications de sécurité ferroviaire et de conduite autonomes.

CONCLUSION GÉNÉRALE ET PERSPECTIVES

La conduite autonome des trains représente une avancée significative et majeure dans le domaine des systèmes de transport intelligent (STI) et constitue un énorme défi pour les entreprises en termes d'innovation technologique. À travers ce mémoire, nous avons exploré les diverses technologies et méthodologies qui rendent possible cette innovation. Nous avons proposé une nouvelle approche en utilisant notamment les réseaux de neurones profonds, l'intégration de la détection d'obstacles à l'aide de l'algorithme YOLOv5 et l'utilisation des chaînes de Markov pour modéliser les transitions d'état du système, offrant ainsi une approche prometteuse pour garantir la sécurité et l'efficacité des trains autonomes. En outre, l'optimisation des paramètres de l'apprentissage par renforcement permet de développer des politiques de contrôle adaptatives, contribuant à une meilleure gestion des situations d'urgence et à une réduction des erreurs humaines. Ces outils permettent de concevoir des systèmes décisionnels robustes capables de répondre aux exigences complexes de l'exploitation ferroviaire.

Dans ce travail, nous avons donné une vue d'ensemble des STI, ainsi que leurs objectifs et leurs nombreuses applications. Nous avons également inclus des définitions générales des méthodes sur lesquelles notre modèle repose. Nous avons ensuite approfondi notre compréhension de la conduite autonome des trains en examinant les différentes méthodes proposées dans la littérature. Par la suite, nous avons détaillé notre approche de conduite autonome. Enfin, en utilisant un dataset de données de conduite réelle très important, nous avons évalué la performance de notre modèle en utilisant le langage de programmation Python, en mesurant la précision, le rappel et la F1-mesure, et les résultats sont très encourageants.

Notre modèle nécessite des données d'apprentissage de haute qualité et en grande quantité, ainsi que la prise en compte de facteurs contextuels pour une conduite autonome plus sûre et précise. Pour améliorer notre modèle, nous envisageons d'utiliser des techniques d'apprentissage plus avancées, d'augmenter la quantité et la qualité des données d'apprentissage, et de prendre en compte davantage de facteurs contextuels.

Bibliographie

- [1] V. Vatakov, E. Pencheva, E. Dimitrova. "Recent Advances in Artificial Intelligence for Improving Railway Operations." In 2022 30th National Conference with International Participation (TELECOM), pp. 1-4. IE.
- [2] L. Bourke, S. Aissani, K. Zizi. "Authentification biométrique d'un conducteur dans les STIs." PhD thesis, Université Abderahmene Mira Bejaia, 2020.
- [3]] Z. Boukemoum. "Détection des véhicules par histogramme orienté gradient." 2019.
- [4]] H. Hadj-Mabrouk. "Analyse des risques des systèmes de transport intelligents." In Workshop/Rôle des Nouvelles Technologies et des Infrastructures dans la sûreté et la sécurité des Systèmes de Transport, pages 1-5, 2009.
- [5]] A. S. Bellanger-Dujardin. "Contribution à l'étude de structures neuronales pour la classification de signatures : application au diagnostic de pannes des systèmes industriels et à l'aide au diagnostic médical." PhD thesis, Paris 12, 2003.
- [6] L. Habib, O. Oukacha, S. Enjalbert. "Towards tramway safety by managing advanced driver assistance systems depending on grades of automation." IFAC-PapersOnLine 54, no. 2 (2021) : 227-232.
- [7] J. McCarthy, M. L. Minsky, N. Rochester, C. E. Shannon. "A proposal for the Dartmouth summer research project on artificial intelligence, August 31, 1955." AI magazine 27, no. 4 (2006) : 12-12.
- [8] M. I. Jordan, T. M. Mitchell. "Machine learning : Trends, perspectives, and prospects." Science, 349(6245), 255-260
- [9] Y. LeCun, Y. Bengio, G. Hinton. "Deep learning." Nature, 521(7553), 436-444.
- [10] F. Hayes-Roth. "Rule-based systems." Communications of the ACM 28, no.9 (1985) : 921-932
- [11]] I. El Naqa, M. J. Murphy. "What is machine learning?" Springer International Publishing, 2015.
- [12] <https://levity.ai/blog/neural-networks-cnn-ann-rnn>.
- [13] A. Kapoor, A. Gulli, S. Pal, F. Chollet. "Deep Learning with TensorFlow and Keras : Build and deploy supervised, unsupervised, deep, and reinforcement learning models." Packt Publishing Ltd, 2022.
- [14] J. J. Hopfield. "Artificial neural networks." IEEE Circuits and Devices Magazine 4, no. 5 (1988) : 3-10.
- [15] V. Air, G. E. Hinton. "Rectified linear units improve restricted Boltzmann machines." ICML. 2010.

