



وزارة البحث العلمي والتعليم العالي
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET
DE LA RECHERCHE SCIENTIFIQUE
جامعة عبد الحميد بن باديس مستغانم
Université Abdelhamid Ibn Badis Mostaganem
كلية العلوم و التكنولوجيا
Faculté des Sciences et de la Technologie
DEPARTEMENT DE GENIE ELECTRIQUE



N° d'ordre : M...../GE/2025

MEMOIRE

Présenté pour obtenir le diplôme de

MASTER EN AUTOMATIQUE

Spécialité : Automatique et informatique industrielle

Par

Par : DJAFER Ahmed

BELLEKHAL Mouley

Intitulé du sujet

Développement d'un système de détection intelligente pour véhicule autonome basé sur machine learning et la fusion de données

Soutenu le 25/05 / 2025 devant le jury composé de :

Président :	BERRADJA Khadidja	MCA	Université de Mostaganem
Examineur :	BENDANI Djazia	MAA	Université de Mostaganem
Rapporteur :	BENCHELLAL Amel	MCB	Université de Mostaganem
Co encadreur	BENAOUALI Mohamed	MAA	Université de Mostaganem

Année Universitaire 2024/2025



Dédicaces

Nous dédions ce travail avant tout à **Allah Tout-Puissant**, qui nous a accordé la patience, la force, et la volonté de mener à bien ce projet jusqu'à son terme.

Nous dédions également ce mémoire à **nos chers parents** : leur amour, leur soutien inconditionnel et leurs sacrifices quotidiens ont été notre source de motivation et de persévérance. Qu'Allah leur accorde santé, bonheur et longue vie.

À **nos familles**, pour leur encouragement constant, leur compréhension et leur présence rassurante dans les moments de doute comme dans les moments de réussite.

À **notre encadrante Madame BENCHELLAL Amel**, pour son suivi bienveillant, ses conseils pertinents et son accompagnement technique et moral tout au long de ce projet.

À **notre co-encadrant, Monsieur BENAOUALI Mohamed**, pour son engagement, son expertise et sa précieuse disponibilité.

À **tous les enseignants** de l'Université Abdelhamid Ibn Badis – Mostaganem, qui nous ont transmis leur savoir avec passion et rigueur.

Enfin, à **toutes les personnes** qui, de près ou de loin, ont contribué à la réalisation de ce projet, et notamment nos amis les plus proches qui nous ont soutenus moralement dans cette aventure, nous vous en sommes sincèrement reconnaissants.

Que ce travail soit le reflet de notre engagement et de notre reconnaissance envers tous ceux qui ont cru en nous.





Remercîment

Nous tenons à remercier sincèrement nos encadreurs : Madame BENCHELLAL Amel

et M. BENOUALI Mohamed d'avoir accepté de nous diriger

et pour tous les conseils et informations qu'ils

nous ont fournis.

Nous remercions les membres du jury pour cet honneur

qu'ils nous font en jugeant cette humble œuvre. Enfin, nous n'oublions pas nos enseignants

qui ont supervisé notre enseignement tout au long du cycle d'études, et

un grand merci également à tous ceux qui ont contribué

directement ou indirectement à l'aboutissement de ce travail.



Résumé

Le présent système a été développé dans le but de détecter divers types d'obstacles pouvant compromettre la sécurité de la conduite, notamment les irrégularités de la chaussée telles que les nids-de-poule, ainsi que les obstacles présents dans les zones de stationnement. La détection des nids-de-poule repose sur l'intégration de techniques d'intelligence artificielle, en particulier l'utilisation de classifieurs capables d'identifier automatiquement, à partir d'images la présence ou l'absence de telles anomalies. En ce qui concerne la détection des obstacles physiques en contexte de stationnement, une approche fondée sur la fusion de données issues de capteurs à ultrasons et d'un capteur infrarouge a été adoptée. Cette combinaison de capteurs permet une perception en temps réel de l'environnement immédiat du véhicule, offrant ainsi une meilleure précision et une plus grande fiabilité du système d'assistance au stationnement

Mots clés : Intelligence Artificielle, SVM, HOG, LBP, classification, capteur, fusion de données, conduite autonome, python

الملخص

يهدف النظام المطور في هذه الدراسة إلى كشف مختلف أنواع العوائق التي قد تُعرّض سلامة القيادة للخطر، وخصوصًا الشذوذات الموجودة على سطح الطريق مثل الحفر، إضافةً إلى العوائق الشائعة في بيئات مواقف السيارات. يعتمد كشف الحفر على دمج تقنيات الذكاء الاصطناعي، وخاصةً من خلال استخدام مصنّفات قادرة على التعرف تلقائيًا على وجود هذه الشذوذات أو عدمها اعتمادًا على تحليل الصور. أمّا بالنسبة لكشف العوائق الفيزيائية في سياق مواقف السيارات، فقد تم اعتماد منهجية دمج البيانات، وذلك من خلال الجمع بين قياسات حسّاسات الموجات فوق الصوتية وحسّاس الأشعة تحت الحمراء. تُمكن هذه البنية الحسية من الإدراك الفوري لمحيط المركبة المباشر، مما يُحسّن من دقة وموثوقية نظام المساعدة على الركن

الكلمات المفتاحية

الذكاء الاصطناعي، آلة المتجهات الداعمة (SVM)، واصفات HOG و LBP مستشعر، دمج البيانات، القيادة الذاتية

Abstract

The system developed in this study aims to detect various types of obstacles that may compromise driving safety, particularly road surface irregularities such as potholes, as well as obstacles commonly found in parking environments. Pothole detection is based on the integration of artificial intelligence techniques, specifically through the use of classifiers capable of automatically identifying the presence or absence of such anomalies from image analysis. For the detection of physical obstacles in parking contexts, a data fusion approach has been adopted, combining measurements from ultrasonic sensors and an infrared sensor. This sensor configuration enables real-time perception of the vehicle's immediate surroundings, thereby improving the accuracy and reliability of the parking assistance system.

Keywords: Artificial Intelligence, SVM, HOG, LBP, classification, sensor, data fusion, autonomous driving, Python.

Table de matière

Introduction générale :	13
Chapitre 1 : Véhicule Autonome	14
1.1. Introduction :	15
1.2. Historique de la voiture autonome :	15
1.2.1. Les prémices (1920 – 1980) : L'ère des prototypes expérimentaux	15
1.2.2. L'ère de la recherche universitaire et des défis militaires (1980 – 2010)	16
1.2.3. L'entrée des géants technologiques (2010 – 2020)	17
1.2.4. Période actuelle (2020 – 2025) : Vers l'autonomie totale ?	17
1.3. Généralités sur les véhicules autonomes :	17
1.3.1. Le degré d'autonomie d'un véhicule autonome :	18
1.4. Vue d'ensemble des technologies employées dans la conduite autonome	20
1.5. Les capteurs pour les systèmes intelligents d'assistance à la conduite	20
1.6. Capteur intelligent	26
1.6.1. Rôle des capteurs intelligents dans un VA	26
1.6.2. Combinaison des capteurs (Fusion de données):	27
Chapitre 2 : Element sur la théorie de l'apprentissage dans le contexte d'aide à la conduite	29
2.1 Introduction :	30
2.2 Approches d'apprentissage supervisées :	30
2.3. Classification :	Error! Bookmark not defined.
2.3.1. Les Machines à Vecteurs de Support (SVM) :	31
2.3.2. Les K Plus Proches Voisins (KNN) :	32
2.3.3. Arbres de décision (Decision Trees) :	34
2.4. Extraction des caractéristiques :	34
2.4.1. Histogrammes de Gradients Orientés :	34
2.4.2. Local Binary Patterns (LBP) :	36
3.1 Introduction :	40
3.2 Cahier des charges :	40
3.3 Présentation de la démarche adoptée dans ce travail	41
3.4 Méthodologie de travail et résultats	42
3.4.1 Description de la base de données :	42
3.4.2 Redimensionnement des images :	43
3.4.3 Extraction des caractéristiques :	44

3.4.3.1 Histogramme des gradients orientés (HOG)	44
3.4.3.2 Extraction des caractéristiques par la méthode LBP.....	45
3.4.4 Classification	46
3.4.4.1 Machine à vecteurs de support (SVM) :	46
3.4.4.2 k plus proches voisins (KNN)	47
3.4.4.3 Métriques d'évaluation de la classification.....	47
3.4.5 Résultats et discussion (détection de nid de poule par ML)	49
A- Base des données non équilibrés :	49
B- Base des données équilibrés :	51
C- Comparaison des performances des deux expériences :.....	54
-Comparaison des performances (Accuracy).....	54
-Comparaison des performances sensibilité et spécificité :	55
3.4.6 Résultats et discussion (détection d'obstacle par capteur)	58
Les tests du jour:	58
Les tests de nuit:	59
3.5 Discussion générale :	60
3.6 Conclusion :	61
Conclusion générale :.....	Error! Bookmark not defined.
Bibliographie.....	65

TABLEAU DES FIGURES

Figure 1.1 : Les 6 niveaux d'autonomie d'un véhicule	10
Figure 1.2 : Capteur ultrason	11
Figure 1.3 : Capteur infrarouges	12
Figure 1.4 : Capteur de mouvement	13
Figure 1.5 : Capteur Lidar	16
Figure 1.6 : Schéma fonctionnel de capteur intelligent	18
Figure 2.1: Structure de l'apprentissage non supervisé	22
Figure 2.2 : Surface de séparation linéaire du classifieur SVM	23
Figure 2.3 : Illustration du fonctionnement de l'algorithme KNN avec $K = 3$	24
Figure 2.4 : Exemple d'application du HOG sur une image	27
Figure 2.5 : Encodages des pixels par extraction des caractéristiques.	28
Figure 2.6 : Histogramme de caractéristique LBP.	28
Figure 3.1 : Exemple d'obstacles	31
Figure 3.2 : Les différentes étapes envisagées dans notre travail.	32
Figure 3.3 : Exemple des obstacles dans la route présentant des nids de poules.	33

Figure 3.4 : Exemple de la route sans obstacles	33
Figure 3.5 : Exemple d'application du HOG sur une image présentant un nid de poule	34
Figure 3.6 : Exemple d'application du HOG sur une image sans obstacle.	35
Figure 3.7 : Exemple d'application du LBP sur une image présentant un nid de poule	35
Figure 3.8 : Exemple d'application du LBP sur une image sans nid de poule	36
Figure 3.9: Performances de classification (accuracy) dans le cas d'une base de données non équilibrée (Apprentissage=80% ; Test=20%)	40
Figure 3.10: Performances de classification (accuracy) dans le cas d'une base de données non équilibrée (Apprentissage=70% ; Test=30%)	41
Figure 3.11 : Performances de classification (accuracy) dans le cas d'une base de données équilibrée (Apprentissage =80% ; Test=20%)	42
Figure 3.12: Performances de classification (accuracy) dans le cas d'une base de données équilibrée (Apprentissage =70% ; Test=30%)	43
Figure 3.13 : Résultats de comparaison des performances (accuracy) des deux expériences	44
Figure 3.14 : Résultats de comparaison des sensibilités et des spécificité (Apprentissage 80 %, test 20 %).	46
Figure 3.15 : Résultats de comparaison des sensibilités et des spécificité (Apprentissage 70 %, test 30 %).	47

Liste des tableaux

Tableau 3.1 : Matrice de confusion	39
Tableau 3.2 : Performances de classification (accuracy) dans le cas d'une base de données non équilibrée (Apprentissage=80% ; Test=20%)	39
Tableau 3.3 : Performances de classification (accuracy) dans le cas d'une base de données non équilibrée (Apprentissage=70% ; Test=30%)	54
Tableau 3.4 : Performances de classification (Accuracy) dans le cas d'une base de données équilibrée (Apprentissage =80% ; Test=20%)	55
Tableau 3.5 : Performances de classification (accuracy) dans le cas d'une base de données équilibrée (Apprentissage =70% ; Test=30%)	56
Tableau 3.6 : Tableau de comparaison des performances de classification (accuracy)	57
Tableau 3.7 : Résultat récapitulatif des sensibilités et des spécificités (Apprentissage 80 %, test 20 %).	59
Tableau 3.8 : Résultat récapitulatif des sensibilités et des spécificités (Apprentissage 70 %, test 30 %) .	60
Tableau 3.9 : Test 1 des capteurs dans le jour	61
Tableau 3.10 : Test 2 des capteurs dans le jour	61
Tableau 3.11 : Test 3 des capteurs dans le jour	62
Tableau 3.12 : Test 1 des capteurs dans la nuit	62

Introduction générale :

La sécurité routière et l'automatisation des véhicules représentent aujourd'hui des enjeux majeurs dans le domaine du transport intelligent. Avec l'évolution rapide des technologies embarquées, les systèmes d'aide à la conduite (ADAS – Advanced Driver Assistance Systems) jouent un rôle crucial dans la réduction des accidents et amélioration du confort de conduite. Parmi ces systèmes, la détection d'obstacles lors des manœuvres de stationnement et l'identification des irrégularités de la chaussée, telles que les nids-de-poule, qui représentent des défis technologiques essentiels. Ces problématiques nécessitent l'intégration de capteurs intelligents capables de percevoir leur environnement, de traiter les données en temps réel et de prendre des décisions pertinentes pour assister efficacement le conducteur.

Dans ce contexte, ce mémoire s'inscrit dans le cadre du développement d'un capteur intelligent combinant des technologies matérielles (capteurs à ultrasons et infrarouges) et des approches logicielles basées sur l'intelligence artificielle. L'objectif principal est de concevoir un système embarqué capable. D'une part, de détecter les obstacles en situation de stationnement à travers une fusion de données capteurs. D'autre part, de distinguer les nids-de-poule des surfaces routières normales à l'aide de techniques d'apprentissage automatique.

