



وزارة البحث العلمي والتعليم العالي
MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR
ET DE

LA RECHERCHE SCIENTIFIQUE

جامعة عبد الحميد بن باديس مستغانم

Université Abdelhamid Ibn Badis Mostaganem

كلية العلوم والتكنولوجيا

Faculté des Sciences et de la Technologie

DEPARTEMENT DE GENIE ELECTRIQUE



N° d'ordre : M...../GE/2026

Mémoire de fin d'étude Présenté pour obtenir le diplôme de Master académique

Filière : Automatique

Spécialité : Automatique et informatique industrielle

Présenté Par

BENICHOU Khadidja et REGUIEG Nedjma

**Détection et classification des dégradations de la route
(nids-de-poule) à l'aide de l'apprentissage automatique pour
les systèmes de transport intelligents**

Soutenu le 11 / 06 / 2026 devant le jury composé de :

Président :	Mr BERRADJA Khadidja	MCA	Université de Mostaganem
Examineur :	Mr BENDANI Djazia	MAA	Université de Mostaganem
Rapporteur :	M. BENAOUALI Mohamed	MCB	Université de Mostaganem.

Année Universitaire 2025/2026

Remerciements

Avant toute chose, on rends grâce à Allah, le Tout-Puissant, pour Sa bénédiction, Son soutien et Sa guidance tout au long de mon parcours. C'est grâce à Sa volonté que nous avons pu surmonter les difficultés rencontrées et mener à bien ce travail, qui représente l'aboutissement de plusieurs années d'efforts et de persévérance.

Nous adressons nos sincères remerciements à notre encadreur, Monsieur **BENAOUALI Mohamed**, pour son accompagnement précieux, sa disponibilité, ses conseils judicieux et la confiance qu'il nous a accordée durant la réalisation de ce projet. Son expertise, sa rigueur scientifique et son soutien constant ont été d'une grande importance pour l'aboutissement de ce travail.

Nous tenons également à exprimer notre profonde gratitude à Madame **BERRADJA Khadidja**, Présidente du jury, ainsi qu'à Madame **BENDANI Djazia**, pour l'honneur qu'elles nous ont fait en acceptant d'évaluer ce mémoire. Nous les remercions pour l'attention portée à ce travail ainsi que pour leurs remarques et suggestions constructives.

Nos remerciements s'adressent également au directeur du laboratoire Signaux et Systèmes, pour nous avoir accueillis au sein du laboratoire et pour les conditions favorables mises à notre disposition afin de mener à bien ce projet.

Nous souhaitons enfin remercier chaleureusement l'ensemble de nos enseignants qui, depuis nos premières années d'études jusqu'à l'université, ont contribué à notre formation par la transmission de leurs connaissances, leur dévouement et leur engagement. Leurs enseignements ont constitué les fondements essentiels de notre parcours académique et professionnel.

À toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce travail, on témoigne nos sincère reconnaissance et nos remerciements les plus respectueux.

Dedicaces :

Avant tout, je remercie Dieu de m'avoir donné la force, la patience et la volonté nécessaires pour mener à bien ce travail.

Je dédie ce mémoire à moi-même, pour tous les efforts fournis, les défis surmontés et la persévérance dont j'ai fait preuve tout au long de ce parcours.

À ma très chère mère, dont l'amour, les sacrifices et les encouragements ont toujours été ma plus grande source de motivation.

À mon cher père, pour son soutien, ses conseils précieux et sa confiance qui m'ont accompagnée à chaque étape de ma vie.

À mes frères et sœurs, pour leur affection, leur présence et leurs encouragements constants.

À toute ma famille, qui m'a soutenue de près ou de loin et qui a partagé avec moi les moments difficiles comme les moments de réussite.

Je vous adresse à tous ma profonde gratitude et mon immense reconnaissance.

Avec tout mon amour et mon respect.

Reguieg nedjma

Dédicace

Je dédie ce travail à ma chère famille, pour son amour, son soutien, ses encouragements et les sacrifices consentis tout au long de mon parcours.

À mes parents, qui ont toujours cru en moi et m'ont donné la force d'avancer.

À mes frères et sœurs, pour leur présence et leurs encouragements.

À mon cher mari, pour sa patience, son soutien indéfectible, sa confiance et son aide précieuse durant la réalisation de ce projet.

À tous ceux qui ont contribué de près ou de loin à la réussite de ce travail.

Avec toute ma gratitude et mon affection.

khadidja

Benichou

Résumé :

Ce mémoire porte sur le développement et la mise en œuvre d'un système intelligent dédié à la détection automatique des nids-de-poule pour les Systèmes de Transport Intelligent (STI) afin de renforcer la sécurité routière. La solution proposée repose sur les techniques de vision par ordinateur et d'apprentissage automatique pour traiter les images capturées par une caméra embarquée sur un véhicule et analysées à l'aide d'une plateforme Raspberry Pi 5. Après une phase de prétraitement des images, les caractéristiques pertinentes sont extraites à l'aide des descripteurs LBP et HOG, puis analysées par des classificateurs tels que SVM et ANN afin de différencier les chaussées en bon état de celles présentant des dégradations sous forme de nids-de-poule. Les résultats de la détection sont indiqués en temps réel par l'allumage d'une LED signalant la présence d'un nid-de-poule. Les tests effectués montrent des performances satisfaisantes du système, tout en soulignant certaines contraintes liées à la qualité des images et aux conditions environnementales.

Mots clés : *détection, nid de poule, LBP, HOG, SVM, ANN, raspberrypi5, Systèmes de Transport Intelligent (STI)*

Abstract :

This dissertation focuses on the development and implementation of an intelligent system for the automatic detection of potholes in order to enhance road safety. The proposed approach is based on computer vision and machine learning techniques to process images captured by an onboard camera mounted on a vehicle and analyzed using a Raspberry Pi 5 platform. After an image preprocessing phase, relevant features are extracted using the LBP and HOG descriptors and then analyzed by classifiers such as SVM and ANN to distinguish between roads in good condition and those affected by pothole-related damage. The detection results are displayed in real time through the activation of an LED, which signals the presence of a pothole. The tests carried out demonstrate satisfactory system performance while highlighting certain limitations related to image quality and environmental conditions.

Keywords: *Pothole Detection, Potholes, LBP, HOG, SVM, ANN, Raspberry Pi 5, Intelligent Transportation Systems (ITS).*

ملخص

تتناول هذه المذكرة تطوير وتنفيذ نظام ذكي مخصص للكشف التلقائي عن الحفر في الطرق بهدف تعزيز السلامة المرورية. يعتمد النهج المقترح على تقنيات الرؤية الحاسوبية والتعلم الآلي لمعالجة الصور الملتقطة بواسطة كاميرا مثبتة على مركبة، والتي يتم تحليلها باستخدام منصة راسبيري باي 5. بعد مرحلة المعالجة المسبقة للصور، يتم استخراج الخصائص المهمة باستخدام واصفي **LBP** و **HOG**، ثم تحليلها بواسطة مصنفات مثل **SVM** و **ANN** للتمييز بين الطرق السليمة وتلك التي تحتوي على أضرار تتمثل في الحفر. يتم عرض نتائج الكشف في الوقت الحقيقي من خلال إضاءة مصباح **LED** للإشارة إلى وجود حفرة. وقد أظهرت الاختبارات المنجزة أداءً مرضياً للنظام، مع الإشارة إلى بعض القيود المرتبطة بجودة الصور والظروف البيئية المحيطة.

الكلمات المفتاحية: كشف الحفر، الحفر الطرقية، الأنماط الثنائية المحلية (**LBP**)، مدرج التدرجات الموجهة (**HOG**)، آلة المتجهات الداعمة (**SVM**)، الشبكات العصبية الاصطناعية (**ANN**)، راسبيري باي 5 (**Raspberry Pi 5**)، أنظمة النقل الذكية (**ITS**) .

Table des matières

<i>Résumé</i>	<i>iii</i>
Liste des figures	iv
Liste des tableaux.....	iv
Liste des symboles	vi
Introduction générale.....	viii
Chapitre 1 : Les systèmes de transport intelligent	
1.1.Introduction	1
1.2.Définition des systèmes de transport intelligent	1
1.3.Objectifs et importance des STI	2
1.3.1. Importance des STI dans la mobilité moderne.....	2
1.3.1.1. Enjeu Environnemental.....	2
1.3.1.3. Sécurité et santé publique.....	2
1.3.1.4. Confort de l'utilisateur.....	3
1.4. Composants des systèmes de transport intelligent	3
1.5. Application des systèmes de transport intelligent	5
1.6. Architecture des systèmes de transport intelligent.	7
1.7. Exemple des systèmes de transport intelligent dans le monde	8
1.7.1. Hangzhou Chine le City Brain.....	8
1.7.2. Singapour Plan Mobilité Intelligente 2030.....	8
1.7.3. Oslo Norvège capitale mobilité électrique.....	9
1.7.4. Espagne routes connectées.....	9
1.7.5. Lyon et Bordeaux renforcent le transport public.....	9
1.8. Vision par ordinateur dans les STI	10
1.8.1. Les tâches fondamentales de la vision	10
1.8.2. Applications Embarquées (Véhicules).....	10
1.8.3. Applications pour infrastructures villes intelligentes.....	11
1.8.4. Défis techniques et leurs solutions.....	11
1.9. Détection automatique des défauts de la route.	12
1.9.1. Méthodes de détection par caméra.....	12
1.9.2. Analyse du profil tridimensionnel par Lidar et laser.....	13