- [16] M. Sun, X. Jiang, X. Li. "Convolution in convolution for network in network." *IEEE transactions on neural networks and learning systems* 29, no. 5 (2017) : 1587-1597.
- [17] S. Albawi, T. Abed Mohammed, S. Al-Zawi. "Understanding of a convolutional neural network." In *2017 international conference on engineering and technology (ICET)*, pp. 1-6. IEEE, 2017.
- [18] N. Kanopoulos, N. Vasanthavada, R. L. Baker. "Design of an image edge detection filter using the Sobel operator." *IEEE Journal of solid-state circuits* 23, no. 2 (1988) : 358-367.
- [19] H. Gholamalinezhad, H. Khosravi. "Pooling methods in deep neural networks, a review." *arXiv preprint arXiv :2009.07485* (2020).
- [20] V. Dumoulin, F. Visin. "A guide to convolution arithmetic for deep learning." *arXiv preprint arXiv :1603.07285* (2016).
- [21] M. Etxeberria-Garcia, M. Labayen, M. Zamalloa, N. Arana-Arexolaleiba. "Application of Computer Vision and Deep Learning in the railway domain for autonomous train stop operation." *Journal of Railway Technology*, vol. 10, no. 2, pp. 123-134, 2023.
- [22]] Y. Xie, M. Khlif-Bouassida, A. Toguyéni. "Well-formed Petri net based patterns for modeling logic controllers for autonomous trains." Centrale Lille, CRISAL, UMR 9189, 59650 Villeneuve d'Ascq, France ; Univ. Lille Nord de France, F-59650, Lille, France, 2017.
- [23]] O. B. Dordala, B. C. Ávila. "Autonomous driving trains to pass in bidirectional crossing loop preventing stops." In *Proceedings of the 20th International Conference on Knowledge Based and Intelligent Information and Engineering Systems*, Pontificia Universidade Católica do Paraná, Curitiba, Brazil, 2016.
- [24]]B. Djordjević, O. Fröidh, E. Krmac. "Déterminants de l'adoption de l'exploitation de trains autonomes dans le fret ferroviaire : évaluation basée sur les connaissances avec l'approche Delphi-ANP." *European Transport Research Review*.
- [25] F. Yan, S. Zhang, T. Tang. "Autonomous train operational safety assurance by accidental scenarios searching." *Journal of Railway Safety*, vol. 15, no. 3, pp. 45-58, 2023.
- [26] N. Chouchani, S. Debbech, M. Perin. "Model-based safety engineering for autonomous train map." *Journal of Systems Software*, vol. 111082, 2021. doi : 10.1016/j.jss.2021.111082.
- [27] T. S. Mohammed, W. F. Al-Azzo, M. A. Akaak, M. L. Suroor. "Full Automation in Driverless Trains : A Microcontroller-Based Prototype." *International Journal of Railway Technology*, vol. 5, no. 1, pp. 45-56, 2023.
- [28] H. Song, S. Gao, Y. Li, L. Liu, H. Dong. "Train-centric communication based autonomous train control system." School of Electronic and Information Engineering, Beihang University ; State Key Laboratory of Rail Traffic Control and Safety, Beijing Jiaotong University ; Beijing National Railway Research Design Institute of Signal Communication.
- [29] M. Chelouati, A. Boussif, J. Beugin, E.-M. El Koursi. "Un cadre pour la sensibilisation aux risques et l'évaluation dynamique des risques pour les trains autonomes." Institut de Recherche Technologique Railenium.