Ce mémoire est structuré de la manière suivante :

Le premier chapitre est consacré à une présentation générale des véhicules autonomes. Nous y abordons leur historique, leurs niveaux d'autonomie, ainsi qu'une description des principaux composants qui les constituent, notamment les capteurs classiques et capteurs intelligents. Ce cadre théorique permet de mieux situer notre projet dans une notion plus large de la conduite autonome.

Le deuxième chapitre traite des fondements du traitement intelligent de l'information. Il présente les méthodes d'apprentissage supervisé, notamment les classifieurs SVM et KNN, ainsi que les descripteurs d'images tels que HOG (Histogram of Oriented Gradients) et LBP (Local Binary Patterns). Ces outils sont essentiels pour la détection automatique des défauts routiers à partir d'images capturées en temps réel.

Ensuite, le troisième chapitre est consacré à la mise en œuvre pratique de notre projet ainsi qu'à l'analyse approfondie des résultats obtenus. Nous y détaillons la conception d'un prototype basé sur une carte Arduino pour la détection d'obstacles en situation de stationnement. Ce système repose sur la fusion des mesures de distance issues des capteurs à ultrasons et infrarouges, en appliquant une approche de moyenne pondérée afin d'optimiser la précision de la détection.

Dans un second temps, nous présentons la mise en place de notre solution de classification d'images visant à différencier les nids-de-poule des surfaces routières normales. Cette partie inclut l'extraction de descripteurs visuels (HOG, LBP) et l'utilisation de classifieurs tels que SVM et KNN. Un ensemble d'expérimentations variées a été réalisé afin d'évaluer les performances des modèles, à travers des métriques telles que la précision, le rappel, et la matrice de confusion. Ces expériences nous ont permis de valider l'efficacité et la robustesse de notre approche dans un contexte réel.

Ce travail vise ainsi à démontrer la faisabilité d'un capteur intelligent à faible coût, combinant électronique embarquée et intelligence artificielle, au service de l'assistance à la conduite, en particulier pour les environnements urbains où la sécurité et la précision de la détection sont primordiales.

Chapitre 1 : Véhicule Autonome

1.1.Introduction :

La voiture autonome, également appelée véhicule autonome ou véhicule sans conducteur, représente l'une des innovations technologiques majeures de ce siècle dans le domaine des transports[1]. Elle désigne un véhicule capable de se déplacer sans intervention humaine, en utilisant une combinaison de capteurs, d'intelligence artificielle, de systèmes de localisation [2] (GPS), de caméras et d'algorithmes de traitement des données. L'objectif principal de cette technologie est d'assurer une conduite sûre, efficace et autonome, en reproduisant voire en surpassant les capacités humaines en matière de perception, de décision et de réaction.

Plus précisément, une voiture autonome peut être définie comme un système de transport intelligent, doté de moyens techniques lui permettant de percevoir son environnement, de prendre des décisions en temps réel et d'effectuer des actions de conduite sans assistance humaine directe. Cette capacité repose sur l'intégration de technologies avancées telles que les lidars, les radars, l'apprentissage automatique, et les réseaux de neurones profonds.

Le développement de la voiture autonome s'inscrit dans une démarche globale de transformation de la mobilité, visant à améliorer la sécurité routière, à réduire les embouteillages, à optimiser la consommation d'énergie et à proposer de nouveaux modèles de transport. Ce domaine suscite aujourd'hui un vif intérêt à la fois dans le monde industriel, scientifique et politique, tant les enjeux économiques, technologiques et éthiques sont considérables.

1.2.Historique de la voiture autonome :

L'histoire des voitures autonomes est marquée par des avancées technologiques, des expérimentations audacieuses et des défis scientifiques. Voici une chronologie complète de leur évolution, des premiers concepts aux systèmes autonomes modernes.

1.2.1. Les prémices (1920 – 1980) : L'ère des prototypes expérimentaux

1925 – Le premier "véhicule sans conducteur"[3]

- ❖ Houdina Radio Control (États-Unis) : Une voiture télécommandée par radio circule dans les rues de New York. Bien que rudimentaire, ce prototype marque le début de l'idée d'un véhicule autonome.

Années 1950-1960 : Les premiers systèmes automatisés

Chapitre 1 : Véhicule autonome

- ❖ 1958 – General Motors "Firebird III" : Équipé d'un système de guidage électromagnétique, ce concept-car explore l'idée d'une voiture contrôlée par des capteurs.
- ❖ 1960 – Stanford Cart (Université de Stanford) : Un robot mobile précurseur, capable de suivre des lignes blanches, ancêtre des systèmes de vision par ordinateur.

Années 1970-1980 : L'essor de la robotique automobile

- ❖ 1977 – Tsukuba Mechanical Engineering Lab (Japon) : Un véhicule autonome atteint 30 km/h en suivant des marquages au sol grâce à des caméras.
- ❖ 1980 – Mercedes-Benz Van autonome (Projet EUREKA Prometheus) : Premier véhicule européen à intégrer des capteurs et une intelligence embarquée.

1.2.2. L'ère de la recherche universitaire et des défis militaires (1980 – 2010)

1986 – NavLab (Carnegie Mellon University)

- ❖ Premier véhicule autonome utilisant la vision par ordinateur et le machine learning.
- ❖ 1995: NavLab 5 parcourt 4 800 km en mode semi-autonome ("No Hands Across America").

2004-2007 – Les DARPA Grand Challenges (États-Unis)

- ❖ 2004 : Premier DARPA Grand Challenge (désert du Mojave) Aucun véhicule ne termine le parcours.
- ❖ 2005 : Stanley (Stanford) remporte le challenge en parcourant 212 km en autonomie.
- ❖ 2007 : DARPA Urban Challenge – Première compétition en milieu urbain simulé.

Années 2000 – Projets européens (Villepinte, ARGO, CyberCars)

- ❖ CyberCars (INRIA, France) : Expérimentations de navettes autonomes dans des zones fermées.

Chapitre 1 : Véhicule autonome

1.2.3. L'entrée des géants technologiques (2010 – 2020)

2010 – Google lance le projet Waymo

- ❖ Développement de la Google Self-Driving Car, basée sur des Lidars et une IA avancée.
- ❖ 2015 : Premier essai sans volant ni pédales (prototype "Firefly").

2014 – Tesla Autopilot (Niveau 2 d'autonomie)

- ❖ Première commercialisation d'un système d'aide à la conduite grand public.

2016 – Uber et les robots-taxis

- ❖ Lancement de tests à Pittsburgh, mais plusieurs accidents ralentissent le projet.

2018 – Premières législations (États-Unis, Europe, Chine)

- ❖ Arizona autorise les tests sans conducteur de secours.
- ❖ France lance des expérimentations sur routes ouvertes (Loi Mobilités, 2019).

1.2.4. Période actuelle (2020 – 2025) : Vers l'autonomie totale ?

2020 – Waymo One (Service de taxi autonome à Phoenix)

- ❖ Première commercialisation limitée de véhicules niveau 4.

2021 – Tesla "Full Self-Driving" (FSD Beta)

- ❖ Système controversé, toujours considéré comme niveau 2+.

2023-2024 – Expansion en Europe et Asie

- ❖ Mercedes obtient une certification niveau 3 en Allemagne et aux États-Unis.
- ❖ Chine accélère avec Baidu Apollo et Xiaomi.

1.3. Généralités sur les véhicules autonomes :

Chapitre 1 : Véhicule autonome

Un véhicule autonome est un système complexe capable de percevoir son environnement, de prendre des décisions et d'agir en conséquence sans intervention humaine. Il repose sur plusieurs composants clés :

- Capteurs : Caméras, radars, lidars, capteurs ultrasoniques, etc., qui collectent des données sur l'environnement du véhicule.
- Systèmes de traitement : Algorithmes d'intelligence artificielle et de machine learning qui interprètent les données des capteurs pour comprendre la situation et prendre des décisions.
- Actionneurs : Composants mécaniques qui exécutent les décisions prises, comme la direction, l'accélération et le freinage.

Ces véhicules visent à améliorer la sécurité routière, réduire les embouteillages et offrir une mobilité accessible à tous.

1.3.1. Le degré d'autonomie d'un véhicule autonome :

La classification des véhicules autonomes est essentielle pour comprendre leurs capacités et limitations. La norme la plus reconnue, établie par la SAE International (Society of Automotive Engineers) [4], définit 6 niveaux d'autonomie (de 0 à 5), selon la figure (1.1). Cette échelle permet de distinguer clairement les systèmes d'aide à la conduite des véhicules entièrement autonomes.

❖ Niveau 0 – Aucune automatisation :

À ce niveau, le véhicule ne dispose d'aucune fonction de conduite autonome. Toutes les tâches sont assurées par le conducteur, bien que certaines aides comme l'avertisseur de freinage puissent être présentes.

❖ Niveau 1 – Assistance au conducteur :

Ici, le véhicule peut aider le conducteur avec une seule fonction, comme maintenir la vitesse (régulateur de vitesse) ou garder la trajectoire. Cependant, le conducteur doit rester actif à tout moment.

❖ Niveau 2 – Automatisation partielle :

Le véhicule peut contrôler à la fois la direction et la vitesse, mais sous la surveillance constante du conducteur. Ce dernier doit rester attentif et être prêt à reprendre le volant à tout instant. C'est ce que proposent certains systèmes comme l'Autopilot de Tesla ou le Super Cruise de Cadillac.

Chapitre 1 : Véhicule autonome

❖ Niveau 3 – Automatisation conditionnelle :

À ce stade, le véhicule peut gérer la conduite de manière autonome dans certaines situations, comme sur autoroute. Le conducteur peut alors relâcher le volant, mais doit rester disponible pour reprendre le contrôle en cas de demande du système.

❖ Niveau 4 – Automatisation élevée :

Le véhicule est capable de se conduire seul dans des conditions bien définies, comme en milieu urbain ou sur des trajets prédéterminés. L'intervention humaine n'est plus nécessaire tant que ces conditions sont réunies. Certaines navettes autonomes expérimentales fonctionnent déjà à ce niveau.

❖ Niveau 5 – Automatisation complète :

C'est le niveau ultime de l'autonomie. Le véhicule peut circuler sans conducteur, sans volant, ni pédales. Il est totalement autonome, peu importe la route, le trafic ou la météo. À ce jour, ce niveau reste encore à l'état de prototype ou de test.

Exemple de niveau d'automatisation :

- ✚ Le pilote d'autoroute : c'est un système de conduite semi-autonome qui permet au conducteur de se reposer pendant les longs trajets sur autoroute. Le système utilise des capteurs pour maintenir la voiture dans sa voie, régler la vitesse et maintenir une distance de sécurité avec les autres véhicules.
- ✚ Le parking automatique est un système de stationnement assisté qui permet aux conducteurs de garer leur voiture sans avoir à manœuvrer. Le système utilise des capteurs pour détecter les places de stationnement et la voiture se gare automatiquement. Cela permet de réduire le stress et le temps passé à chercher une place de stationnement [5].

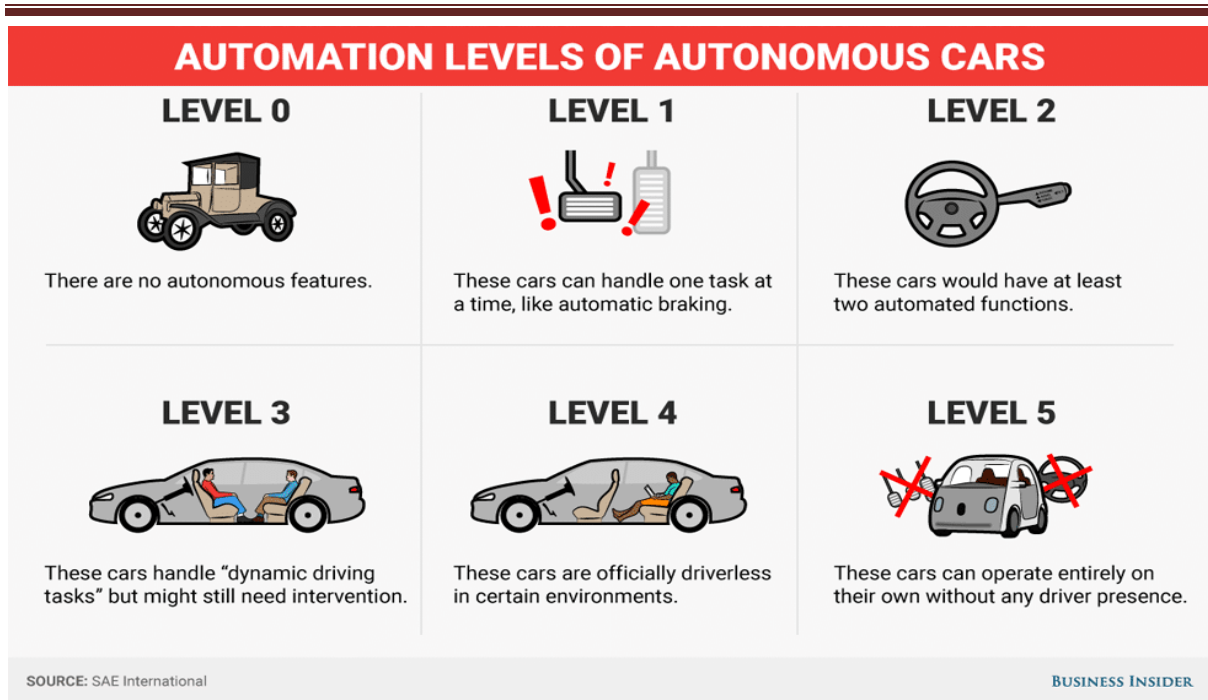


Figure 1.1 : Les 6 niveaux d'autonomie d'un véhicule

1.4. Vue d'ensemble des technologies employées dans la conduite autonome

Les véhicules autonomes reposent sur une combinaison de technologies avancées pour percevoir leur environnement, prendre des décisions et interagir avec leur milieu. Ces technologies couvrent plusieurs domaines : capteurs, intelligence artificielle, communication, informatique embarquée, etc. Cette section présente un panorama d'éléments clés sur lesquels repose le principe de la conduite automatisée. Chaque capteur possède ses propres avantages et certaines limites. De ce fait, ils sont souvent combinés afin d'offrir une vision plus globale et précise du monde environnant, une technique connue sous le nom de fusion de données.