1.9.3. Détection avec accéléromètres.....	13
1.10. Structure d'un système embarqué de détection.....	13
1.11. Avantage des systèmes de transport intelligent :.....	14
1.12. Conclusion :.....	15

Chapitre 2 : Vision par ordinateur pour la détection des défauts routiers

2.1. Introduction	18
2.2. Définition de conduit intelligent.....	18
2.3. Notion d'apprentissage automatique (machine Learning)	19
2.3.1. Machine Learning.....	20
2.3.2. Machine Learning supervisé..	22
2.3.3. Le Machine Learning non supervise	22
2.4. Extraction des caractéristiques (feature extraction) :.....	23
2.4.1. Méthode LBP (local binary pattern).....	23
2.4.2. Méthode HOG (histogram of oriented gradients).	24
2.5. Méthode de classification.....	26
2.5.1. Le classifieur SVM	27
2.5.2. Réseau de neurones artificiels (ANN)	28
2.6. Conclusion	30

Chapitre 3 : Développement et implémentation du système de détection des nids-de-poule

3.1. Introduction	33
3.2. Architecture globale du système matériel et logiciel.....	33
3.2.1. Description générale du système embarqué	33
3.2.2. Schéma fonctionnel de la solution proposée	33
3.3. Développement et implémentation du système.....	34
3.3.1. Partie conception du modèle de classification	35
3.3.1.1. Acquisition et base de données d'images ..	35
3.3.1.2. Prétraitement des images	36
3.3.1.3. Extraction des caractéristiques	37
3.3.1.4. Classification	38
3.3.1.5. Métriques de mesure :.....	39

3.3.1.6. Résultats et performances des classificateurs	40
3.3.2. Partie implémentation sur Raspberry Pi5	44
3.3.2.1. Présentation de la plateforme Raspberry Pi5.....	44
3.3.2.2. La caméra Web 812H	46
3.3.2.3 Diode électroluminescente (LED).....	47
3.3.2.4. Configuration du Raspberry Pi5.....	47
3.3.3. Résultats de la classification en temps réel.....	49
3.4. Conclusion.....	50
Conclusion générale et perspectives	52-
	53

Liste des figures

Figure 1.1 : Exemple de collecte, traitement et échange des données dans les systèmes de 5

transport intelligents

Figure 1.2 : Application des systèmes de transport intelligent 8

Figure 1.3 : Architecture des systèmes de transport intelligent 8

Figure 1.4 : Avantage des systèmes de transport intelligent 15

Figure 2.1 : Apprentissage automatique 20

Figure 2.2 : Principe du Machine Learning 21

Figure 2.3 : Codages des pixels par extraction des caractéristiques 24

Figure 2.4 : Histogramme de caractéristique LBP 24

Figure 2.5 : Exemple d'application du HOG sur une image 26

Figure 2.6 : Séparation des classes par hyperplan optimal à l'aide du SVM . 28

Figure 2.7 : Architecture d'un réseau de neurones artificiels (ANN) 30

Figure 3.1 : Schéma bloc de la solution proposée 33

Figure 3.2 : Exemples d'images collectées à partir de la plateforme Kaggle 35

Figure 3.3 : Exemple d'application du LBP sur une image présentant un nid-de-poule 36

Figure 3.4 : Exemple d'application du HOG sur une image présentant un nid-de-poule 37

Figure 3.5 : comparaison des méthodes LBP et HOG selon les mesures de performance 41

accuracy ,precision et recall (cas base de données non équilibrée)

Figure 3.6 : comparaison des méthodes LBP et HOG selon les mesures de performance 42

accuracy ,precision et recall (cas base de données équilibrée)

Figure 3.7 : Architecture Raspberry Pi 44

Figure 3.8 : Photo de la caméra Web 812H 45

Figure 3.9 : Photo d'une diode électroluminescente (DEL) 46

Figure 3.10 : Environnement Python 47

Figure 3.11 : Photo du travail réel en laboratoire 49

Liste des tableaux :

Tableau 2.1 : Comparaison entre LBP et HOG	26
Tableau 3.1 : matrice de confusion	38
Tableau 3.2 : performance de classification dans le cas de la base de données non équilibrée	40
Tableau 3.3 : performance de classification dans le cas de la base de données équilibrée	41

Liste des symboles :

TP : True Positive (Vrai positif)
TN : True Negative (Vrai négatif)
FP : False Positive (Faux positif)
FN : False Negative (Faux négatif)
Accuracy : Taux de bonne classification
Precision : Précision du modèle
Recall : Taux de rappel (sensibilité)
LBP : Local Binary Pattern
HOG : Histogram of Oriented Gradients
SVM : Support Vector Machine
ANN : Artificial Neural Network
ROI : Region Of Interest (Région d'intérêt)
R : Rayon utilisé dans l'algorithme LBP
P : Nombre de voisins dans l'algorithme LBP
GPIO : General Purpose Input/Output
LED (DEL) : Diode Électroluminescente
GHz : Gigahertz
Go : Gigaoctet
USB : Universal Serial Bus
OpenCV : Open Source Computer Vision Library

Accuracy : Exactitude globale du classifieur

Precision : Proportion des détections positives correctes

Recall : Capacité à détecter tous les nids-de-poule présents

AI : Artificial Intelligence (Intelligence Artificielle)

ML : Machine Learning (Apprentissage Automatique)

CNN : Convolutional Neural Network

LiDAR : Light Detection And Ranging

GPS : Global Positioning System

ReLU : Rectified Linear Unit

X : Vecteur de caractéristiques

W : Vecteur de poids du modèle SVM

B : Biais

Z : Somme pondérée

A : Sortie du neurone

F : Fonction d'activation

Y : Valeur réelle

Y : Valeur prédite

LED / DEL : Diode électroluminescente

GPIO : General Purpose Input Output

USB : Universal Serial Bus



Introduction générale

L'état des infrastructures routières constitue un enjeu majeur pour la sécurité des usagers, le confort de conduite et l'efficacité des systèmes de transport. Parmi les différentes dégradations pouvant affecter la chaussée, les nids-de-poule représentent l'un des défauts les plus fréquents et les plus dangereux. Leur présence peut provoquer des accidents, endommager les véhicules et engendrer des coûts importants de maintenance. Dans ce contexte, la mise en place de solutions intelligentes capables de détecter automatiquement ces anomalies devient une nécessité pour améliorer la gestion et la sécurité du réseau routier.

L'évolution des technologies de l'information et de la communication a conduit à l'émergence des systèmes de transport intelligents (STI), qui visent à intégrer des moyens de communication, de traitement et d'analyse des données afin d'optimiser la mobilité, de renforcer la sécurité routière et de réduire les impacts environnementaux liés au transport. Parallèlement, les progrès réalisés dans les domaines de la vision par ordinateur et de l'apprentissage automatique offrent aujourd'hui de nouvelles possibilités pour l'automatisation des tâches d'inspection et de surveillance des infrastructures routières.

Dans ce travail, nous proposons la conception et le développement d'un système embarqué de détection automatique des nids-de-poule basé sur l'analyse d'images de la chaussée. La solution développée combine des techniques de vision par ordinateur pour le traitement et l'extraction des caractéristiques des images, ainsi que des algorithmes de Machine Learning pour la classification des défauts routiers. L'ensemble est implémenté sur une plateforme Raspberry Pi 5 afin de permettre un fonctionnement autonome et en temps réel.

Ce mémoire est organisé en trois chapitres. Le premier chapitre présente les concepts fondamentaux des systèmes de transport intelligents, leurs architectures, leurs applications ainsi que les défis liés à leur mise en œuvre. Le deuxième chapitre est consacré à la vision par ordinateur et aux techniques d'apprentissage automatique utilisées pour la détection des défauts routiers, en mettant l'accent sur les méthodes de traitement d'images, d'extraction de caractéristiques et de classification. Enfin,

le troisième chapitre décrit la mise en œuvre pratique de la solution proposée, depuis la conception de l'architecture matérielle et logicielle jusqu'à l'évaluation expérimentale du système de détection des nids-de-poule en temps réel.

Chapitre 1 : Les systèmes de transport intelligent

1.1. Introduction

L'évolution rapide des technologies de l'information, des communications et de l'intelligence artificielle a profondément transformé le domaine des transports. Face à l'augmentation du trafic routier et aux exigences croissantes en matière de sécurité, de mobilité et de confort, de nouvelles solutions technologiques ont été développées afin d'améliorer la gestion des infrastructures et des déplacements. Parmi les nombreux défis rencontrés par les gestionnaires routiers, la dégradation des chaussées et la présence de nids-de-poule constituent des problèmes majeurs pouvant entraîner des dommages matériels, réduire le confort des usagers et augmenter le risque d'accidents.

Dans ce contexte, les systèmes de transport intelligents (STI) jouent un rôle essentiel en intégrant des technologies de communication, de perception et de traitement des données permettant une surveillance continue de l'environnement routier. Grâce à l'utilisation de capteurs, de caméras embarquées et d'algorithmes d'intelligence artificielle, ces systèmes sont capables de collecter, analyser et exploiter des informations en temps réel afin d'améliorer la sécurité routière et la qualité des infrastructures. La détection automatique des défauts de chaussée, notamment des nids-de-poule, s'inscrit pleinement dans cette démarche en offrant une solution efficace pour l'inspection et la maintenance préventive des routes.