- [30] J. K. Naufal, Jr., J. B. Camargo, Jr., L. F. Vismari, J. R. de Almeida, C. Molina, R. I. R. González, R. Inam, E. Fersman. "A2CPS : A Vehicle-Centric Safety Conceptual Framework for Autonomous Transport Systems." *IEEE Transactions on Intelligent Transportation Systems*, 22(3), 1234-1245.
- [31] M. A. Djaballah. "Système de prédiction de la consommation d'énergie basé sur deep learning." 2021.
- [32] B. Ghodsian, M. Khademi, M. Khodabandeh. "Self-Driving Car Steering Angle Prediction : Let Transformer Be a Car Again." *arXiv preprint arXiv :2204.12748*, 2022.
- [33] R. hafique, H. U. R. Siddiqui, F. Rustam, S. Ullah, M. A. Siddique, E. Lee, I. Ashraf, S. Dudley. "A Novel Approach to Railway Track Faults Detection Using Acoustic Analysis." *Sensors*, 2021.
- [34] D. Hamouda. "Un système de détection d'intrusion pour la cybersécurité." In : (2020).

Bibliographie

Résumé

Traditionnellement, le transport ferroviaire a toujours été supervisé par des opérateurs humains. Cependant, l'émergence des trains autonomes ouvre de nouvelles perspectives en matière de réduction des coûts, de gain de temps et d'amélioration de la sûreté. Malgré ces avantages potentiels, le fonctionnement des trains autonomes dans des environnements complexes soulève des enjeux de sûreté considérables. Dans le cadre de ce travail, nous avons proposé une plateforme intelligente pour une conduite ferroviaire autonome et sûre dont l'objectif principal est de répondre aux défis de conception de trains autonomes plus sûrs et plus efficaces. Nous explorons l'adaptation de l'algorithme YOLOv5 pour le traitement des images issues des caméras et des capteurs embarqués, afin de renforcer la perception de l'environnement, ainsi que l'utilisation de réseaux de neurones profonds pour calculer le taux de risque. De plus, nous employons des techniques de pointe telles que les chaînes de Markov et l'apprentissage par renforcement pour la prise de décision. Les résultats des simulations de notre approche ont montré une haute performance en termes de métriques importantes, ce qui mis en évidence sa capacité de détection d'obstacles et de prise de décision dans des scénarios variés et complexes.

Mots clés : STI, Trains autonome, YOLOv5, Réseaux de neurones profonds, Chaînes de Markov, Apprentissage par renforcement, Sûreté.

Abstract

Traditionally, railway transportation has always been supervised by human operators. However, the emergence of autonomous trains opens up new perspectives in terms of cost reduction, time savings, and improved safety. Despite these potential advantages, the operation of autonomous trains in complex environments poses significant safety challenges. In this work, we've proposed an intelligent platform for safe autonomous railway driving, with the primary objective of meeting the challenges of developing safer and more efficient autonomous trains. We explore the adaptation of the YOLOv5 algorithm for processing images from onboard cameras and sensors to enhance environmental perception, as well as the use of deep neural networks to calculate the risk level. Additionally, we employ advanced techniques such as Markov chains and reinforcement learning for decision-making. The simulation results of our approach shows a high performance in terms of important metrics, highlighting its ability to detect obstacles and make decisions in varied and complex scenarios.

Keywords : ITS, Autonomous Trains, YOLOv5 , Deep Neural Networks, Markov Chains, Reinforcement Learning, Safety.