1.5. Les capteurs pour les systèmes intelligents d'assistance à la conduite

Les systèmes intelligents d'assistance à la conduite, ou ADAS (*Advanced Driver Assistance Systems*), utilisent un ensemble de capteurs pour observer et comprendre l'environnement du véhicule. Ces capteurs permettent de détecter des obstacles, analyser la route, surveiller les autres usagers, et parfois intervenir automatiquement pour éviter un accident. Ce chapitre détaille les principaux capteurs impliqués dans la conception de ces systèmes.

1.5.1. Capteurs à ultrasons

Chapitre 1 : Véhicule autonome

Les capteurs à ultrasons émettent des ondes sonores à haute fréquence (inaudibles à l'oreille humaine). Ces ondes se réfléchissent sur les objets environnants, et le capteur mesure le temps que met l'onde à revenir pour déterminer la distance.




Figure 1.2 : Capteur ultrason

Le capteur à ultrasons permet à la voiture autonome de mesurer la distance entre elle-même et les objets environnants, en émettant des ondes sonores à haute fréquence (inaudibles pour l'humain) et en analysant le temps que met l'écho à revenir après avoir frappé un obstacle (figure 1.2).

Il présente les fonctions suivantes :

- **Détection d'obstacles :**

Le capteur identifie la présence d'objets ou de murs proches de la voiture, ce qui permet d'éviter les collisions.

- **Aide à la navigation :**

Il fournit des informations en temps réel au système de contrôle pour ajuster la trajectoire ou la vitesse du véhicule.

- **Manœuvres de stationnement :**

Utilisé pour détecter la distance aux autres véhicules ou à des bordures pendant un stationnement autonome.

- **Sécurité :**

Il contribue à l'arrêt automatique ou au ralentissement du véhicule lorsqu'un obstacle est détecté à faible distance.

1.5.2. Capteur infrarouge (type SHARP)

Le capteur infrarouge SHARP utilise la réflexion d'un faisceau infrarouge pour mesurer la distance entre le capteur et un objet. Ils fonctionnent en triangulant la position du point réfléchi sur un capteur optique.




Figure 1.7 : Capteur infrarouge

Le capteur infrarouge permet à la voiture autonome de détecter la présence d'obstacles et d'estimer leur distance en utilisant un faisceau lumineux infrarouge. Il émet un rayon IR, qui se réfléchit sur un objet proche, et mesure l'angle de retour pour calculer la distance. Contrairement au capteur à ultrasons qui mesure le temps, le capteur IR (type Sharp) mesure un angle de réflexion. Il présente les fonctions suivantes :

- **Détection d'obstacles à courte distance** : Très utile dans les environnements serrés où une réaction rapide est nécessaire.
- **Complément aux capteurs à ultrasons** : Il fournit une précision accrue à courte portée, là où les ultrasons peuvent être perturbés par des angles ou surfaces absorbantes.
- **Mesure de distance directe** : Le capteur Sharp donne une tension proportionnelle à la distance, facile à lire avec un microcontrôleur.

Chapitre 1 : Véhicule autonome

- **Détection d'objets spécifiques** : Il peut être utilisé pour différencier des objets par leur proximité dans des tâches précises (comme l'arrêt devant une ligne de détection ou un mur).

1.5.3. Capteurs de mouvement (accéléromètres, gyroscopes)

Ces capteurs mesurent l'accélération (accéléromètre) ou la vitesse angulaire (gyroscope) du véhicule dans plusieurs axes. Ils sont utilisés pour analyser les mouvements du véhicule (freinage, virage, accélération).

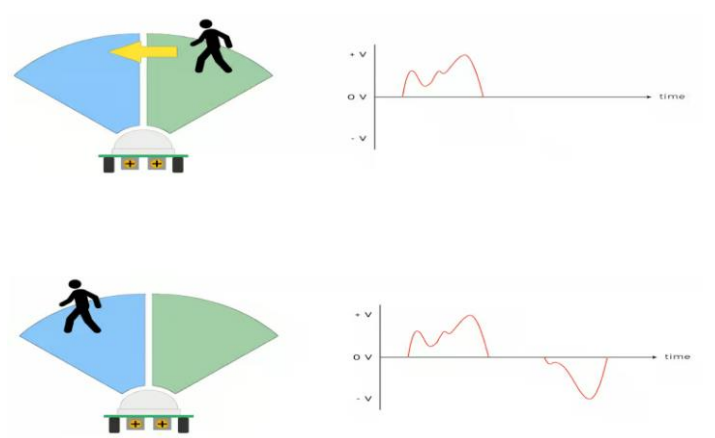


Figure 1.8 : Capteur de mouvement

Les capteurs de mouvement permettent à la voiture autonome de comprendre sa position, son orientation et ses accélérations dans l'espace. Ils jouent un rôle essentiel dans la stabilisation, la navigation et le contrôle du mouvement.

Accéléromètre

L'accéléromètre mesure l'accélération linéaire selon un ou plusieurs axes (X, Y, Z). Cela permet de détecter si la voiture accélère, ralentit ou change de direction.

Fonctions principales :

- Détection de mouvements brusques (freinage ou virage).
- Contrôle de la vitesse instantanée.
- Estimation de la position par intégration (avec limites de précision).

Gyroscope

Le gyroscope mesure la vitesse de rotation (angulaire) autour d'un ou plusieurs axes.

Il permet de savoir si la voiture tourne, et à quelle vitesse elle le fait. Parmi ses fonctions :

- Suivi de l'orientation (angle de rotation).
- Stabilité de la trajectoire (éviter les dérapages).
- Aide au virage contrôlé et à l'alignement.

1.5.4. Radar (Radio Detection And Ranging)

Le radar émet des ondes électromagnétiques (radio) qui se réfléchissent sur les objets. Il calcule la distance, la vitesse, et parfois l'angle de ces objets en mesurant le temps de retour de l'onde et l'effet Doppler.

Le radar (Radio Detection And Ranging) est un capteur qui utilise des ondes radio pour détecter la présence, la distance, et la vitesse des objets autour de la voiture. Il fonctionne même dans des conditions difficiles (pluie, brouillard, obscurité), ce qui le rend très fiable pour la conduite autonome. Il permet :

- **Détection longue portée** : Le radar peut détecter des objets jusqu'à plusieurs dizaines ou centaines de mètres, utile pour l'anticipation.
- **Suivi de véhicules en mouvement** : Il mesure la vitesse relative des véhicules devant ou autour (freinage automatique, régulateur adaptatif).
- **Détection par mauvais temps** : Contrairement aux caméras ou capteurs IR, il fonctionne bien en pluie, brouillard, ou faible luminosité.
- **Aide à l'évitement de collision** : Le système peut freiner automatiquement si un véhicule ou obstacle est détecté à vitesse réduite.

- **Détection des marquages au sol** : Les caméras détectent les lignes de voie, les passages piétons, les flèches de direction, ce qui aide à maintenir le véhicule dans sa voie.

- **Évaluation des distances et du mouvement** : Associées à des algorithmes de vision par ordinateur, les caméras peuvent estimer la vitesse des objets environnants et la distance qui les sépare du véhicule.

- **Vision à 360° et assistance au stationnement** : Plusieurs caméras peuvent être disposées autour du véhicule pour offrir une vue panoramique, utile pour les manœuvres et le stationnement automatique.
- **Conditions de conduite complexes** : Les caméras sont utiles pour interpréter des situations complexes (travaux, feux tricolores, gestes d'un agent de circulation, etc.) que certains capteurs comme le lidar ou le radar ne peuvent pas identifier seuls.

1.5.5. LIDAR (Light Detection and Ranging)

Le LIDAR envoie des impulsions laser vers l'environnement. Ces impulsions rebondissent sur les objets et reviennent au capteur, qui mesure le temps de vol pour calculer la distance. Un balayage 3D est réalisé autour du véhicule. Figure (1.5).




Figure 1.5 : Capteur Lidar

Parmi ses fonctionnalités :

- **Perception 3D de l'environnement** : Le LIDAR génère un nuage de points 3D extrêmement précis en mesurant la distance entre le véhicule et les objets qui l'entourent. Il détecte la forme, la taille et la position des objets : voitures, piétons, obstacles, trottoirs, panneaux, etc.
- **Cartographie et SLAM (Simultaneous Localization and Mapping)** : Le LIDAR aide à créer et mettre à jour en temps réel une carte 3D de l'environnement. Grâce au SLAM, le véhicule peut se localiser avec précision sur la carte sans GPS, même dans des environnements complexes (tunnels, parkings).
- **Détection d'obstacles et suivi de trajectoire** : Il permet une détection fiable des **obstacles**, même dans des conditions de faible luminosité ou de nuit (contrairement à

une caméra seule). Le LIDAR aide à calculer les distances de sécurité, éviter les collisions, et planifier une trajectoire sûre.

- **Mesure précise des distances** : Il offre une précision centimétrique, bien supérieure à celle des radars ou des capteurs à ultrasons. Utile pour les manœuvres précises, comme le stationnement ou la navigation en zone étroite.

1.6. Capteur intelligent

Les capteurs intelligents représentent une avancée majeure dans le domaine des véhicules autonomes. Contrairement aux capteurs traditionnels qui se contentent de mesurer des données physiques (distance, lumière, vitesse, etc.), les capteurs intelligents possèdent une capacité de traitement embarquée. Cela signifie qu'ils peuvent analyser et interpréter certaines informations localement, sans attendre l'intervention de l'unité centrale du véhicule.

1.6.1. Rôle des capteurs intelligents dans un VA

Les capteurs intelligents permettent à la voiture autonome de :

- Détecter les obstacles (piétons, véhicules, objets).
- Analyser l'environnement (routes, panneaux, feux de signalisation).
- Prédire les comportements des autres usagers (voitures, cyclistes).
- Prendre des décisions en temps réel (freinage, changement de voie).

Dans le contexte de l'automatisation de la conduite, Un capteur est qualifié d'intelligent lorsqu'il combine plusieurs fonctionnalités avancées, telles que le traitement embarqué, lui permettant d'analyser les données localement sans dépendre du cloud, et l'apprentissage automatique (ML), qui améliore en continu ses algorithmes de classification.

Il intègre également la fusion de données issus d'un réseau de capteurs (voir figure (1.6)) permettant d'optimiser la fiabilité des données en les combinant ensemble.

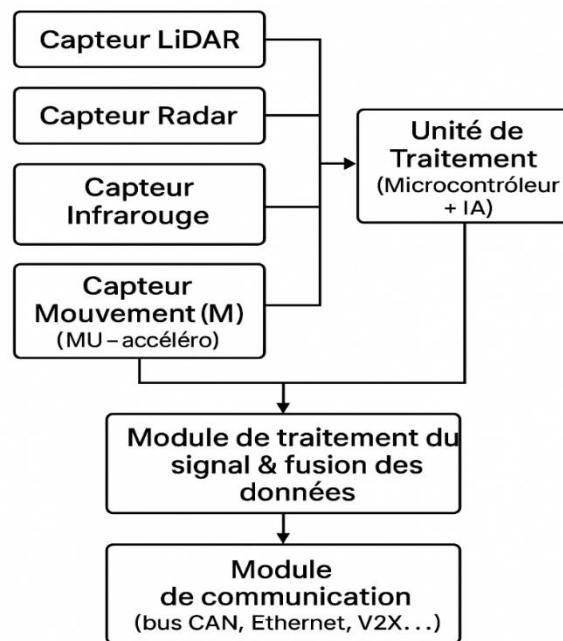


Figure 1.6 : Schéma fonctionnel de capteur intelligent

1.6.2. Combinaison des capteurs (Fusion de données):

Les capteurs intelligents sont intimement liés à la notion de fusion de données, une technique qui combine les informations issues de plusieurs capteurs (caméras, Lidar, radar, GPS...). Cette approche permet d'obtenir une vision plus précise, plus fiable et plus complète de l'environnement. Par exemple, si la caméra ne fonctionne pas de manière optimale dans le brouillard, le radar ou le Lidar peut compenser cette limite.

Par exemple, Les systèmes autonomes comme Tesla (Vision-based), Waymo (Lidar-based) ou Mobileye utilisent une fusion de capteurs pour compenser les limites de chaque technologie.

Chaque constructeur adopte une approche différente, par exemple la technologie Tesla mise sur les caméras + IA, tandis que d'autres intègrent Lidar + Radar + Caméras en combinant les données issues de ce réseau de capteurs.

1.6.3. Quelques exemples d'applications de capteurs intelligent

- **Caméra avec IA embarquée :** Détection de panneaux de signalisation en temps réel.