Ce chapitre présente les concepts fondamentaux des systèmes de transport intelligents, leurs architectures et leurs principaux domaines d'application. Il décrit également les technologies de communication et de perception utilisées dans les environnements de transport modernes, ainsi que les approches de surveillance de l'état des routes. Enfin, une attention particulière est accordée aux techniques de vision embarquée et d'intelligence artificielle qui constituent la base des systèmes automatisés de détection des nids-de-poule développés dans ce travail. [1]

1.2. Définition des systèmes de transport intelligent

Utilisation des nouvelles technologies de l'information et de la communication dans le secteur des transports et de la logistique est connue sous le nom de systèmes de transport intelligents (STI) ou systèmes d'intelligence des transports intelligents (STI). Les STI s'inscrit dans une perspective à long terme, car ils soutiennent la gestion de la mobilité. On les retrouve dans de nombreux domaines d'activité, notamment les services de développement, l'optimisation de l'utilisation des infrastructures de transport, et l'amélioration de la sécurité (en particulier la sécurité de routine) et de la surveillance. [2]

1.3. Objectifs et importance des STI

Au cœur des villes, les outils numériques offrent à mieux circuler sans ralentir l'ensemble du réseau. Grâce à des détecteurs posés sur la route, les signaux changent tout seuls quand trop de voitures arrivent. Si une situation risquée apparaît, un signal sonore alerte celui au volant pendant que la voiture réduit sa vitesse seule. Avec davantage d'informations traitées en temps réel, chacun reçoit des horaires précis, même lorsque le trafic change brusquement. Quand les autos parlent avec les bus ou les vélos connectés, passer d'un moyen à un autre devient presque invisible. [3]

1.3.1. Importance des STI dans la mobilité moderne

L'importance des systèmes de transport intelligents (STI) dans la mobilité moderne s'est considérablement accrue face à l'urbanisation croissante et aux défis environnementaux actuels. En permettant une gestion plus efficace des infrastructures et des flux de circulation, les STI contribuent à réduire les embouteillages, à optimiser la consommation énergétique et à diminuer les émissions de gaz à effet de serre. Ils favorisent également une mobilité plus sûre, plus durable et mieux adaptée aux besoins des usagers, ce qui en fait un élément essentiel du développement des villes intelligentes et des transports du futur.

1.3.1.1. Enjeu Environnemental

Grâce aux technologies du transport intelligent, chaque trajet devient un peu moins gourmand en énergie. Lorsque la circulation coule sans heurts, les voitures ne sont plus coincées dans des cycles incessants de freinage et d'accélération. Moins ces arrêts brusques se produisent, moins le moteur gaspille du carburant. Résultat est que L'air s'en trouve légèrement moins chargé de polluants. Chaque kilomètre fluide compte pour abaisser l'impact climatique.

1.3.1.2. Efficacité économique

Chaque année, la congestion routière engendre d'importantes pertes économiques en raison des retards, de la surconsommation de carburant et de la baisse de productivité. Une gestion intelligente du trafic permet d'optimiser l'utilisation des infrastructures existantes, d'améliorer la fluidité des déplacements et de limiter le recours à des projets d'extension coûteux, contribuant ainsi à une utilisation plus efficace des ressources financières.

1.3.1.3. Sécurité et santé publique

Lorsqu'un système détecte un risque de collision, il peut déclencher automatiquement le freinage du véhicule, contribuant ainsi à la prévention des accidents. Ces dispositifs sont

également capables d'identifier les obstacles ou les perturbations sur la chaussée. Grâce à ces réactions rapides, la sécurité des usagers est renforcée et la circulation devient plus fluide. Cette amélioration du trafic se traduit par une réduction des embouteillages, des nuisances sonores et des émissions polluantes. Par conséquent, les environnements urbains deviennent plus apaisés et la qualité de l'air ainsi que le confort de vie des habitants s'en trouvent améliorés.

1.3.1.4. Confort de l'utilisateur

Le gain de temps constitue un avantage majeur dans les systèmes de transport intelligents, en réduisant les périodes d'attente et les incertitudes liées aux changements d'horaires ou aux perturbations imprévues. Les usagers peuvent ainsi adapter plus facilement leurs déplacements lorsqu'ils disposent d'informations actualisées avant leur départ. Une notification, consultée rapidement sur un support numérique, permet de prendre une décision éclairée en temps réel. Dans ce contexte, la mobilité devient dynamique et adaptable, où chaque déplacement peut être ajusté en fonction des conditions du moment. Ainsi, le voyage n'est pas nécessairement parfait, mais il devient plus fluide grâce à une meilleure compréhension et anticipation des situations, favorisant une circulation plus harmonieuse[3].

1.4. Composants des systèmes de transport intelligent

Les systèmes de transport intelligents reposent sur un ensemble de composants technologiques interconnectés permettant d'assurer la surveillance, l'analyse et l'optimisation du trafic routier en temps réel. Ces dispositifs s'appuient principalement sur des capteurs et des dispositifs de perception répartis sur les infrastructures et intégrés aux véhicules.

Dans ce cadre, des capteurs et caméras installés sur les routes jouent un rôle essentiel dans la détection continue de l'environnement routier. Ils permettent de suivre le flux de circulation, d'identifier les véhicules et de détecter les situations anormales telles que les embouteillages ou les obstacles. Lorsque la densité du trafic augmente, les systèmes de régulation adaptent automatiquement les feux de signalisation afin d'optimiser la fluidité de la circulation et de réduire les congestions.

Par ailleurs, l'évolution des STI a introduit des formes de mobilité plus automatisées, notamment les véhicules autonomes, capables de se déplacer avec une intervention humaine minimale grâce à des systèmes avancés de perception et de décision. Ces véhicules exploitent

des technologies telles que le radar, le lidar et les caméras pour analyser leur environnement et assurer une navigation sécurisée.

En complément, les infrastructures modernes intègrent des capteurs intelligents capables de fonctionner même dans des conditions difficiles, y compris de nuit. Ces dispositifs peuvent détecter la présence de véhicules, mesurer leur vitesse ou leur poids, et transmettre ces données à des systèmes centraux de traitement.

Enfin, chaque véhicule connecté dispose aujourd'hui de systèmes de localisation et de diagnostic en temps réel. Ces technologies permettent de connaître précisément sa position, d'évaluer son état de fonctionnement et de signaler immédiatement toute anomalie détectée. L'ensemble de ces composants contribue ainsi à rendre les systèmes de transport plus sûrs, plus efficaces et mieux adaptés aux besoins de mobilité modernes.

Un système intelligent (dans le contexte des systèmes de transport intelligents ou de tout système basé sur l'IA (intelligence artificiel)) repose généralement sur plusieurs composantes essentielles qui travaillent ensemble pour percevoir, analyser, décider et agir :

A. Capteurs (perception)

Ce sont les « yeux et oreilles » du système. Ils collectent les données de l'environnement :

- Caméras
- Radars / LIDAR
- Capteurs de température, pression, vitesse, etc.
- GPS

B. Unité de traitement (intelligence) C'est

le « cerveau » du système :

- Algorithmes d'intelligence artificielle (SVM, ANN, CNN...)
- Traitement du signal et des images
- Analyse et extraction d'informations utiles

C. Système de communication

Il permet l'échange d'informations entre les différents éléments :

- Véhicules ↔ véhicules (V2V)
- Véhicules ↔ infrastructure (V2I)
- Réseaux sans fil (Wi-Fi, 4G/5G, ITS-G5)

D. Unité de décision

Elle interprète les résultats du traitement et prend des décisions :

- Détection d'un danger
- Ajustement du trafic

- Alerte ou action automatique

E. Actionneurs (réaction)

Ce sont les éléments qui exécutent les décisions :

- Freinage automatique
- Feux de signalisation intelligents
- Affichage d'alertes
- Commandes du véhicule

F. Interface utilisateur (IHM)

Elle permet l'interaction avec l'humain :

- Écrans embarqués
- Applications mobiles
- Alertes sonores ou visuelles [1]

La figure ci-dessous présente un exemple de collection, traitement et échange des données dans les systèmes de transport intelligents :




Figure 1.1 : Exemple de collection, traitement et échange des données dans les systèmes de transport intelligents

1.5. Application des systèmes de transport intelligent

Les usagers utilisent aujourd'hui des applications mobiles et des systèmes informatiques afin de faciliter leurs déplacements et de réduire la complexité des trajets. Grâce à l'intelligence artificielle, il devient possible d'anticiper les congestions et les variations du trafic en milieu urbain. Par ailleurs, les feux de signalisation s'adaptent en temps réel aux conditions de circulation sans intervention humaine prolongée. À titre

d'exemple, certaines applications permettent de localiser les bus en temps réel. De plus, les véhicules équipés de systèmes intelligents peuvent détecter les risques de collision et ajuster automatiquement leur trajectoire afin d'éviter les obstacles environnants. Ce type de fonctionnement repose sur l'échange continu d'informations entre véhicules et infrastructures, sans intervention directe du conducteur. Lorsqu'un retard survient, par exemple dans le transport ferroviaire, des itinéraires alternatifs peuvent être proposés grâce aux données disponibles en temps réel. Ainsi, les décisions ne reposent plus sur l'intuition, mais sur des informations précises et actualisées. L'ensemble du système devient dynamique, capable de s'adapter en permanence, ce qui améliore la fluidité globale de la circulation.

Les systèmes de transport intelligents (STI) trouvent aujourd'hui de nombreuses applications dans la gestion et l'optimisation des déplacements. Ils sont notamment utilisés dans la gestion intelligente du trafic urbain, où les feux de signalisation s'adaptent en temps réel à la densité de circulation afin de réduire les embouteillages et d'améliorer la fluidité routière. Dans le domaine de la navigation, les applications de guidage exploitent les données en temps réel pour proposer les itinéraires les plus efficaces en fonction des conditions de trafic, des accidents ou des travaux. Par ailleurs, les STI sont largement intégrés dans les systèmes d'aide à la conduite (ADAS), permettant d'améliorer la sécurité des usagers grâce à des fonctionnalités telles que le freinage automatique d'urgence, la détection des piétons ou encore l'alerte de collision. L'émergence des véhicules connectés et autonomes renforce également l'efficacité de ces systèmes grâce à l'échange d'informations entre véhicules et infrastructures. En outre, les STI jouent un rôle important dans la gestion du transport public en assurant le suivi en temps réel des véhicules et l'information des usagers. Ils contribuent également à la surveillance des infrastructures routières en détectant les dégradations telles que les nids-de-poule, facilitant ainsi la maintenance préventive. Enfin, ces systèmes permettent une meilleure gestion des situations d'urgence en alertant automatiquement les services concernés et en redirigeant le trafic afin de minimiser les perturbations. [4]

La figure 1.2 ci-dessous montre les différentes applications des systèmes de

transportintelligent:



Figure 1.2 : Application des systèmes de transport intelligent

1.6. Architecture des systèmes de transport intelligent

Dans les systèmes de transport modernes, les échanges d'informations s'effectuent de manière continue entre les véhicules ainsi qu'entre les véhicules et les infrastructures routières. Ce réseau de communication permet à chaque usager de dialoguer non seulement avec les autres véhicules, mais aussi avec les équipements de signalisation tels que les feux tricolores et les panneaux de circulation. Afin d'assurer une compréhension uniforme des données échangées, l'utilisation d'un langage commun est indispensable.

Dans ce contexte, ces systèmes reposent souvent sur des structures logiques formalisées, appelées ontologies, qui permettent d'organiser et de structurer les connaissances relatives au domaine routier. Ces ontologies intègrent différents types d'informations, notamment les itinéraires, les règles de circulation, la signalisation routière ainsi que les conditions environnementales comme la météo.

L'exploitation conjointe de ces données permet d'optimiser la fluidité du trafic et de réduire les risques d'accidents. L'objectif principal de cette architecture est ainsi d'assurer une meilleure coordination entre les différents éléments en mouvement sur la chaussée. [1]




Figure 1.3. Architecture des systèmes de transport intelligent

1.7. Exemple des systèmes de transport intelligent dans le monde

Ci-dessous, on présente quelques exemples de systèmes de transport intelligent déployés dans différentes régions du monde.

1.7.1. Hangzhou Chine le City Brain

Le système City Brain, développé par Alibaba, est reconnu pour ses performances avancées et suscite l'intérêt des experts du domaine. Il analyse en temps réel les flux de circulation et s'adapte en continu aux conditions du trafic. Ce dispositif pilote plus de mille feux tricolores, ce qui permet d'améliorer la fluidité routière, avec une augmentation moyenne de la vitesse de circulation d'environ 15 %, tout en facilitant notamment la priorité de passage aux véhicules d'urgence comme les ambulances. [5]

1.7.2. Singapour Plan Mobilité Intelligente 2030

Dans le cadre de son Plan de mobilité intelligente 2030, Singapour s'appuie sur une gestion optimisée et en temps réel du trafic routier grâce à des feux de signalisation

intelligents. Ce système permet, par exemple, d'accorder une priorité aux bus en cas de retard, en prolongeant automatiquement la durée du feu vert afin de réduire les perturbations dans les horaires.

Ces ajustements sont réalisés de manière dynamique en fonction de l'intensité du trafic, ce qui permet d'améliorer la fluidité de la circulation et de renforcer l'efficacité globale du réseau de transport [6]

1.7.3. Oslo Norvège capitale mobilité électrique

À Oslo, des technologies intelligentes sont déployées afin d'accompagner la transition vers une mobilité plus durable. La gestion des stations de recharge électrique est automatisée, avec un ajustement en temps réel de la distribution d'énergie afin de limiter les pertes et d'éviter tout gaspillage.

Des capteurs permettent également d'identifier les véhicules et de transmettre des informations instantanées sur le trafic. Ces données servent à adapter certaines règles d'accès aux zones urbaines en fonction du type de motorisation.

L'ensemble du système fonctionne de manière autonome, sans intervention humaine directe, contribuant ainsi à une circulation plus fluide, efficace et adaptée aux enjeux environnementaux [7].

1.7.4. Espagne routes connectées

Sur les autoroutes espagnoles, notamment l'AP-7 et l'A-2, un système intelligent a été mis en place afin d'améliorer la fluidité du trafic. Celui-ci repose sur une régulation électronique de la vitesse en temps réel, permettant d'adapter la circulation en fonction des conditions et de réduire les congestions.

Des capteurs répartis le long des axes routiers détectent automatiquement les situations à risque, telles que le verglas ou la présence de véhicules immobilisés, et transmettent ces informations instantanément aux usagers. Ce dispositif fonctionne de manière autonome, sans intervention humaine directe, afin d'améliorer la sécurité et la réactivité du réseau routier [8].

1.7.5. Lyon et Bordeaux renforcent le transport public

Dans les villes de Lyon et Bordeaux, des solutions de transport intelligent sont mises en œuvre afin d'améliorer la mobilité urbaine et de renforcer l'efficacité des transports publics. Les feux de signalisation sont désormais capables de s'adapter automatiquement aux conditions de circulation.

À Bordeaux, par exemple, des capteurs embarqués sur les bus et les tramways permettent de détecter leur approche et d'accorder prioritairement le feu vert. Cette gestion dynamique réduit les arrêts fréquents, améliore la ponctualité des lignes et contribue également à diminuer le temps de trajet ainsi que la consommation de carburant. [9]

1.8. Vision par ordinateur dans les STI :

La vision par ordinateur s'intègre progressivement dans les systèmes de transport intelligent, en évoluant de manière graduelle selon les usages réels et les besoins opérationnels. Son développement s'adapte aux contraintes du terrain, sans déploiement brusque, mais plutôt à travers une amélioration continue des capacités d'analyse visuelle.

Cette technologie permet d'interpréter automatiquement les images captées par les caméras routières afin de détecter des objets, des véhicules, des piétons ou encore des situations anormales. Elle contribue ainsi à renforcer la sécurité routière, à optimiser la gestion du trafic et à améliorer la réactivité des systèmes de transport. [10]

1.8.1. Les tâches fondamentales de la vision

Dans les systèmes de vision par ordinateur, l'analyse des images repose généralement sur des techniques de Deep Learning, notamment les réseaux de neurones convolutifs (CNN). Ces modèles apprennent progressivement à extraire des informations visuelles, en commençant par la détection de contours simples, puis en identifiant des structures plus complexes, jusqu'à la reconnaissance d'objets bien définis.

Des algorithmes tels que YOLO (You Only Look Once) et SSD (Single Shot MultiBox Detector) permettent de traiter des flux vidéo en temps réel, même en présence de mouvements rapides, tout en conservant de bonnes performances. Ces approches rendent possible la détection et l'identification d'objets tels que les véhicules, les camions ou encore les panneaux de signalisation.

Par ailleurs, chaque image peut être analysée afin d'attribuer des labels précis aux différentes zones de la scène, permettant de distinguer la chaussée, les passages piétons ou encore les zones de travaux [11].

1.8.2. Applications Embarquées (Véhicules)

Les véhicules modernes intègrent des technologies leur permettant de percevoir et d'interpréter leur environnement en temps réel. Un logiciel de vision artificielle analyse les images captées par les caméras de manière similaire à la perception humaine, afin d'assister le système de conduite dans la prise de décision rapide.

Grâce à différents capteurs, le système est capable de détecter et d'identifier des éléments tels que les piétons, les véhicules et les panneaux de signalisation. Il peut également intervenir pour corriger la trajectoire du véhicule lorsqu'une dérive est détectée, améliorant ainsi la sécurité et la stabilité de la conduite.

Par ailleurs, la reconnaissance des panneaux de limitation de vitesse permet d'adapter automatiquement le comportement du véhicule. Enfin, des dispositifs de surveillance du conducteur analysent son état d'attention et peuvent déclencher des alertes en cas de fatigue ou de distraction, influençant ainsi le fonctionnement global du système de conduite [12].

1.8.3. Applications pour infrastructures villes intelligentes

Dans les villes intelligentes, des capteurs visuels installés le long des axes routiers permettent de surveiller en temps réel les flux de circulation. Ces dispositifs analysent les mouvements des véhicules et transmettent les données à un centre de contrôle, où elles sont utilisées pour ajuster dynamiquement les feux de signalisation afin d'anticiper les ralentissements et d'améliorer la fluidité du trafic.