Chapitre 1 : Véhicule autonome

- **Radar intelligent** : Capacité à distinguer un piéton immobile d'un objet fixe (comme un poteau).
- **Capteur de stationnement intelligent** : Détecte les espaces libres et calcule la manœuvre de stationnement

1.7. Conclusion :

L'étude des véhicules autonomes met en lumière l'évolution impressionnante des technologies embarquées dans le domaine du transport intelligent. Depuis les premières expérimentations jusqu'aux solutions déployées aujourd'hui, ces systèmes reposent sur l'intégration harmonieuse de capteurs, d'algorithmes de traitement et d'intelligence artificielle.

Les capteurs, en particulier, jouent un rôle fondamental dans la perception de l'environnement, et leur combinaison à travers des techniques de fusion de données permet d'améliorer significativement la fiabilité et la sécurité de la conduite automatisée. À travers cette convergence technologique, la voiture autonome ne cesse de se rapprocher de son objectif ultime : une mobilité totalement autonome, sûre et accessible. Le prochain chapitre explorera les approches d'apprentissage automatique qui permettent à ces systèmes de prendre des décisions intelligentes en temps réel.

Chapitre 2 : Éléments sur la théorie de l'apprentissage dans le contexte d'aide à la conduite

2.1 Introduction :

Le but de ce chapitre est de fournir au lecteur une vue d'ensemble des notions fondamentales à base d'apprentissage automatique intervenant lors de la mise en œuvre d'un système d'identification de nids-de-poule routier. Cela se fait dans un contexte global d'assistance à la conduite.

Dans un premier temps, nous décrivons l'apprentissage supervisé tout en détaillant quelques méthodes utilisées dans le cadre de cette étude. Deux approches d'apprentissage supervisés sont alors exploitées : les classifieurs SVM et KNN.

2.2 Approches d'apprentissage supervisées :

L'apprentissage automatique repose sur le principe de formation de modèle informatique à partir de données disponibles afin qu'il puisse effectuer des prédictions ou des classifications sur de nouvelles données non vues auparavant.

Il existe différentes méthodes d'apprentissage, notamment l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement. L'apprentissage supervisé est utilisé lorsque le modèle est entraîné sur un ensemble de données étiquetées, c'est-à-dire des données dont les classes sont connues d'avance.

Le machine learning consiste alors à donner à une machine la capacité d'apprendre sans la programmer de façon explicite. Une des stratégies qu'on peut utiliser est l'apprentissage supervisé qui consiste à montrer à la machine des exemples X et Y et à lui demander de trouver l'association qui relie X à Y telle que $Y=F(X)$. Ces exemples qu'on lui montre constituent la Dataset ou base de données.

En apprentissage supervisé, notre Dataset contient toujours deux types de variables. D'un côté, on a la Target Variable (Target Y), c'est notre objectif, c'est ce que la machine apprend à prédire (par exemple : identifier un email en SPAM ou pas). D'un autre côté, on a les features ou les facteurs qui viennent influencer la valeur de Y . Ces attributs sont clairement associés à chacune des classes considérées. Une fois le modèle entraîné, il peut être utilisé pour prédire les classes de nouvelles données non étiquetées [6].

En effet, cet apprentissage sur des données ayant déjà la réponse correcte permet de prédire par la suite le label des données nouvelles non étiquetés, pour cela ce type d'apprentissage est dit supervisé, la figure (2.1) représente apprentissage supervisé

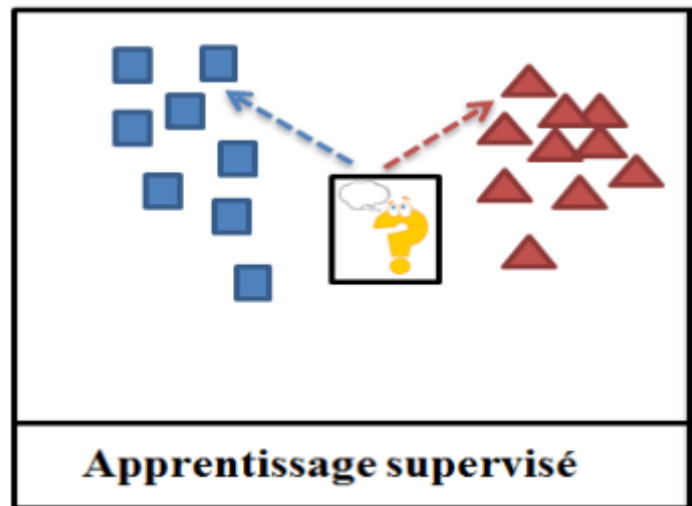


Figure 2.1: Apprentissage supervisé

Les algorithmes d'apprentissage pour la classification sont divers, tels que les machines à vecteurs de support (SVM), les k plus proches voisins (KNN), Arbres de décision (Décision Trees), ainsi que d'autres.

On abordera dans ce qui suit une brève définition de ces techniques :

2.3.1. Les Machines à Vecteurs de Support (SVM) :

L'algorithme du SVM vise à trouver, pour les données fournies, un hyperplan qui maximise la marge pour l'ensemble d'apprentissage. Cet hyperplan est paramétré par :

$$f(x) = w^t x + b \quad (2.1)$$

où w est un vecteur de poids et b un biais [7].

La classification d'un point x se fait selon le signe de $f(x)$:

- si $f(x) > 0$, l'exemple est classé dans la classe **+1** (classe pothole) ;

- si $f(\mathbf{x}) < 0$, il est classé dans la classe -1 (classe non pothole);
- si $f(\mathbf{x}) = 0$, le point se trouve sur l'hyperplan.

Le choix du SVM est motivé par ses performances élevées en classification visuelle, sa robustesse face au bruit et sa capacité à gérer des espaces de caractéristiques de grande dimension [8], figure ci-dessus représente le classifieur SVM figure (2.2).

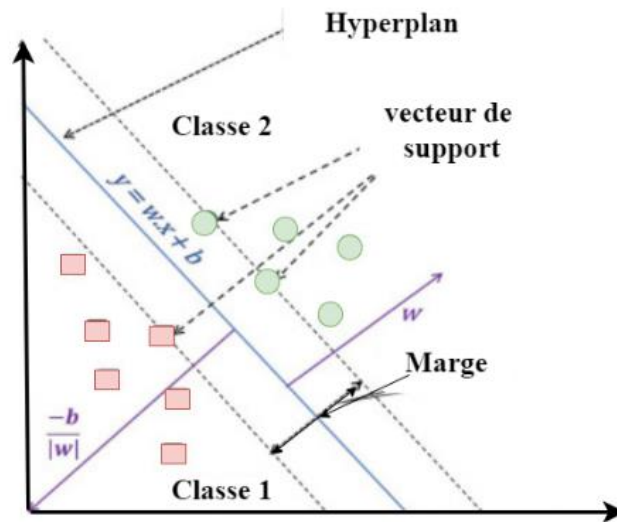


Figure 2.2 : Surface de séparation linéaire du classifieur SVM

2.3.2. Les K Plus Proches Voisins (KNN) :

Le KNN est une méthode d'apprentissage supervisé simple et intuitive. Elle repose sur le principe que des échantillons similaires se regroupent dans l'espace des caractéristiques. Le KNN attribue une classe à un nouvel échantillon en se basant sur les classes majoritaires parmi les k échantillons les plus proches dans l'espace des caractéristiques. Le KNN est facile à comprendre, et peut être utilisé pour des problèmes de classification multi-classes [9] comme la figure ci-dessus figure (2.3).




Figure 2.3 : Illustration du fonctionnement de l'algorithme KNN avec $K = 3$

Voici une explication des différentes étapes de l'algorithme K-NN [10] :

1) **Choix du nombre de voisins (K)**

La première étape consiste à définir la valeur de K , représentant le nombre de voisins les plus proches à prendre en compte pour la classification. Ce paramètre est généralement déterminé par expérimentation, afin d'optimiser les performances du modèle.

2) **Calcul des distances euclidiennes**

Une fois K défini, l'algorithme calcule la distance euclidienne entre le point à classer et tous les points de l'ensemble d'entraînement. Cette distance correspond à la mesure directe entre deux points dans un espace à plusieurs dimensions, et elle permet d'évaluer la proximité entre les données.

3) **Identification des K voisins les plus proches**

Après le calcul des distances, l'algorithme sélectionne les K points de données les plus proches du point à classer, c'est-à-dire ceux ayant les distances les plus faibles. Ces voisins serviront de référence pour l'étape suivante.

4) **Comptage des classes parmi les voisins sélectionnés**

L'algorithme examine ensuite les étiquettes de classe associées à ces K voisins et compte combien appartiennent à chaque catégorie. Cela permet d'identifier la classe dominante dans le voisinage immédiat du point inconnu.

5) Attribution de la classe majoritaire au nouveau point

Le point à classer est alors affecté à la classe majoritaire parmi ses K voisins, en suivant le principe du vote majoritaire. Cette classe constitue la prédiction du modèle.

6) Modèle prêt à l'utilisation

Une fois le point classé, le modèle peut être utilisé pour prédire la classe d'autres points en répétant ce même processus. Le k -NN est ainsi prêt à fonctionner pour toute tâche de classification.

2.3.3. Arbres de décision (Decision Trees) :

Les arbres de décision sont une méthode d'apprentissage supervisé et non supervisé utilisée pour la classification et la régression. Ils utilisent une structure hiérarchique d'arbre, où chaque nœud représente un test sur une caractéristique et chaque feuille représente une classe ou une valeur de sortie. Les arbres de décision sont appréciés pour leur interprétabilité, leur facilité d'utilisation et leur capacité à gérer des données à la fois catégorielles et numériques [9].

2.4. Extraction des caractéristiques :

Les classifieurs tels que le Support Vector Machine (SVM), le k -Nearest Neighbors (KNN) ou encore les arbres de décision sont des outils puissants pour distinguer entre différentes classes, à condition que les données soient représentées de manière pertinente. C'est dans ce contexte que les techniques d'extraction de caractéristiques, telles que le Histogram of Oriented Gradients (HOG), le Local Binary Pattern (LBP) ou encore les descripteurs basés sur les ondelettes, jouent un rôle fondamental.

Ces méthodes permettent de transformer une image ou un signal complexe en un vecteur de caractéristiques plus compact, capturant l'essentiel de l'information discriminante. L'efficacité d'un système de reconnaissance ou encore d'apprentissage automatique repose ainsi sur une combinaison optimale entre une représentation pertinente des données et un algorithme de classification adapté. Cette synergie constitue la base des systèmes modernes de détection d'objets, de reconnaissance faciale, ou encore de classification d'activités humaines.

2.4.1. Histogrammes de Gradients Orientés :

Les Histogrammes des Gradients Orientés (HOG), introduits par Naveet Dalal et Bill Triggs, constituent un descripteur de caractéristiques largement utilisé en vision par

ordinateur et en traitement d'images, notamment pour la détection d'objets. Cette méthode repose sur l'analyse des orientations de gradient dans des régions localisées de l'image. Le descripteur HOG met particulièrement en évidence la forme et la structure des objets en s'appuyant simultanément sur la magnitude et la direction des gradients. Ces données sont ensuite agrégées sous forme d'histogrammes calculés pour chaque zone de l'image, permettant ainsi une représentation compacte et efficace des caractéristiques visuelles locales.

Le processus de calcul du descripteur HOG se déroule selon plusieurs étapes clés :

a) Prétraitement de l'image :

L'image est tout d'abord convertie en niveaux de gris si elle est en couleur, afin de simplifier le calcul des gradients. Un éventuel redimensionnement peut également être appliqué pour normaliser les tailles des images analysées.

b) Calcul des gradients :

Pour chaque pixel de l'image, on calcule le gradient horizontal (G_x) et vertical (G_y) à l'aide de filtres de dérivation. À partir de ces deux composantes, on obtient la magnitude du gradient ainsi que son orientation à chaque point de l'image.

$$G_x = I(x + 1, y) - I(x - 1, y) \quad (2.2)$$

$$G_y = I(x, y + 1) - I(x, y - 1) \quad (2.3)$$

$I(x, y)$ représente l'intensité du pixel à la position (x, y) dans l'image.

c) Division de l'image en cellules

L'image est ensuite découpée en cellules (souvent de taille 8×8 pixels). Dans chaque cellule, on crée un histogramme des orientations de gradients, en répartissant les directions (par exemple sur 9 angles de 0° à 180°) pondérées par leur magnitude

Magnitude :

$$M(x, y) = \sqrt{G_x^2 + G_y^2} \quad (2.4)$$

Orientation :

$$\theta(x, y) = \arctan(G_y / G_x) \quad (2.5)$$

d) Regroupement en blocs et normalisation

Pour renforcer la robustesse du descripteur face aux variations d'éclairage, plusieurs cellules sont regroupées en blocs (par exemple 2×2 cellules), et les histogrammes sont normalisés au sein de ces blocs. Cette étape améliore l'invariance locale du descripteur.

e) Construction du vecteur final

Le vecteur final de HOG est obtenu en concaténant tous les histogrammes normalisés des blocs couvrant l'image entière. Ce vecteur forme une représentation compacte et discriminante des structures locales de l'image, figure ci-dessus représente application de HOG figure (2.4).



Image originale




Image des gradients

Figure 2.4 : Exemple d'application du HOG sur une image

2.4.2. Local Binary Patterns (LBP) :

Le descripteur Local Binary Pattern (LBP) [10] est une technique d'extraction de caractéristiques largement utilisée en traitement d'images pour décrire et analyser les textures locales présentes dans une image. Elle permet de capturer les motifs d'intensité qui caractérisent les structures de surface, et s'avère particulièrement efficace pour des tâches telles que la reconnaissance de motifs, la détection d'anomalies ou encore la classification d'images.