Le système est capable d'apprendre et de s'adapter progressivement, sans intervention humaine directe. Il peut également détecter et signaler immédiatement des anomalies, telles qu'un véhicule immobilisé sur une voie rapide ou une circulation en sens inverse.

Par ailleurs, les caméras de surveillance peuvent lire les plaques d'immatriculation, facilitant ainsi la gestion des accès aux parkings et l'identification des véhicules volés. Enfin, des caméras embarquées sur certains véhicules permettent d'enregistrer l'état des infrastructures routières et de détecter automatiquement les changements sur les itinéraires parcourus [13]

1.8.4. Défis techniques et leurs solutions

Dans les systèmes de transport intelligents, la perception de l'environnement devient complexe lorsque les scènes sont dynamiques, fortement encombrées ou soumises à des conditions d'éclairage difficiles. La présence simultanée de nombreux véhicules en mouvement, notamment dans des environnements peu éclairés, peut également augmenter la charge de calcul et réduire la fiabilité de l'analyse en temps réel.

Pour surmonter ces limitations, des solutions multi-capteurs sont mises en place. Elles combinent la vision par caméra avec d'autres technologies comme les capteurs

thermiques, le LiDAR et le radar, afin d'améliorer la robustesse de la détection dans diverses conditions.

Par ailleurs, des unités de calcul embarquées permettent de traiter les données localement et en temps réel, sans dépendre uniquement d'un traitement centralisé. Enfin, même en cas d'occultation temporaire d'un véhicule (par exemple lorsqu'il est caché derrière un obstacle), des modèles prédictifs basés sur les trajectoires passées permettent d'estimer sa position future et d'assurer une continuité dans le suivi. [14]

1.9. Détection automatique des défauts de la route

Voici un aperçu des principales techniques technologiques couramment utilisées pour la détection automatique des défauts de la chaussée :

Ces approches reposent généralement sur des systèmes de vision par ordinateur couplés à des algorithmes d'apprentissage automatique ou de Deep Learning. Les caméras embarquées sur les véhicules ou installées en bord de route capturent en continu l'état de la surface routière, puis les images sont analysées pour identifier les anomalies telles que les nids-de-poule, les fissures ou les dégradations du revêtement.

Les modèles de réseaux de neurones convolutifs (CNN) sont souvent utilisés pour extraire automatiquement les caractéristiques visuelles pertinentes et classer les différents types de défauts. Dans certains systèmes plus avancés, des architectures de détection d'objets en temps réel permettent de localiser précisément les zones endommagées.

Par ailleurs, ces techniques peuvent être complétées par des capteurs inertiels (accéléromètres, gyroscopes) intégrés aux véhicules, qui détectent les variations brusques liées aux irrégularités de la route. La fusion de ces données améliore la précision et la robustesse du système de détection.[15]

1.9.1. Méthodes de détection par caméra

Cette méthode présente l'avantage d'être compatible avec différents types de véhicules, ce qui lui confère une grande flexibilité de déploiement. Elle repose sur l'analyse automatique d'un grand nombre d'images afin d'identifier les dégradations présentes sur la chaussée.

Grâce à cette analyse, l'algorithme détecte les anomalies présentes sur la chaussée et détermine avec précision leurs contours, facilitant ainsi leur caractérisation et leur évaluation. La segmentation joue un rôle essentiel dans ce processus, car elle permet de définir avec précision les limites des anomalies, notamment les fissures et les nids-de-poule.

Ces informations sont particulièrement importantes pour estimer l'ampleur des dégâts et planifier les interventions de maintenance nécessaires.

Par ailleurs, l'analyse détaillée de la texture du revêtement permet de révéler des irrégularités parfois invisibles à l'œil nu. Ces caractéristiques fines, extraites à partir des images, fournissent des indications précieuses sur l'état structurel de la chaussée et sur la présence éventuelle de défauts sous-jacents [12].

1.9.2. Analyse du profil tridimensionnel par Lidar et laser

Lorsque la précision est essentielle, une simple image bidimensionnelle peut s'avérer insuffisante, car elle ne permet pas de représenter la profondeur des défauts de la chaussée, ce qui complique l'évaluation exacte de leur gravité.

Le LiDAR, basé sur l'émission de faisceaux laser dirigés vers la surface routière, permet de reconstruire un modèle tridimensionnel précis de la route. Cette technologie génère ainsi une représentation en relief qui met en évidence les irrégularités du revêtement.

Elle permet de détecter des variations subtiles du sol et de révéler des détails difficilement perceptibles avec des méthodes classiques. Grâce à cette capacité d'analyse fine, le LiDAR améliore significativement la détection des déformations et contribue à une évaluation plus fiable de l'état de la chaussée. [16]

1.9.3. Détection avec accéléromètres

Cette méthode repose sur l'intégration de capteurs de mouvement, installés sur les essieux ou le châssis du véhicule, qui mesurent en continu les vibrations, les inclinaisons et les secousses durant le déplacement. Ces données permettent d'analyser le comportement dynamique du véhicule et de détecter d'éventuelles irrégularités de la chaussée.

Lorsqu'une roue traverse un nid-de-poule ou une déformation de la route, une signature vibratoire spécifique est enregistrée. En combinant ces informations avec la géolocalisation GPS, il devient possible de localiser précisément les zones de perturbation et de constituer une cartographie des défauts routiers.

Ce système fonctionne de manière autonome et reste efficace même dans des conditions environnementales difficiles, ce qui en fait une solution complémentaire aux méthodes de détection par vision ou par LiDAR [17].

1.10. Structure d'un système embarqué de détection

Un système embarqué de détection des défauts routiers est une solution complète qui combine plusieurs composants matériels et logiciels afin d'assurer l'acquisition, le traitement

et l'exploitation des données en temps réel. Son objectif principal est d'identifier automatiquement les anomalies de la chaussée (fissures, nids-de-poule, déformations) tout en fournissant leur localisation précise pour faciliter la maintenance.

Sur le plan matériel, le système repose généralement sur une plateforme embarquée installée sur un véhicule. Celle-ci intègre une ou plusieurs caméras chargées de capturer en continu l'état de la route. Ces caméras peuvent être complétées par des capteurs additionnels tels que le GPS pour la localisation, ainsi que des capteurs inertiels (accéléromètre, gyroscope) afin de détecter les vibrations liées aux irrégularités de la chaussée.

Sur le plan logiciel, un module de prétraitement améliore la qualité des images en ajustant automatiquement la luminosité, le contraste et la stabilité des images. Ensuite, un module d'analyse basé sur la vision par ordinateur et le Deep Learning, notamment les réseaux de neurones convolutifs (CNN), est utilisé pour extraire les caractéristiques pertinentes et détecter les défauts de la route. Dans certains cas, des architectures de détection en temps réel permettent également de localiser précisément les anomalies dans l'image.

Une fois les défauts identifiés, un module de fusion de données associe les informations visuelles aux données de localisation GPS. Cela permet de positionner chaque anomalie sur une carte géographique et de constituer une base de données structurée des dégradations routières.

Enfin, un module de communication ou de stockage assure l'enregistrement ou la transmission des résultats vers une plateforme de supervision. Ces données peuvent ensuite être exploitées pour la planification des interventions de maintenance et l'amélioration de la gestion des infrastructures routières[18].

1.11. Avantage des systèmes de transport intelligent :

Les systèmes de transport intelligents (STI) permettent une gestion plus efficace et optimisée des déplacements urbains. Grâce à l'intégration des technologies numériques et à l'exploitation des données en temps réel, les infrastructures de transport sont continuellement mises à jour et adaptées aux besoins actuels, remplaçant progressivement les méthodes de gestion traditionnelles devenues obsolètes.

L'un des principaux avantages des STI réside dans leur capacité à anticiper les problèmes de circulation. Les informations collectées en temps réel permettent d'identifier les congestions potentielles et d'adapter les flux de trafic, ce qui contribue à une organisation plus fluide et plus économique des déplacements. Les usagers bénéficient ainsi d'indications

plus précises et mieux adaptées à leur situation, ce qui réduit les temps d'attente imprévus et améliore le confort de déplacement.

De plus, le trajet des usagers peut être ajusté dynamiquement en fonction de l'évolution du trafic, ce qui permet une meilleure fluidité globale et une réduction des embouteillages. Cette optimisation entraîne une diminution de la consommation énergétique et une amélioration de l'efficacité du réseau routier.

Sur le plan environnemental, les STI contribuent également à la réduction des émissions polluantes grâce à une meilleure gestion des flux de circulation et à la diminution des arrêts inutiles. À long terme, cela favorise l'émergence de villes plus calmes, plus organisées et plus durables, où la mobilité est mieux maîtrisée et plus respectueuse de l'environnement [19].

La figure 1.4 montre les avantages des systèmes de transport intelligent :




Figure 1.4 : Avantage des systèmes de transport intelligent

1.12. Conclusion :

Dans ce chapitre, nous avons présenté les systèmes de transport intelligents (STI) en commençant par une introduction générale, suivie de leur définition ainsi que de leurs objectifs et de leur importance dans la modernisation des réseaux de transport. Nous avons ensuite détaillé leurs principales composantes, ainsi que leurs différentes applications et architectures.

Nous avons également mis en évidence les avantages offerts par ces systèmes, ainsi que les technologies sur lesquelles ils reposent. Des exemples concrets de déploiement des STI à travers le monde ont été présentés afin d'illustrer leur efficacité et la diversité de leurs usages.

Par la suite, nous avons abordé le rôle de la vision par ordinateur dans les STI, ainsi que les méthodes de détection automatique des défauts de la route, notamment les nids-depoule, qui constituent l'idée centrale de notre projet. Enfin, nous avons décrit la structure d'un système embarqué de détection, en mettant en évidence ses principaux modules ainsi que son fonctionnement global.

Chapitre 2 : Vision par ordinateur pour la détection des défauts routiers

2.1. Introduction

Dans le contexte de la vision par ordinateur et des techniques de machine learning appliquées à la détection des défauts routiers, l'apprentissage peut être défini comme un processus par lequel un modèle acquiert ou améliore sa capacité à représenter et interpréter les données issues de son environnement, notamment les images de la chaussée. L'objectif est de permettre au système de reconnaître automatiquement les anomalies et d'améliorer progressivement ses performances de détection.

L'apprentissage correspond ainsi à une adaptation du modèle à partir des données d'entraînement, ce qui lui permet de développer une capacité de généralisation face à de nouvelles situations. Dans notre cas, cela se traduit par la reconnaissance des nids-de-poule, fissures et autres dégradations de la route à partir d'images ou de signaux issus de capteurs. Il se distingue des simples traitements déterministes, car il repose sur l'expérience acquise à partir des données plutôt que sur des règles fixes programmées manuellement.

Dans le domaine du machine learning, on distingue plusieurs paradigmes d'apprentissage, notamment l'apprentissage supervisé, largement utilisé dans les tâches de classification et de détection d'objets, ainsi que l'apprentissage non supervisé et par renforcement. Dans les systèmes de vision par ordinateur, les réseaux de neurones, en particulier les CNN, jouent un rôle central dans l'extraction automatique des caractéristiques et l'amélioration continue des performances de détection des défauts routiers. [20]

2.2. Définition de conduit intelligent

Dans le cadre de la vision par ordinateur et des techniques de machine learning appliquées à la détection des défauts routiers, la conduite intelligente peut être définie comme la capacité de certains véhicules à percevoir et analyser leur environnement de manière semi-autonome, afin d'assister le conducteur dans la prise de décision ou, dans certains cas, d'assurer une conduite automatisée. Grâce à l'intelligence artificielle, au machine learning et à l'utilisation de divers capteurs (caméras, LiDAR, radar), ces systèmes interprètent en permanence les informations issues de la route pour améliorer la sécurité et la performance de conduite.

Le niveau d'autonomie des véhicules est généralement structuré en six niveaux, allant de simples systèmes d'assistance à la conduite jusqu'à une autonomie complète où aucune intervention humaine n'est requise. À ces niveaux correspondent trois fonctions

fondamentales du système: percevoir l'environnement à travers les capteurs, analyser et prendre une décision, puis exécuter une action adaptée.

Malgré les progrès rapides dans ce domaine, plusieurs limites subsistent, notamment la gestion des situations imprévues et la fiabilité des systèmes dans des environnements complexes. De plus, la perception et l'acceptation de ces technologies par les usagers restent encore variables. Enfin, le cadre réglementaire continue d'évoluer afin d'encadrer l'utilisation des véhicules intelligents, notamment en ce qui concerne la responsabilité du conducteur dans les systèmes semi-autonomes. .[21]

2.3. Notion d'apprentissage automatique (machine Learning)

Aujourd'hui, de nombreuses entreprises utilisent des technologies avancées afin d'améliorer leurs performances et leur efficacité, notamment dans le domaine de l'intelligence artificielle, dont le Machine Learning constitue une branche essentielle. Ce domaine permet d'analyser de grandes quantités de données à l'aide d'algorithmes et de calculs complexes, dans le but de détecter des tendances, de faire des prédictions ou de résoudre différents problèmes.

Le Machine Learning repose sur la capacité des systèmes à apprendre automatiquement à partir des données, sans être explicitement programmés pour chaque tâche. Il permet ainsi d'améliorer les modèles au fil du temps, en affinant leurs performances grâce à l'expérience acquise.

Dans ce contexte, cette approche peut être utilisée pour anticiper des résultats, optimiser des processus ou encore corriger certaines erreurs dans un système donné. Elle offre ainsi une nouvelle manière de concevoir et de gérer des systèmes complexes, en particulier dans des domaines comme la logistique, l'analyse de données ou encore les systèmes intelligents de transport, où les décisions doivent être prises de manière rapide et efficace[22].

La figure 2.1 : présente l'apprentissage automatique et ses composantes :




Figure 2.1 : composantes de l'apprentissage automatique [22]

2.3.1. Machine Learning

Le Machine Learning, également appelé apprentissage automatique, désigne une branche de l'intelligence artificielle permettant aux systèmes d'apprendre de manière autonome à partir de données, grâce à des algorithmes dédiés. Ces données peuvent prendre différentes formes telles que du texte, des valeurs numériques, des mesures ou encore des images, servant de base au processus d'apprentissage.

Le Machine Learning est inspiré du fonctionnement cognitif humain, il cherche à reproduire la capacité d'apprentissage à partir de l'expérience. En s'appuyant sur des exemples fournis, l'algorithme identifie les informations pertinentes, en extrait les tendances importantes, puis construit un modèle capable de prendre des décisions ou de réaliser des prédictions.

Une fois la phase d'apprentissage achevée, le modèle est déployé pour être utilisé sur de nouvelles données. Cette approche permet notamment la reconnaissance de motifs, l'aide à la décision ainsi que la prédiction à partir de grands volumes d'informations.

Le développement d'un modèle de Machine Learning repose généralement sur quatre étapes principales, allant de la constitution et la préparation des données d'entraînement jusqu'à l'évaluation, le déploiement et l'amélioration continue du modèle. La figure 2.2 illustre le principe du machine Learning :




Figure 2.2 : principe du machine learning

A- Sélection des données d'entraînement

La première étape consiste à constituer les données utilisées pour entraîner le système. Ces données permettent au modèle de Machine Learning d'apprendre et de comprendre la tâche à accomplir. Avant l'entraînement, il est indispensable de nettoyer et structurer les données afin de corriger les erreurs et d'assurer leur cohérence. Selon le cas, des annotations peuvent être ajoutées pour guider le modèle vers les informations importantes à analyser. À l'inverse, dans certains scénarios, aucune indication n'est fournie, laissant au modèle la liberté d'extraire automatiquement les caractéristiques pertinentes.

B- Sélection de l'algorithme

La deuxième étape consiste à choisir l'algorithme d'apprentissage le plus adapté aux données disponibles et au problème à résoudre. Ce choix dépend de plusieurs facteurs, notamment la nature des données, leur volume, ainsi que le type de tâche à effectuer (classification, régression, détection, etc.).

C- Entraînement de l'algorithme

La troisième étape correspond à la phase d'apprentissage proprement dite. Durant cette étape, les données sont introduites dans l'algorithme afin d'ajuster ses paramètres internes. Les résultats obtenus sont ensuite comparés aux valeurs attendues, ce qui permet d'identifier les erreurs et d'optimiser progressivement le modèle afin d'améliorer sa précision.

D- Utilisation et amélioration du modèle

La quatrième étape concerne l'exploitation du modèle ainsi que son amélioration continue. Elle consiste à appliquer le modèle entraîné sur de nouvelles données qu'il n'a jamais rencontrées auparavant, afin d'évaluer sa capacité de généralisation et sa performance sur le problème réel à traiter. Par la suite, les résultats obtenus permettent d'identifier les limites éventuelles du modèle. Celui-ci peut alors être ajusté, réentraîné ou optimisé afin d'améliorer progressivement sa précision et sa robustesse au fil du temps.

E- Les différents types de Machine Learning

Le Machine Learning repose sur un ensemble d'algorithmes permettant d'exploiter les données pour apprendre et prendre des décisions. Actuellement, plusieurs approches sont utilisées dans les applications industrielles et académiques, notamment l'apprentissage supervisé, non supervisé, semi-supervisé ainsi que l'apprentissage par renforcement. Ces différentes catégories se distinguent principalement par la nature des données d'entrée disponibles (étiquetées ou non) ainsi que par l'objectif recherché, qu'il s'agisse de classification, de regroupement ou de prise de décision optimale

2.3.2. Machine Learning supervisé

L'apprentissage supervisé est l'approche la plus couramment utilisée en Machine Learning. Dans ce cas, le modèle est entraîné à partir de données étiquetées, c'est-à-dire des exemples dont les résultats sont déjà connus. Le data scientist guide donc le processus d'apprentissage en fournissant au modèle des entrées associées à des sorties précises. L'algorithme apprend ainsi à établir une relation entre les données et leurs résultats afin de prédire correctement de nouvelles sorties.

2.3.3. Le Machine Learning non supervise

Grâce à l'apprentissage non supervisé, la machine est capable de reconnaître des motifs et des procédés sophistiqués, sans nécessiter une supervision permanente d'un spécialiste en données. Cela signifie donc une formation initiale avec des données non labellisées et sans résultat lié.