Le processus LBP repose sur le parcours de l'image à l'aide d'une fenêtre de taille fixe, généralement 3×3 pixels, afin de générer un motif binaire local pour chaque pixel. Ce motif est obtenu en comparant l'intensité du pixel central avec celles de ses 8 voisins immédiats. Pour chaque voisin, une valeur binaire est attribuée :

- 1 si l'intensité du voisin est supérieure ou égale à celle du pixel central,
- 0 sinon.

Chapitre 2 : Eléments sur la théorie de l'apprentissage dans le contexte d'aide à la conduite

Les valeurs binaires obtenues sont ensuite concaténées dans le sens horaire ou antihoraire pour former un code binaire de 8 bits, qui est converti en une valeur décimale. Cette valeur remplace le pixel central, produisant ainsi une nouvelle image appelée image LBP, qui encode les informations de texture.

La figure (2.5) ci-dessus représente l'encodage d'une image




Figure 2.5 : codages des pixels par extraction des caractéristiques.




Figure 2.6 : Histogramme de caractéristique LBP.

2.5. Mesure de performances en classification :

L'évaluation des performances d'un modèle de classification repose sur l'utilisation de métriques quantitatives permettant de mesurer la qualité des prédictions effectuées. Parmi les indicateurs les plus couramment utilisés figurent la précision de classification (Accuracy) [11], la spécificité [12] et la sensibilité. Ces métriques offrent une vue d'ensemble sur la capacité du modèle à distinguer correctement les différentes classes et sont essentielles pour analyser sa robustesse et sa fiabilité.

2.6. Conclusion :

Chapitre 2 : Eléments sur la théorie de l'apprentissage dans le contexte d'aide à la conduite

Dans ce chapitre, nous avons présenté les fondements théoriques de l'apprentissage supervisé appliqué au contexte de l'aide à la conduite, en particulier pour la détection automatique des nids-de-poule. Nous avons détaillé les principales méthodes de classification, notamment les machines à vecteurs de support (SVM), les k plus proches voisins (KNN) et les arbres de décision, en expliquant leur fonctionnement et leurs avantages respectifs.

De plus, une attention particulière a été accordée aux techniques d'extraction de caractéristiques telles que HOG (Histogram of Oriented Gradients) et LBP (Local Binary Pattern), qui jouent un rôle essentiel dans la représentation efficace des données visuelles. Ces descripteurs permettent de transformer une image brute en un vecteur caractéristique plus pertinent pour la classification.

Enfin, nous avons introduit les principales métriques d'évaluation permettant de quantifier les performances d'un modèle de classification, à savoir l'accuracy, la spécificité et la sensibilité, ainsi que la matrice de confusion, outil fondamental pour interpréter les résultats.

Ce socle théorique constitue la base indispensable pour la mise en œuvre pratique et l'expérimentation des algorithmes dans le chapitre 3, où nous présenterons l'implémentation du système proposé et l'analyse des résultats obtenus.

Chapitre 3 : Analyse et interprétation des résultats

3.1 Introduction :

Le concept de route intelligente repose sur l'intégration de technologies avancées telles que la vision par ordinateur, l'intelligence artificielle et les capteurs embarqués, dans le but d'améliorer la sécurité routière et le confort des conducteurs. L'un des problèmes fréquents et souvent négligés sur les routes est la présence de nids-de-poule (pothole), de bosses ou d'irrégularités qui peuvent provoquer des dommages mécaniques aux véhicules, perturber la fluidité du trafic, voire entraîner des accidents graves. Face à cette problématique, des systèmes intelligents sont proposés capables de détecter automatiquement, et à distance, l'état de la chaussée en temps réel. Ce système s'appuie sur des caméras et/ou des capteurs (comme l'ultrason ou le LIDAR, etc ...) installés sur le véhicule ou le long de la route, afin d'identifier la présence d'anomalies sur la surface. Les données collectées sont ensuite analysées par une unité centrale ou un algorithme intelligent, qui alerte immédiatement le conducteur via une interface visuelle ou sonore.

Un tel système permet non seulement d'éviter les dommages coûteux pour les usagers, mais aussi de collecter des informations précieuses pour les autorités, en vue d'un entretien plus efficace du réseau routier.

Dans la suite on va exposer notre système conçu pour ce projet.

3.2 Cahier des charges :

Le système que nous avons conçu vise à détecter différents types d'obstacles rencontrés sur la route, notamment les nids-de-poule, ainsi que ceux présents dans les zones de stationnement.

Pour la détection des nids-de-poule, nous avons recours à des techniques d'intelligence artificielle, en particulier à des classificateurs capables d'indiquer la présence ou l'absence de tels défauts à partir d'images analysées.

En ce qui concerne la détection des obstacles physiques dans les zones de stationnement, nous avons mis en œuvre une approche basée sur la fusion de données issues de deux capteurs à ultrasons et d'un capteur infrarouge (IR), permettant d'identifier en temps réel les objets situés à proximité immédiate du véhicule.

La figure 3.1 ci-dessous présente des exemples d'obstacle traité dans ce projet.



Figure 3.1 : Exemple d'obstacles

3.3 Présentation de la démarche adoptée dans ce travail

Dans le cadre de ce projet, une démarche méthodologique rigoureuse a été suivie afin de concevoir, un système de détection des obstacles adapté aux environnements routiers et aux zones de stationnement. Cette démarche repose sur une approche combinée entre techniques d'intelligence artificielle, traitement d'images, et capteurs embarqués, permettant de couvrir une large gamme de scénarios de détection.

La figure 3.2 ci-dessous illustre les démarches adoptées dans ce travail :

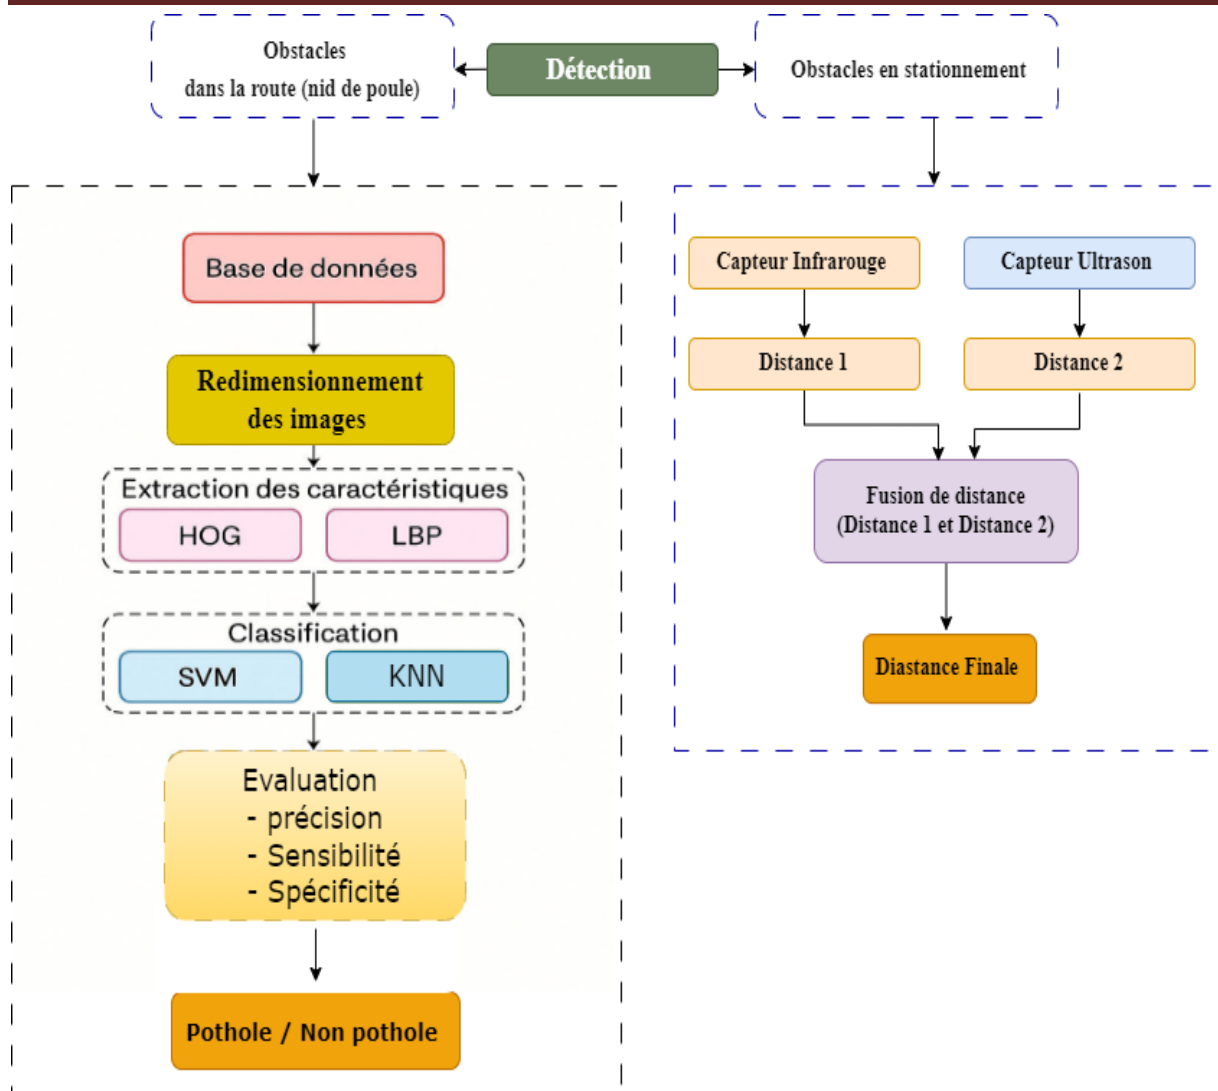


Figure 3.2 : Les différentes étapes envisagées dans notre travail.

3.4 Méthodologie de travail et résultats

3.4.1 Description de la base de données :

Dans le cadre de la détection des obstacles routiers à l'aide de techniques d'apprentissage automatique, une base de données a été spécialement constituée pour permettre la reconnaissance automatique des nids-de-poule (potholes) par vision par ordinateur. Cette base contient un ensemble de 510 images en couleur, capturées dans des environnements réels, reflétant une diversité de conditions de chaussée, d'éclairage et de perspectives de prise de vue [13].

Plus précisément, la base contient :

Chapitre 3 : Analyse et interprétation des résultats

- 310 images de routes présentant un ou plusieurs nids-de-poule : caractérisés par des déformations visibles du revêtement routier, des fissures ou des trous (voir figure 3.3 ci-dessous).



Figure 3.3 : Exemple des obstacles dans la route présentant des nids de poules.

- 200 images de routes sans anomalie : utilisées comme classe négative (absence de nids-de-poule), afin de permettre au système d'apprendre à distinguer les situations normales de celles présentant un danger.



Figure 3.4 : Exemple de la route sans obstacles

3.4.2 Redimensionnement des images :

Le prétraitement désigne l'ensemble des opérations qu'on a fait sur les données brutes en amont de toute phase d'analyse ou d'apprentissage automatique. Ces étapes sont essentielles pour améliorer la qualité des données, éliminer les éventuelles distorsions ou le bruit, normaliser les entrées, et optimiser les performances des algorithmes de classification.

Dans notre cas, aucun prétraitement complexe n'a été appliqué aux images de la base de données utilisées pour la détection automatique des nids-de-poule. Les images ont été exploitées dans leur état d'origine, leur qualité et leur définition étant jugées suffisantes pour l'analyse, à l'exception d'un redimensionnement uniforme à une taille de 128×128 pixels afin de les adapter aux exigences des algorithmes de classification.

3.4.3 Extraction des caractéristiques :

L'extraction des caractéristiques représente une étape essentielle dans le processus de classification d'images. Elle consiste à convertir les données visuelles brutes en représentations numériques pertinentes, sous forme de vecteurs de caractéristiques, permettant aux algorithmes d'apprentissage automatique d'identifier les objets ou les traits distinctifs présents dans les images.

Dans le cadre de notre projet de détection des nids-de-poule, nous avons retenu deux méthodes complémentaires d'extraction de caractéristiques : l'histogramme des gradients orientés (HOG) et les motifs binaires locaux (LBP). Ces techniques sont reconnues pour leur efficacité à capturer les formes, les textures et les structures locales présentes dans les images.

3.4.3.1 Histogramme des gradients orientés (HOG)

Cette méthode est particulièrement bien adaptée à la détection de nids-de-poule, car ces derniers se manifestent par des ruptures nettes dans la texture de la chaussée. HOG permet de capturer efficacement ces contours irréguliers et d'en extraire une signature visuelle caractéristique. Les vecteurs HOG obtenus sont ensuite utilisés comme entrées pour les classifieurs SVM ou KNN. L'efficacité de cette méthode dans notre système se justifie par sa robustesse face au bruit et sa capacité à discriminer les structures locales, ce qui est essentiel dans un contexte où la forme des nids-de-poule varie fortement selon la route, la lumière et la perspective.

Les deux figures 3.5 et 3.6 nous montre un exemple d'extraction des caractéristiques par la méthode HOG.



Image originale




Image des gradients

Figure 3.5 : Exemple d'application du HOG sur une image présentant un nid de poule




Figure 3.6 : Exemple d'application du HOG sur une image sans obstacle.

3.4.3.2 Extraction des caractéristiques par la méthode LBP

LBP est particulièrement utile dans notre application, car les nids-de-poule présentent des variations texturales significatives par rapport à une chaussée régulière. En capturant ces motifs de texture, LBP permet de distinguer les zones endommagées des surfaces normales. les figure ci-dessous nos montre l'application de cette méthode sur deux images l'une présent une irrégularité (pothole) et l'autre une route saine (non pothole).




Figure 3.7 : Exemple d'application du LBP sur une image présentant un nid de poule




Figure 3.8 : Exemple d'application du LBP sur une image sans nid de poule

3.4.4 Classification

La classification constitue une étape clé de notre système de détection des nids-de-poule, permettant de distinguer automatiquement les images représentant une chaussée endommagée de celles représentant une chaussée intacte. Pour cela, deux algorithmes d'apprentissage supervisé ont été mis en œuvre : la machine à vecteurs de support (SVM) et la méthode des k plus proches voisins (KNN). Ces méthodes sont reconnues pour leur efficacité dans les tâches de classification binaire, même avec un volume de données limité [14][15].

3.4.4.1 Machine à vecteurs de support (SVM) :

Le SVM est un classifieur supervisé largement utilisé dans le domaine de la vision par ordinateur. Il vise à déterminer un hyperplan optimal qui sépare la base de données en deux classes tout en maximisant la marge entre les points les plus proches de la frontière de décision, appelés vecteurs de support [16]. Ce principe assure une généralisation robuste du modèle aux nouvelles données.

Dans notre projet, nous avons utilisé un SVM linéaire, adapté aux problèmes où la séparation entre classes est approximativement linéaire. Les caractéristiques extraites par les descripteurs HOG et LBP ont été utilisées comme vecteurs d'entrée. Chaque image a été étiquetée selon deux classes :

- Classe 1 : image avec nid-de-poule (pothole),
- Classe 0 : image sans nid-de-poule (sans pothole).

3.4.4.2 k plus proches voisins (KNN)

Le classifieur KNN (K-Nearest Neighbors) est une méthode simple et intuitive de classification, qui repose sur la proximité géométrique dans l'espace des caractéristiques.

Lorsqu'une nouvelle donnée est soumise au classifieur, celui-ci recherche les k voisins les plus proches et lui attribue la classe majoritaire parmi ces derniers [17].

Le KNN est reconnu pour sa simplicité de mise en œuvre et son efficacité, notamment lorsqu'il est utilisé avec des descripteurs puissants comme HOG et LBP [18].

Le paramètre essentiel de ce classifieur réside dans la détermination du nombre K de plus proches voisins à prendre en compte, K représentant le nombre d'échantillons les plus proches à considérer lors de la classification. Dans ce travail on a considéré trois voisin (k=3).

3.4.4.3 Métriques d'évaluation de la classification

Dans le cadre de cette étude, nous avons évalué la performance de notre système de classification à l'aide de trois métriques quantitatives fondamentales : la précision de classification (Accuracy) [11], la spécificité (Specificity) [12] et la sensibilité (Sensitivity). Ces indicateurs sont couramment utilisés dans les systèmes de reconnaissance visuelle pour évaluer, de manière objective, la capacité d'un modèle à bien distinguer deux classes opposées : dans notre cas, les routes présentant un nid-de-poule et celles qui sont intactes.

- Précision de classification (Accuracy)

La précision est une métrique globale qui permet de mesurer le taux de bonnes classifications réalisées par le modèle. Elle est définie comme la proportion d'images correctement classifiées (qu'elles soient positives ou négatives) par rapport au nombre total d'images traitées. Il s'agit d'une mesure directe et intuitive de la performance globale d'un modèle de classification binaire [11].

La formule de précision :

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (3.1)$$

où :

- **TP (True Positives)** : cas où un nid-de-poule est correctement détecté.
- **TN (True Negatives)** : cas où une route sans nid-de-poule est correctement détectée.

- **FP (False Positives)** : cas où une route en bon état est incorrectement classée comme présentant un nid-de-poule.
- **FN (False Negatives)** : cas où un nid-de-poule réel est incorrectement classé comme une route saine.

-Spécificité (Specificity)

La spécificité est une mesure importante dans la classification binaire, car elle permet d'évaluer la capacité du modèle à reconnaître correctement les cas négatifs, c'est-à-dire les routes sans nid-de-poule. Elle est particulièrement utile pour vérifier que le système ne génère pas de fausses alertes, ce qui pourrait nuire à l'expérience de conduite assistée [12].

Pour calculer la Spécificité :

$$\text{Spécificité} = \frac{TN}{TN + FP} \times 100 \quad (3.2)$$

Une spécificité élevée indique que le modèle est performant pour éviter les erreurs de type faux positifs.

- Sensibilité (Sensitivity)

La sensibilité, également appelée rappel (Recall), mesure la capacité du modèle à détecter correctement les cas positifs, ou les nids-de-poule présents dans l'image. Elle est définie par la formule suivante :

$$\text{Sensibilité} = \frac{TP}{TP + FN} \times 100 \quad (3.3)$$

Cette métrique est particulièrement pertinente dans le cadre de notre étude , car l'un des objectifs principaux du système est de minimiser les cas de non-détection de nids-de-poule, ce qui peut avoir des conséquences importantes sur la sécurité du véhicule et de ses occupants.

- Évaluation à l'aide de la matrice de confusion

Les métriques précédemment présentées (précision, spécificité et sensibilité) peuvent être dérivées à partir d'un outil fondamental en classification supervisée : la matrice de confusion. Cette dernière permet de résumer visuellement et numériquement les performances d'un classifieur en indiquant les cas où les prédictions du modèle concordent ou non avec les valeurs réelles. Elle est composée de quatre éléments principaux dans le cadre d'un problème

Chapitre 3 : Analyse et interprétation des résultats

de classification binaire (classe positive vs classe négative), comme illustré dans le Tableau 3.1.

Tableau 3.1 : matrice de confusion

	Prédit	Nid-de-poule (1)	Sans nid-de-poule (0)
Valeur réelle			
Nid-de-poule (1)		TP (True Positive)	FN (False Negative)
Sans nid-de-poule (0)		FP (False Positive)	TN (True Negative)

3.4.5 Résultats et discussion (détection de nid de poule par ML)

Dans cette section, les résultats issus des expérimentations sont présentés, accompagnés d'une analyse interprétative permettant d'évaluer les performances du modèle proposé.

Nous avons mené deux expériences : la première en utilisant une base de données déséquilibrée, la seconde avec une base équilibrée. Pour chacune d'elles, nous avons varié le pourcentage d'images utilisées pour l'entraînement et le test. Par ailleurs, nous avons testé différentes combinaisons entre classifieurs et extracteurs de caractéristiques afin d'évaluer leur impact sur les performances.

A-Base des données non équilibrés :

Dans ce travail, la base de données utilisée pour la détection des nids-de-poule est déséquilibrée, c'est-à-dire que le nombre d'images représentant chaque classe n'est pas égal. Plus précisément, elle contient 310 images avec nid-de-poule et 200 images sans nid-de-poule. Ce déséquilibre peut avoir des conséquences importantes sur les performances des algorithmes de classification.

Le tableau ci-dessous présente les résultats de classification obtenus avec une base de données déséquilibrée.

1^{er} cas : - Apprentissage = 80%, test= 20%

Le tableau 3.2 illustre les performances de SVM et KNN sur une base de données non équilibrée, avec les descripteurs LBP et HOG, selon un découpage 80 % apprentissage / 20 % test.

Chapitre 3 : Analyse et interprétation des résultats

Tableau 3.2 : Performances de classification (accuracy) dans le cas d'une base de données non équilibrée (Apprentissage=80% ; Test=20%)

Classifieur	Descripteur	Accuracy (%)	Sensibilité (Recall) (%)	Spécificité (%)
SVM	HOG	89.77	85.2	85.20
	LBP	94.32	100	91.93
	HOG + LBP	52.27	28	100
KNN	HOG	85.23	82	90
	LBP	71.59	60	96.43
	HOG + LBP	75	64	97

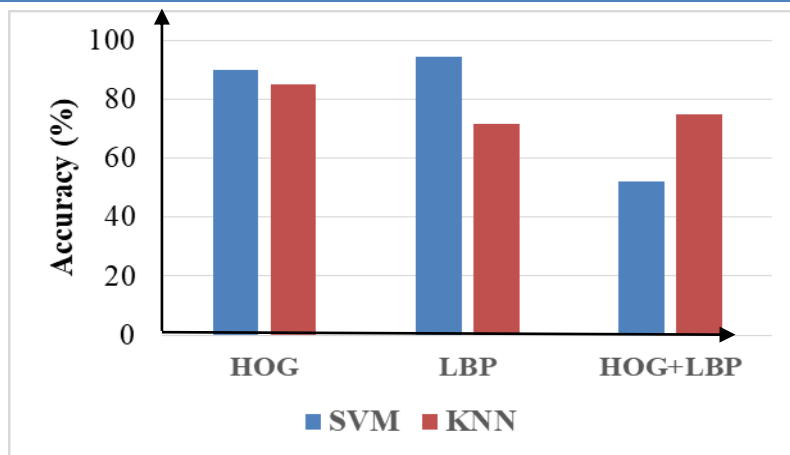


Figure 3.9 : Performances de classification (accuracy) dans le cas d'une base de données non équilibrée (Apprentissage=80% ; Test=20%)

Discussion :

Les résultats du tableau 3.2 montrent que la combinaison SVM + LBP offre les meilleures performances de classification (accuracy) de 94.32 %, une sensibilité parfaite (100 %) et une spécificité de 91.93 %, indiquant une détection optimale des nids-de-poule. À l'opposé, SVM + HOG + LBP enregistre une forte baisse de performance de classification (accuracy) de (52.27 %) et une sensibilité très faible (28 %) malgré une spécificité maximale (100 %), suggérant une incapacité à détecter les cas positifs.

2^{ème} cas : - Apprentissage = 70%, test= 30% :

Le tableau 3.3 illustre les performances de SVM et KNN sur une base de données non équilibrée, avec les descripteurs LBP et HOG, selon un découpage 70 % apprentissage / 30 % test.

Tableau 3.3 : Performances de classification (accuracy) dans le cas d'une base de données non équilibrée (Apprentissage=70% ; Test=30%)

Classifieur	Descripteur	Accuracy (80%,20%)	Accuracy (70%,30%)
SVM	HOG	97.8	89.77
	LBP	94.11	94.32
	HOG + LBP	100	52.27
KNN	HOG	90	85.23
	LBP	54.08	71.59
	HOG + LBP	42	75

Tableau 3.3 : Performances de classification (accuracy) dans le cas d'une base de données non équilibrée (Apprentissage=70% ; Test=30%)




Figure 3.10 : Performances de classification (accuracy) dans le cas d'une base de données non équilibrée (Apprentissage=70% ; Test=30%)

Discussion :

Dans ce second cas sur le tableau 3.3, SVM + HOG présente la meilleure performance de classification (accuracy) de 95.45 % et une sensibilité de 97.8 % , ce qui traduit une excellente capacité de généralisation. En revanche, KNN + HOG + LBP affiche la performance de classification (accuracy) la plus faible (56.82 %) et une sensibilité limitée (42 %), confirmant la moindre robustesse du KNN, surtout lorsqu'il est associé à descripteurs multiple

B- Base des données équilibrés :

Dans ce travail, la base de données utilisée pour la détection des nids-de-poule est équilibrée, c'est-à-dire que le nombre d'images représentant chaque classe est identique. Plus précisément, elle contient 310 images avec nid-de-poule et 310 images sans nid-de-poule. Cette répartition équilibrée permet d'éviter les biais lors de l'entraînement du modèle de

Chapitre 3 : Analyse et interprétation des résultats

classification et contribue à améliorer la robustesse et l'équité des performances de l'algorithme entre les différentes classes.

3^{ème} cas : - Apprentissage = 80%, test= 20%

Le tableau 3.4 illustre les performances de SVM et KNN sur une base de données équilibrée, avec les descripteurs LBP et HOG, selon un découpage 80 % apprentissage / 20 % test.

Tableau 3.4 : Performances de classification (Accuracy) dans le cas d'une base de données équilibrée (Apprentissage =80% ; Test=20%)

Classifieur	Descripteur	Accuracy (80%,20%)	Accuracy (70%,30%)
SVM	HOG	95.45	97.97
	LBP	96.18	93.29
	HOG + LBP	93.94	87.88
KNN	HOG	82.58	82.23
	LBP	71.76	74.62
	HOG + LBP	79.55	74.62

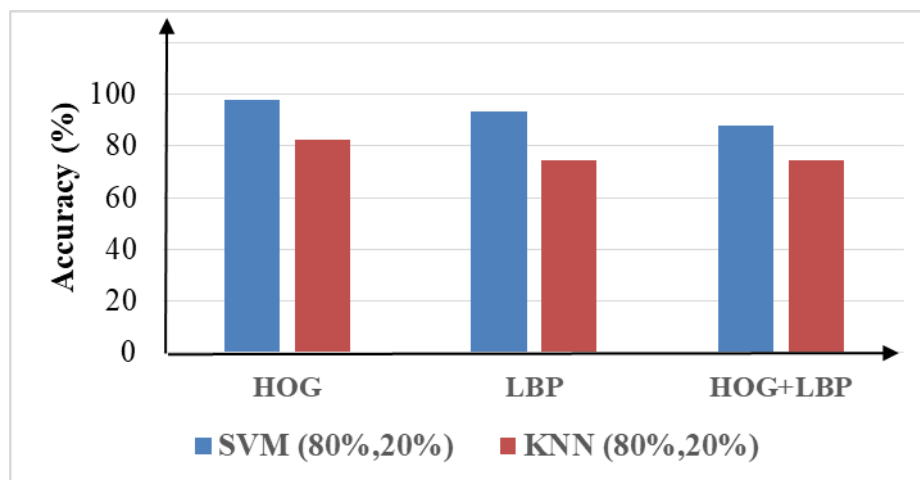


Figure 3.11 : Performances de classification (accuracy) dans le cas d'une base de données équilibrée (Apprentissage =80% ; Test=20%)

Discussion :

Dans ce cas où la base de données est équilibrée d'après les résultats du tableau 3.4, la configuration SVM + LBP se distingue avec 96.18 % de performance de classification (accuracy), 96.72 % de sensibilité et 95.71 % de spécificité, démontrant une très bonne aptitude à classer correctement les deux classes. À l'inverse, KNN + LBP affiche des

Chapitre 3 : Analyse et interprétation des résultats

performances limitées (71.76%), notamment une sensibilité très faible (38.33 %) , traduisant une difficulté à détecter les nids-de-poule malgré une spécificité parfaite (100 %).