2.3.4. Le Machine Learning par renforcement

L'apprentissage par renforcement partage quelques points avec l'apprentissage supervisé. Pourtant, ici, on n'utilise pas de base de données pour les anciens algorithmes ; ils apprennent plutôt en testant, échouant, puis réussissant petit à petit. Chaque succès déclenche

une sorte de signal positif intégré au code lui - même. Ce signal agit comme un mais à atteindre durant le processus. [23]

2.4. Extraction des caractéristiques (feature extraction) :

L'extraction des caractéristiques représente une étape fondamentale dans le traitement des images, car elle consiste à transformer une image en un ensemble de descripteurs numériques représentatifs de ses propriétés essentielles. Ce processus permet de réduire la dimension des données, de simplifier la phase d'apprentissage et de mettre en évidence les informations les plus discriminantes, tout en améliorant les performances de classification. Dans le cadre de la détection des défauts routiers tels que les nids-de-poule, les caractéristiques les plus pertinentes reposent principalement sur la texture, qui est déterminante pour leur identification, la forme, qui décrit la structure géométrique des objets présents dans l'image (comme les fissures et les déformations), ainsi que les bords, qui correspondent aux contours et aux variations de la surface de la chaussée. Ainsi, la représentation de l'image sous forme de caractéristiques permet de réduire la complexité des données tout en conservant les informations essentielles, facilitant ainsi les tâches d'analyse, de détection et de classification par les algorithmes de Machine Learning.

Parmi les méthodes d'extraction de caractéristiques les plus utilisées en vision par ordinateur, on retrouve notamment le LBP (Local Binary Pattern) [25] et le HOG (Histogram of Oriented Gradients) [26];, qui sont particulièrement efficaces pour représenter les propriétés visuelles d'une image. [24]

2.4.1. Méthode LBP (local binary pattern)

Il s'agit d'un algorithme automatisé important pour l'extraction de caractéristiques en analyse d'images, notamment pour l'analyse de texture. Son objectif est de représenter les variations d'intensité lumineuse en les convertissant en valeurs numériques, facilitant ainsi la description de la structure plane de l'image. Cette méthode est utilisée pour l'analyse de surface dans des applications qui en dépendent, comme la détection des nids-de-poule sur les routes. [25]:

Principe de fonctionnement :

L'algorithme LBP repose sur le comptage de pixels. Un pixel central est sélectionné et comparé à ses pixels voisins. Selon le résultat de cette comparaison, chaque pixel se voit attribuer une valeur (0 ou 1) : si le pixel central est supérieur au pixel voisin, il reçoit la

valeur 0 ; s'il est inférieur, il reçoit la valeur 1. Ces valeurs binaires sont ensuite additionnées pour obtenir un code binaire, qui est converti en une valeur décimale représentant les propriétés de l'image. Ce processus est répété pour l'ensemble de l'image.




Figure 2.3 : codages des pixels par extraction des caractéristiques.




Figure 2.4 : Histogramme de caractéristique LBP.

2.4.2. Méthode HOG (histogram of oriented gradients)

Cette méthode est l'un des procédés utilisés pour extraire des propriétés en vue du traitement et de l'analyse d'images, en se concentrant sur l'analyse des contours et les changements de direction de l'intensité lumineuse, qui est un élément clé dans l'identification des formes et des motifs, tels que la forme des nids-de-poule sur la route [26].

Principe de fonctionnement

Cette méthode repose sur le calcul des différences de luminosité entre pixels adjacents afin d'analyser les contours d'une image. L'image est d'abord divisée en petits groupes, puis la direction des contours au sein de chaque groupe est calculée et représentée sous forme d'histogramme. Enfin, ces informations sont compilées pour former un vecteur caractéristique, qui sera ensuite utilisé pour la classification.

Pour chaque pixel de l'image, on calcule les gradients horizontaux et verticaux :

$$G_x = I(x + 1, y) - I(x - 1, y) \quad (2.1)$$

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

où :

G_x : gradient horizontal

G_y : gradient vertical

$I(x,y)$: intensité du pixel

- Magnitude du gradient

La magnitude (force du contour) est calculée par :

$$M = \sqrt{G_x^2 + G_y^2} \quad (2.3)$$

- Orientation du gradient

L'orientation est donnée par :

$$\theta = \arctan\left(\frac{G_y}{G_x}\right) \quad (2.4)$$

où :

M : représente l'intensité du contour.

θ : représente sa direction.

- Étapes de l'algorithme HOG

1. Convertir l'image en niveaux de gris.
2. Calculer les gradients G_x et G_y .
3. Déterminer la magnitude M et l'orientation θ .
4. Diviser l'image en petites cellules .
5. Construire un histogramme des orientations dans chaque cellule.
6. Pondérer chaque orientation par sa magnitude.
7. Regrouper plusieurs cellules en blocs.
8. Normaliser les histogrammes afin de réduire l'effet des variations d'éclairage.
9. Concaténer tous les histogrammes pour former le vecteur de caractéristiques HOG.

La figure 2.5 présente un exemple d'application du HOG sur une image de route qui présente un nid de poule.



Figure 2.5 : Exemple d'application du HOG sur une image

Comparaison entre le LBP et le HOG :

Tableau 2.1 : Comparaison entre le LBP et le HOG

LBP	HOG
Type texture	Type Edge
Centre vs voisinage	Calcule gradients
Rapide	Lente
Facile et simple	Complexe et difficile
Détection rapide des irrégularités	Détection plus précise

2.5. Méthode de classification

La classification constitue l'étape finale du processus d'analyse après l'extraction des caractéristiques. Elle consiste à exploiter les descripteurs obtenus afin de prendre une décision automatique sur la nature de l'image. Dans le cadre de la détection des défauts routiers, cette étape permet de distinguer entre deux classes principales : une route saine (sans défaut) et une route présentant un nid-de-poule.

Pour ce faire, les caractéristiques extraites (telles que celles issues du LBP ou du HOG) sont fournies à un algorithme de classification, qui apprend à reconnaître les différences entre les deux catégories à partir d'exemples d'entraînement. Une fois le modèle entraîné, il est capable de généraliser et de classer de nouvelles images inconnues en se basant sur les motifs appris. Cette étape joue donc un rôle crucial dans la performance globale du système, car elle détermine directement la précision de la détection automatique. [27]

2.5.1. Le classifieur SVM

Le SVM ou machine à vecteurs de support est une méthode d'apprentissage supervisée qui sert à effectuer des tâches de classification et de régression. Le but principal du SVM est de déterminer la meilleure séparation des classes de données possible, une séparation appelée hyperplan.

À propos de ce projet, le SVM est employé avec un noyau linéaire afin de classer l'image selon deux classes : potholes / normale [28]

Principe mathématique :

Soit un ensemble de données d'apprentissage :

$$\{(x_i, y_i)\}_{i=0}^N \quad (2.5)$$

où :

x_i : représente le vecteur de caractéristiques (LBP, HOG ou LBP+HOG).

$y_i \in \{-1, +1\}$: représente la classe associée.

Le SVM cherche un hyperplan défini par :

$$w \cdot x + b = 0 \quad (2.6)$$

où :

- w : vecteur normal à l'hyperplan. -
- b : biais.
- x : vecteur de caractéristiques.




Figure 2.6 : Séparation des classes par hyperplan optimal à l'aide du SVM

2.5.2. Réseau de neurones artificiels (ANN) :

Les réseaux de neurones artificiels (ANN) constituent un modèle d'apprentissage automatique qui s'inspire du fonctionnement du cerveau humain. Il est composé d'un réseau de neurones artificiels interconnectés, capables d'apprendre à partir des données et de réaliser ainsi des tâches de classification ou de prédiction.

Dans le cadre de ce projet, l'ANN permet de classer les images de chaussée en deux catégories : Nid de poule/ ordinaire

Structure d'un ANN .[29]:

Un réseau de neurones artificiels comporte habituellement trois sortes de couches :

1. Couche d'entrée : reçoit les caractéristiques extraites des images (LBP, HOG ou LBP+HOG).
2. Couche cachée (Hidden Layer) : effectue les traitements et l'apprentissage.
3. Couche de sortie (Output Layer) : donne la classe prédite.

Principe mathématique

Chaque neurone effectue une combinaison pondérée des entrées :

$$z = \sum_{i=1}^n w_i x_i + b \quad (2.7)$$

où :

x_i : entrée du neurone.

w_i : poids associé à l'entrée.

b : biais.

z : somme pondérée.

Le résultat est ensuite passé à une fonction d'activation:

$$a = f(x)$$

où :

a : sortie du neurone.

f : fonction d'activation (ReLU, Sigmoid, Tanh, etc.)

Fonction d'activation Sigmoid

Une fonction fréquemment utilisée est :

$$f(z) = \frac{1}{1+e^{-z}} \quad (2.8)$$

Cette fonction transforme la sortie en une valeur comprise entre 0 et 1, interprétable comme une probabilité.

Apprentissage du réseau :

L'apprentissage consiste à ajuster les poids du réseau pour réduire au minimum l'erreur entre les prédictions et les résultats réels.

L'erreur peut être calculée par :

$$E = \frac{1}{2} (y - \hat{y}) \quad (2.9)$$

où :

y : valeur réelle. $\hat{y}$:

valeur prédite.

Les poids sont ensuite mis à jour grâce à l'algorithme de rétropropagation (**Backpropagation**) associé à la descente de gradient.