4^{ème} cas : Apprentissage = 70%, test= 30% :

Le tableau 3.5 illustre les performances de SVM et KNN sur une base de données équilibrée, avec les descripteurs LBP et HOG, selon un découpage 70 % apprentissage / 30 % test.

Tableau 3.5 : Performances de classification (accuracy) dans le cas d'une base de données équilibrée (Apprentissage =70% ; Test=30%)

Classifieur	Descripteur	Accuracy (%)	Sensibilité (Recall) (%)	Spécificité (%)
SVM	HOG	97.97	97.87	98.06
	LBP	93.29	98.83	98.19
	HOG + LBP	87.88	100	77
KNN	HOG	82.23	64	97
	LBP	74.62	46.15	99.86
	HOG + LBP	74.62	44	99

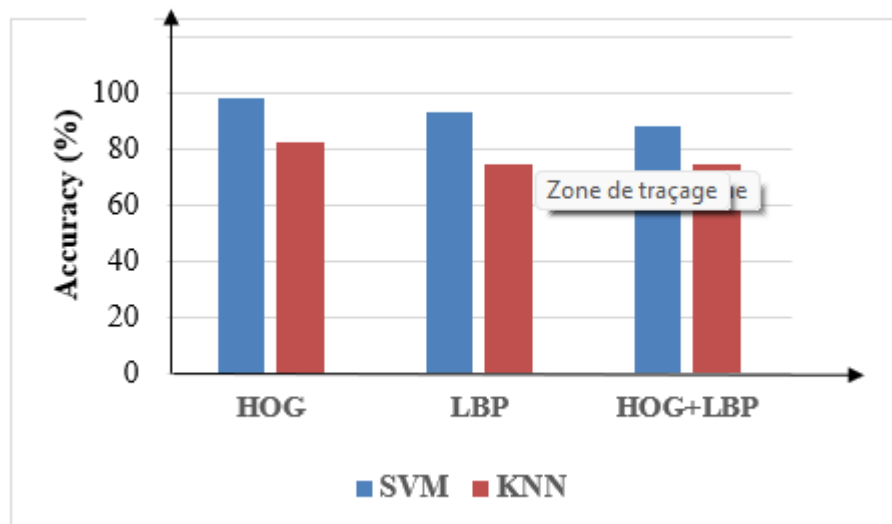


Figure 3.12 : Performances de classification (accuracy) dans le cas d'une base de données équilibrée (Apprentissage =70% ; Test=30%)

Discussion :

Le tableau 3.5 révèle que SVM + HOG atteint la meilleure performance de classification (accuracy) globale (97.97 %), avec un excellent équilibre entre sensibilité (97.87 %) et spécificité (98.06 %). Bien que SVM + HOG + LBP atteigne une sensibilité parfaite (100 %), la spécificité chute à 77 %, suggérant un taux élevé de faux positifs. KNN, quant à lui, montre

Chapitre 3 : Analyse et interprétation des résultats

une fois de plus des performances modestes, particulièrement en sensibilité (inférieure à 50 % dans certains cas).

C- Comparaison des performances des deux expériences :

Dans ce cas on va comparer les résultats des performances des deux expériences (base des données est équilibrée et non équilibrée).

- Comparaison des performances (Accuracy)

Tableau 3.6 : résultat récapitulatif des performances (accuracy) de différents classificateurs appliqués à des bases de données équilibrée et non équilibrée, en combinaison avec les descripteurs HOG et LBP.

Tableau 3.6 : Tableau de comparaison des performances de classification (accuracy)

		Accuracy (%)			
Base de données	Extracteur	SVM (80%,20%)	KNN (80%,20%)	SVM (70%,30%)	KNN (70%,30%)
Non équilibrée	HOG	89,77	85,23	95,45	89,39
	LBP	94,32	71,59	94,7	65,91
	HOG+LBP	52,27	75	87,88	56,82
Équilibrée	HOG	95,45	82,58	97,97	82,23
	LBP	96,18	71,76	93,29	74,62
	HOG+LBP	93,94	79,55	87,88	74,62

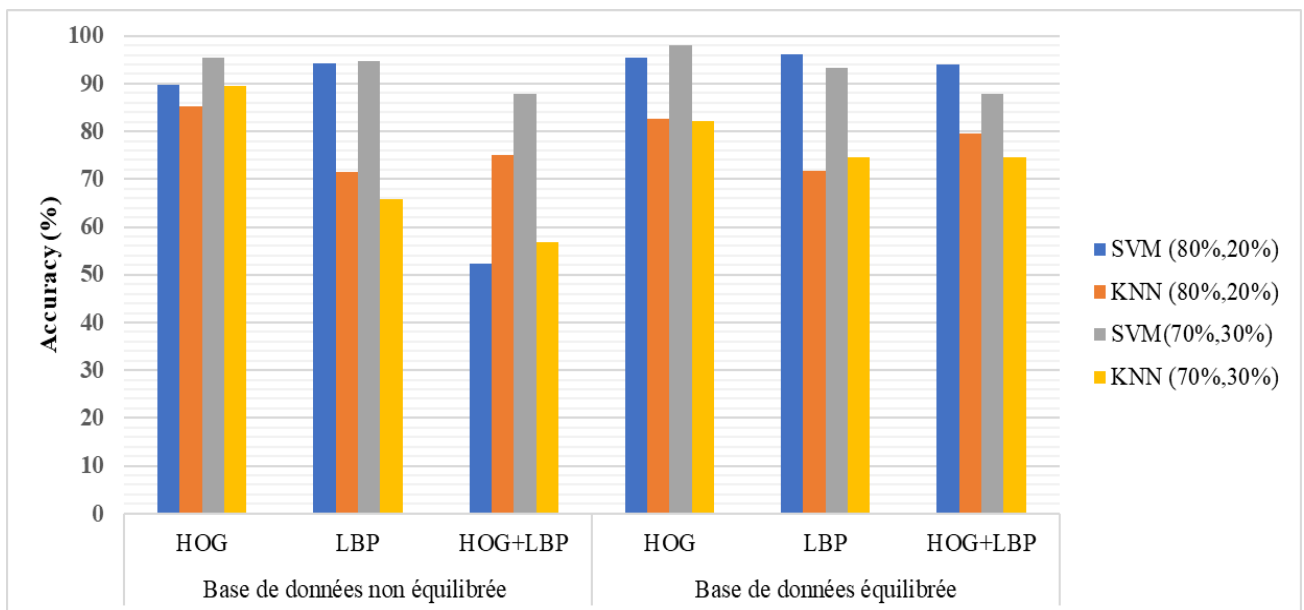


Figure 3.13 : Résultats de comparaison des performances (accuracy) des deux expériences

Discussion des résultats :

Les résultats obtenus à travers les différentes expériences permettent de comparer de manière approfondie les performances des classifieurs SVM et KNN dans la tâche de détection de nids-de-poule, en utilisant les descripteurs HOG, LBP et leur combinaison HOG+LBP. Les performances sont mesurées en termes de performance de classification, sensibilité (recall) et spécificité, sur des bases de données équilibrées et non équilibrées, et avec deux proportions d'entraînement/test : 80/20 et 70/30.

De manière générale, les classifieurs SVM surpassent les KNN dans presque toutes les configurations, quelle que soit la base utilisée. Cela s'explique par la capacité du SVM à optimiser les frontières de décision dans des espaces de grande dimension, ce qui est particulièrement pertinent lorsque les descripteurs produisent des vecteurs de caractéristiques complexes.

- Sur les bases non équilibrées, SVM atteint des précisions allant jusqu'à 95.45 % avec HOG et 94.70 % avec LBP (70/30), contre des performances significativement plus basses pour KNN.
- Sur les bases équilibrées, SVM affiche une précision maximale de 97.97 % (HOG, 70/30), confirmant sa robustesse.

-Comparaison des performances sensibilité et spécificité :

Comparaison des performances (sensibilité pour la détection des nids-de-poule et spécificité pour la détection correcte des routes saines) dans deux cas de répartition des données : 80 % pour l'apprentissage et 20 % pour le test, puis 70 % pour l'apprentissage et 30 % pour le test.

1^{er} Cas (Apprentissage 80 %, test 20 %) :

Le tableau 3.7 et la figure 3.16 ci-dessous présentent les résultats récapitulatifs des sensibilités et des spécificités de différents classificateurs appliqués à des bases de données équilibrée et non équilibrée, en combinaison avec les descripteurs HOG et LBP.

Chapitre 3 : Analyse et interprétation des résultats

Tableau 3.7 : résultat récapitulatif des sensibilités et des spécificités (Apprentissage 80 %, test 20 %).

Base de données	Extracteur	Classifieur	Sensibilité (%)	Spécificité (%)
Non équilibrée	LBP	SVM	100	91,93
		KNN	60	96,43
	HOG	SVM	85,2	85,2
		KNN	82	90
	HOG+LBP	SVM	28	100
		KNN	64	97
Équilibrée	LBP	SVM	96,72	95,71
		KNN	38,33	100
	HOG	SVM	96,6	94,5
		KNN	65	97
	HOG+LBP	SVM	97	92
		KNN	55	100




Figure 3.14: Résultats de comparaison des sensibilités et des spécificité (Apprentissage 80 %, test 20 %).

2^{ème} Cas (Apprentissage 70 % , test 30 %) :

Le tableau 3.8 et la figure 3.17 ci-dessous présentent les résultats récapitulatifs des sensibilités et des spécificités de différents classificateurs appliqués à des bases de données équilibrée et non équilibrée, en combinaison avec les descripteurs HOG et LBP.

Chapitre 3 : Analyse et interprétation des résultats

Tableau 3.8 : Résultat récapitulatif des sensibilités et des spécificités (Apprentissage 70 %, test 30 %).

Base de données	Extracteur	Classifieur	Sensibilité (%)	Spécificité (%)
Non équilibrée	LBP	SVM	94,11	94,89
		KNN	54,08	100
	HOG	SVM	97,8	90
		KNN	90	88,1
	HOG+LBP	SVM	100	66
		KNN	42	95
Équilibrée	LBP	SVM	98,83	98,19
		KNN	46,15	99,86
	HOG	SVM	97,87	98,06
		KNN	64	97
	HOG+LBP	SVM	100	77
		KNN	44	99

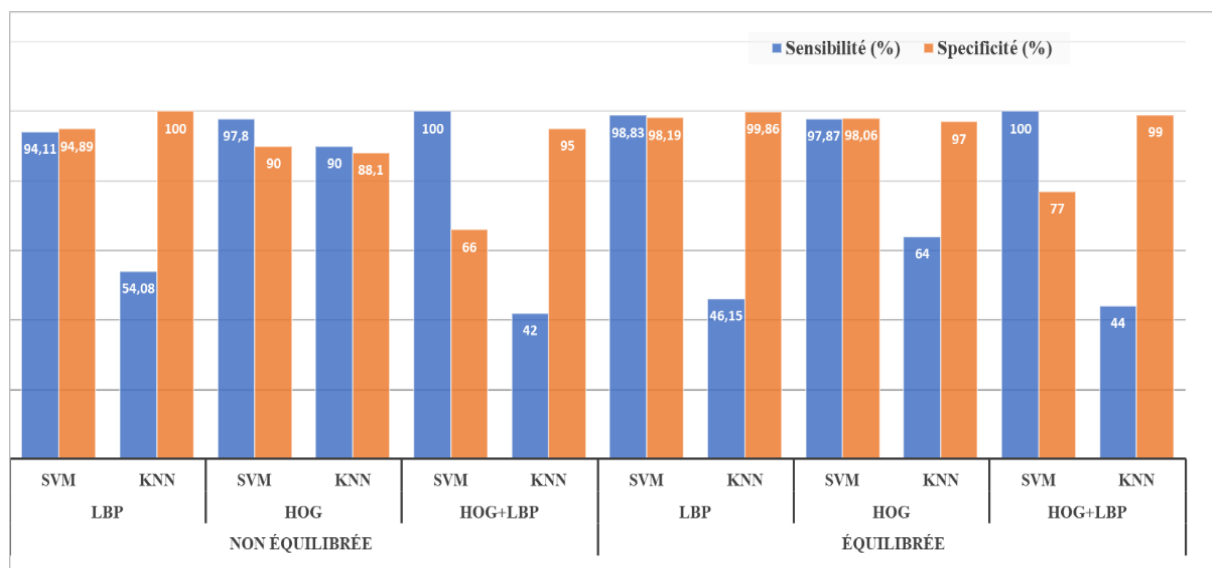


Figure 3.15 : Résultats de comparaison des sensibilités et des spécificité (Apprentissage 70 %, test 30 %).

Comparaison des sensibilités et spécificités (Tableau 3.7 et 3.8)

L'analyse croisée des sensibilités et spécificités indique que SVM + LBP (base des données non équilibrée, 80%/20%) nous donne une sensibilité maximale (100 %), tandis que SVM + HOG + LBP (même configuration) montre la plus faible sensibilité (28 %). Pour la spécificité, KNN + LBP ou KNN + LBP+HOG (équilibrée) atteignent systématiquement 100 %, mais au

Chapitre 3 : Analyse et interprétation des résultats

prix d'une sensibilité très faible, ce qui traduit une tendance à favoriser la détection des routes saines au détriment des anomalies.

3.4.6 Résultats et discussion (détection d'obstacle par capteur)

Les tests du jour:

1^{er} Test :

Tableau 3.9 :test 1 des capteurs dans le jour

Distance (cm) / Capteur	10	15	20	30	80	200
Ultrason	9.95	14.22	21.11	29.28	80.35	198.84
IR	10.42	14.53	20.43	30.34	79.73	Pas détecté

Les résultats montrent une bonne précision pour le capteur ultrason à toutes les distances testées, tandis que le capteur IR devient imprécis à longue portée (2 m), où il ne détecte plus l'obstacle.

2^{eme} Test:

Tableau 3.10 :test 2 des capteurs dans le jour

distance (cm) / Capteur	10	15	20	30	80	200
Ultrason	10.77	15.13	20.22	30.27	80.11	195.61
IR	10.35	16.31	20.08	30.71	79.73	Pas détecté

Les deux capteurs présentent une stabilité satisfaisante, mais l'IR reste limité à une portée inférieure à 2 m, confirmant sa faible efficacité à longue distance.

Chapitre 3 : Analyse et interprétation des résultats

3^{ème} Test:

Tableau 3.11 :test 3 des capteurs dans le jour

distance (cm) Capteur	10	15	20	30	80	200
Ultrason	9.96	15.49	20.99	30.15	80.08	211.09
IR	10.73	15.75	21.24	30.09	79.73	Pas détecté

La Stabilité des mesures du capteur ultrason confirme sa fiabilité, alors que le capteur IR commence à montrer une légère amélioration sans pour autant détecter à 2 m.

Les tests de nuit:

1^{er} Test:

Tableau 3.12 :test 1 des capteurs dans la nuit

distance (cm) Capteur	10	15	20	30	80	200
ultrason	10.82	15.13	20.39	30.39	80.63	207.13
IR	13.22	16.92	22.65	32.49	N'est pas stable	Pas détecté

Le capteur ultrason reste très stable malgré l'absence de lumière, tandis que l'IR devient instable à partir de 20 cm et cesse de détecter au-delà de 80 cm.

Chapitre 3 : Analyse et interprétation des résultats

2^{ème} Test:

Tableau 3.13 :test 2 des capteurs dans la nuit

distance (cm) Capteur	10	15	20	30	80	200
ultrason	10.42	15.66	20.17	30.29	80.53	195.81
IR	9.75	15.88	19.91	31.87	N'est pas stable	Pas détecté

Les performances de l'ultrason restent constantes. En revanche, l'IR est instable au-delà de 80 cm, ce qui confirme sa sensibilité aux conditions de luminosité.

3.5 Discussion générale :

L'ensemble des expérimentations réalisées dans ce chapitre a permis d'évaluer de manière approfondie les performances de différents classifieurs et descripteurs dans le cadre de la détection automatique des nids-de-poule par vision par ordinateur. Les résultats obtenus à partir de différentes configurations (bases équilibrées et non équilibrées, taux d'apprentissage variables) montrent une tendance constante : les modèles basés sur le classifieur SVM surpassent nettement ceux utilisant KNN, en termes de précision globale, de sensibilité et de spécificité.

Les descripteurs HOG et LBP, pris individuellement, ont démontré une efficacité notable pour extraire des caractéristiques discriminantes, notamment LBP dans le cas des surfaces texturées. En revanche, la combinaison HOG + LBP n'a pas systématiquement amélioré les performances. Dans certains cas, elle a même entraîné une baisse de la sensibilité, probablement en raison d'une redondance d'information ou d'une complexité accrue du vecteur de caractéristiques.

Par ailleurs, l'influence du déséquilibre des données a également été mise en évidence. Lorsque la base de données est équilibrée, les performances des classifieurs sont globalement meilleures et plus stables, notamment pour la classe minoritaire. Cela souligne l'importance d'un bon échantillonnage pour éviter les biais et améliorer la généralisation du modèle.

Chapitre 3 : Analyse et interprétation des résultats

En complément des tests de classification, des expérimentations sur la fusion de capteurs à ultrasons et infrarouge ont été réalisées. Les résultats ont montré que le capteur ultrason offre une très bonne précision et stabilité, y compris en conditions de faible éclairage. En revanche, le capteur IR présente des limitations significatives en termes de portée et de stabilité, particulièrement en extérieur et en forte luminosité.

Ces observations confirment la pertinence de la fusion de données multi-capteurs, qui permet de compenser les faiblesses individuelles de chaque capteur et d'accroître la robustesse globale du système. Enfin, les résultats obtenus à ce stade valident l'approche proposée et ouvrent des perspectives vers des solutions plus avancées, notamment basées sur des réseaux de neurones profonds, des systèmes embarqués en temps réel, ou encore l'intégration dans des véhicules intelligents.

3.6 Conclusion :

Dans ce chapitre, on a présenté l'implémentation expérimentale du système de détection automatique des nids-de-poule, en combinant des techniques de vision par ordinateur, des descripteurs d'images et des algorithmes d'apprentissage supervisé. Une base de données d'images réelles a été constituée, reflétant une variété de situations routières et utilisée pour entraîner et évaluer différents classifieurs.

Les descripteurs HOG et LBP ont permis d'extraire des caractéristiques pertinentes des surfaces routières, facilitant ainsi la distinction entre les images contenant des anomalies et celles représentant des chaussées saines. Ces descripteurs ont été exploités par deux classifieurs (SVM, KNN) dans le but de comparer leurs performances.

L'analyse des résultats, fondée sur les métriques standards (précision, sensibilité, spécificité), a mis en évidence la supériorité du classifieur SVM, notamment lorsqu'il est associé au descripteur LBP. Cette configuration a montré une forte capacité de détection, avec un taux de bonnes prédictions élevé et une meilleure robustesse face aux erreurs.

En complément, une expérimentation matérielle basée sur la fusion de capteurs à ultrasons (HC-05) et infrarouge a permis de renforcer la détection d'obstacles. Les résultats ont démontré l'intérêt de la fusion de données pour renforcer la fiabilité de la perception embarquée, en particulier dans des conditions environnementales variables.

Conclusion générale

Conclusion générale

Aujourd'hui, les technologies intelligentes transforment profondément la conduite automobile. L'assistance à la conduite, notamment pour détecter les obstacles et les irrégularités de la route, permet d'améliorer la sécurité et le confort des conducteurs. Dans ce mémoire, nous avons proposé une solution basée sur un capteur intelligent conçu pour la détection d'obstacles lors des manœuvres de stationnement, ainsi qu'à la reconnaissance des nids-de-poule sur la chaussée.

Pour cela, nous avons combiné deux approches complémentaires : l'utilisation de capteurs physiques (ultrasons et infrarouge) pour mesurer les distances des obstacles, et l'intelligence artificielle pour analyser des images et reconnaître les défauts de la route. Grâce à une carte Arduino, nous avons intégré les capteurs dans un prototype fonctionnel, en appliquant une fusion de données par moyenne pondérée afin d'augmenter la précision des mesures.

En parallèle, nous avons conçu un modèle de classification d'images pour distinguer les routes saines des routes abîmées. Les algorithmes SVM et KNN, associés aux descripteurs HOG et LBP, ont été utilisés pour entraîner un classifieur capable de détecter efficacement les nids-de-poule à partir d'une base d'images.

En parallèle, nous avons conçu un modèle de classification d'images pour distinguer les routes saines des routes abîmées. Les algorithmes SVM et KNN, associés aux descripteurs HOG et LBP, ont été utilisés pour entraîner un classifieur capable de détecter efficacement les nids-de-poule à partir d'une base d'images. Les résultats obtenus ont révélé que la combinaison SVM+HOG offre les meilleures performances en termes de précision.

Cette supériorité peut s'expliquer par plusieurs facteurs. D'une part, HOG est particulièrement efficace pour capturer les contours et les variations directionnelles dans les images, ce qui est pertinent pour détecter la structure irrégulière et les bords marqués des nids-de-poule. D'autre part, le classifieur SVM est bien adapté aux problèmes de classification binaire avec un volume de données modéré, comme c'est le cas ici (310 images). Il est robuste aux dimensions élevées des vecteurs de caractéristiques générés par HOG, et permet une séparation optimale entre les classes en maximisant la marge.

En revanche, bien que LBP soit un descripteur de texture efficace et rapide, il est moins sensible aux formes globales, ce qui peut limiter sa performance pour la détection de

structures aussi spécifiques que les nids-de-poule. De plus, KNN, en tant que classificateur basé sur la distance, est plus sensible au bruit et à la distribution des données, ce qui peut expliquer ses performances légèrement inférieures.

Enfin, les résultats obtenus montrent que notre système est fonctionnel, simple à mettre en œuvre, et peut être utilisé comme base pour des applications réelles d'aide à la conduite. Cependant, certaines limites restent à corriger, comme la performance du système en cas de conditions météorologiques défavorables ou dans des environnements plus complexes.

Perspectives :

À l'issue de ce travail, plusieurs pistes d'amélioration peuvent être envisagées afin de renforcer la robustesse et l'efficacité du système :

Utiliser des algorithmes d'apprentissage automatique plus avancés, notamment les réseaux de neurones convolutifs (CNN), pour améliorer la précision de la classification des images ;

En termes de fusion de données, développer un algorithme qui permet d'établir le lien entre différents types de données issus de capteurs de différents nature, tels que capteurs IR, Ultrason, radar, LIDAR et camera, ce qui fera un réel défi entre données sous forme de signaux unidimensionnels, un nuage de point 3D et des images 2D. Intégrer une multitude de capteurs permet d'obtenir une perception plus fine et plus fiable de l'environnement routier.

Miniaturiser le système dans le but de faciliter son intégration dans un véhicule réel sans encombrement.

Tester et valider la solution sur un plus grand échantillon de cas réels, en diversifiant les environnements d'expérimentation (zones urbaines et rurales, conditions météorologiques différentes).

En somme, ce mémoire pose les bases d'un système embarqué intelligent pour l'assistance à la conduite. Il ouvre la voie à des travaux plus poussés en vue de concevoir des solutions plus autonomes, plus sûres et mieux adaptées aux défis de la mobilité de demain.

Bibliographie

Bibliographie

- [1] KIDIQUI. "Voiture autonome". In : Kidioui, France (consulté le 15/03/2022). Disponible sur : <https://voiture.kidioui.fr/lexique-automobile/voiture-autonome.html>
- [2] NATIONAL ACADEMY OF SCIENCES. "Autonomous Vehicle Technologies: Challenges and Opportunities". In : National Academies Press, États-Unis (2022).
- [3] BISHOP R. "A History of Automated Vehicles". In : "IEEE Transactions on Vehicular Technology", vol. 54, n°3, pp. 891–903 (2005).
- [4] SAE INTERNATIONAL. "J3016: Taxonomy and Definitions for Terms Related to Driving Automation Systems". In : SAE International (2021). Disponible sur : <https://www.sae.org/standards>
- [5] USINE DIGITALE. "Niveaux d'autonomie des véhicules". In : Usine Digitale, France (consulté le 16/04/2022).
Disponible sur : <https://www.usine-digitale.fr/article/reperes-quels-sont-les-differents-niveaux-d-autonomie-des-vehicules.N596558>
- [6] ANDRIĆ M., ZRNIC B.M., BONDZULIC B. "Feature Extraction Related to Target Classification for a Radar Doppler Echoes". In : "18th Telecommunications Forum TELFOR", novembre 2010.
- [7] FRÉDÉRIC S. "Introduction à l'apprentissage automatique". In : École des Mines de Nancy, France (2023).
- [8] ALPAYDIN E. "Introduction to Machine Learning". In : MIT Press, England (2020).
- [9] AHA D.W., KIBLER D., ALBERT M.K. "Instance-based learning algorithms". In : "Machine Learning", vol. 6, n°1, pp. 37–66 (1991).
- [10] HUANG D., SHAN C., ARDABILIAN M., WANG Y., CHEN L. "Local binary patterns and its application to facial image analysis" (2011).
- [11] DIEBOLD F.X., MARIANO R.S. "Comparing predictive accuracy". In : "Journal of Business and Economic Statistics", vol. 20, n°1, pp. 134–144 (2002).
- [12] BUCKLAND M., GEY F. "The relationship between recall and precision". In : "Journal of Information Science" (1994).
- [13] KAGGLE. "Datasets". In : Kaggle, consulté en 2022. Disponible sur : <https://www.kaggle.com/datasets>

Bibliographie

[14] COVER T., HART P. "Nearest neighbor pattern classification". In : "IEEE Transactions on Information Theory", vol. 13, n°1, pp. 21–27 (1967).

[15] DUDA R.O., HART P.E., STORK D.G. "Pattern Classification" (2^e édition). In : Wiley, États-Unis (2000).

[16] CORTES C., VAPNIK V. "Support-vector networks". In : "Machine Learning", vol. 20, n°3, pp. 273–297 (1995).

[17] HSU C.W., CHANG C.C., LIN C.J. "A practical guide to support vector classification". In : Department of Computer Science, National Taiwan University (2016).

[18] ALTMAN N.S. "An introduction to kernel and nearest-neighbor nonparametric regression". In : "The American Statistician", vol. 46, n°3, pp. 175–185 (1992).