- Étapes de l'algorithme ANN :

1. Extraire les caractéristiques d'une image.
2. Saisir les données dans la couche d'entrée.

3. Calcul du résultat des neurones.
4. Comparer les résultats obtenus avec les résultats réels.
5. Calculer l'erreur.
6. Modifier les poids par rétropropagation.
7. Répéter jusqu'à convergence.
8. Utiliser le réseau entraîné pour classer des nouvelles images.

La figure 3.5 ci-dessous illustre une architecture d'un réseau de neurones artificiels (ANN).




Figure 2.7 : Architecture d'un réseau de neurones artificiels (ANN).

2.6. Conclusion

Dans ce chapitre, nous avons présenté les principaux concepts de la vision par ordinateur et du Machine Learning appliqués à la détection des défauts routiers. Nous avons tout d'abord introduit la notion de conduite intelligente ainsi que le rôle de l'intelligence artificielle dans l'amélioration de la sécurité et de l'automatisation des systèmes de transport.

Nous avons ensuite étudié les fondements du Machine Learning en présentant ses différentes étapes de développement ainsi que ses principaux types d'apprentissage : supervisé, non supervisé et par renforcement. Ces notions constituent la base des systèmes

intelligents capables d'apprendre à partir des données et de prendre des décisions de manière autonome.

Par ailleurs, nous avons détaillé les méthodes d'extraction de caractéristiques utilisées dans notre travail, notamment les descripteurs LBP et HOG, qui permettent de représenter efficacement les informations de texture, de forme et de contour présentes dans les images de chaussées. Nous avons également présenté les techniques de classification SVM et ANN, largement utilisées pour la reconnaissance et la classification d'images.

L'ensemble des concepts et méthodes étudiés dans ce chapitre constitue le fondement théorique de notre système de détection automatique des nids-de-poule. Ces connaissances serviront de base à la mise en œuvre pratique du système, qui sera développée et validée dans le chapitre suivant.

Chapitre 3 :

Développement et implémentation du système de détection des nids-de-poule

3.1. Introduction

Ce chapitre présente la phase pratique du projet, consacrée à la mise en œuvre du système de détection automatique des nids-de-poule. Il décrit l'architecture matérielle et logicielle adoptée, basée sur une plateforme embarquée Raspberry Pi 5, une caméra pour l'acquisition des images et une LED d'indication pour la visualisation des résultats.

Le fonctionnement global du système est ensuite détaillé, depuis la capture des images de la chaussée jusqu'à leur traitement. Les images sont d'abord prétraitées à l'aide de techniques de vision par ordinateur afin d'améliorer leur qualité et d'extraire les caractéristiques pertinentes. Ces dernières sont ensuite exploitées par des algorithmes de Machine Learning pour effectuer la classification entre route normale et route dégradée.

Enfin, les modules développés sont intégrés dans une architecture embarquée permettant un traitement en temps réel. Le système fournit une décision automatique visualisée par une LED : allumée en présence d'un nid-de-poule et éteinte dans le cas d'une route en bon état. [30]

3.2. Architecture globale du système matériel et logiciel

3.2.1. Description générale du système embarqué

Le système embarqué proposé est une solution intelligente de détection automatique des nids-de-poule, intégrée sur une plateforme Raspberry Pi 5. Il repose sur une caméra embarquée (Web 812H) installée sur un véhicule pour capturer en temps réel des images de la chaussée. Ces images sont ensuite traitées localement par le système embarqué à travers une chaîne de traitement comprenant le prétraitement, l'extraction de caractéristiques (LBP et HOG), puis la classification à l'aide de modèles d'apprentissage automatique (SVM et ANN). Le résultat de l'analyse permet de distinguer entre une route en bon état et une route présentant des dégradations. En cas de détection d'un nid-de-poule, le système déclenche une action de signalisation en temps réel via l'allumage d'une LED. L'ensemble du processus est réalisé de manière embarquée, garantissant une détection rapide et autonome sans recours à un traitement externe. [31]

3.2.2. Schéma fonctionnel de la solution proposée

La figure ci-dessous illustre en détail le schéma fonctionnel de la solution proposée pour la détection automatique des nids-de-poule.




Figure 3.1 : Schéma bloc de la solution proposée

3.3. Développement et implémentation du système

Pour la mise en œuvre du système de détection automatique des nids-de-poule, plusieurs étapes ont été réalisées afin de garantir une détection fiable et efficace en temps réel. La solution développée repose sur l'intégration d'une plateforme embarquée, d'un dispositif d'acquisition d'images et d'algorithmes de vision par ordinateur et d'apprentissage automatique.

3.3.1. Partie conception du modèle de 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 (nid de poule) de celles représentant une chaussée intacte(normal). Pour cela, deux algorithmes d'apprentissage supervisé ont été mis en œuvre : la machine à vecteurs de support (SVM) et le réseau de neurone artificiel (ANN). Ces méthodes sont reconnues pour leur efficacité dans les tâches de classification binaire [32][33].

Mais avant d'atteindre l'étape de classification, plusieurs opérations préalables sont nécessaires afin de garantir la qualité et la pertinence des données utilisées par le modèle. Tout d'abord, les images acquises sont soumises à une phase de prétraitement visant à améliorer leur qualité visuelle et à réduire les perturbations telles que le bruit ou les variations d'éclairage.

Ensuite, une étape d'extraction de caractéristiques est réalisée afin de transformer les images brutes en descripteurs numériques représentatifs. Ces caractéristiques permettent de capturer les informations importantes liées à la texture et à la structure de la chaussée, tout en réduisant la complexité des données initiales.

Une fois ces étapes effectuées, les vecteurs de caractéristiques obtenus sont transmis aux algorithmes de classification, qui assurent la distinction entre les images de chaussée normale et celles présentant des nids-de-poule. Cette chaîne de traitement garantit ainsi une meilleure performance et une plus grande fiabilité du système global.

3.3.1.1. Acquisition et base de données d'images

Pour cette étude, nous avons collecté des images de chaussées à partir de jeux de données publics disponibles sur la plateforme Kaggle [100] Les images sélectionnées représentent deux situations différentes : des chaussées normales et des chaussées présentant des nids-de-poule. Après la collecte, les images ont été vérifiées, triées et organisées afin de constituer un ensemble de données adapté aux besoins de notre système de détection.

Le jeu de données utilisé est composé de 640 images, réparties en deux classes :

- Normale : 320 images représentant des chaussées sans défaut visible.
- Nid-de-poules : 320 images contenant un ou plusieurs nids-de-poule clairement identifiables.

Cette répartition équilibrée entre les deux classes permet d'améliorer la phase d'apprentissage et d'évaluation des modèles de classification utilisés dans ce travail, notamment les approches basées sur les descripteurs LBP et HOG ainsi que les classificateurs SVM et ANN.



Figure 3.2 : Exemples d'images collectées à partir de la plateforme Kaggle :

-a- : image présentant des nids de poules ; -b- : image présentant route normale

3.3.1.2. Prétraitement des images

Avant utilisation des images dans les différentes phases du projet, un prétraitement manuel a été réalisé. Chaque image a été examinée une par une puis recadrée de façon à garder uniquement la zone de la chaussée d'intérêt (ROI). On a éliminé le plus possible les éléments qui pourraient brouiller l'analyse : véhicules, végétation ou autres objets présents dans l'environnement routier. Les images ont ensuite été redimensionnées de façon à obtenir une taille uniforme 128x128, afin d'homogénéiser l'ensemble du jeu de données. Cette étape permet de faciliter le traitement des images et assure l'uniformité des données utilisées pour l'entraînement et l'évaluation des modèles.

Après avoir été recadrées et redimensionnées, les images ont été converties en gris. Cette transformation permet de réduire la quantité d'informations à traiter tout en conservant les détails essentiels de la surface routière et des nids-de-poule.

L'utilisation du niveau de gris est particulièrement adaptée aux méthodes d'extraction de caractéristiques utilisées dans cette étude (LBP, HOG), car elle met davantage l'accent sur les variations d'intensité et les textures de l'image plutôt que sur les informations relatives aux couleurs.

3.3.1.3. 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.

3.3.1.3.1. Extraction des caractéristiques par la méthode LBP

Le descripteur **LBP (Local Binary Pattern)** est particulièrement adapté à la détection des nids-de-poule, car il permet de caractériser efficacement les textures présentes à la surface de la chaussée. Dans ce travail, le LBP a été appliqué avec un **rayon** $R=2$ et un **nombre de voisins** $P=8$ pixels, permettant de capturer les variations locales de texture autour de chaque pixel. Les zones dégradées présentent généralement des irrégularités et des variations texturales plus importantes que les routes en bon état. Grâce à l'analyse de ces motifs texturaux locaux, la méthode LBP met en évidence les différences entre les surfaces intactes et les surfaces endommagées, facilitant ainsi leur classification.

La figure ci-dessous présente un exemple d'application de la méthode LBP sur une image représentant une chaussée comportant un nid-de-poule (pothole). Cette illustration montre la manière dont la méthode met en évidence les caractéristiques de texture de la zone endommagée. [34].



Figure 3.3 : Exemple d'application du LBP sur une image présentant un nid de poule

3.3.1.3.2. Histogramme des gradients orientés (HOG)

Le descripteur HOG est très utile pour détecter les nids-de-poule. Cela permet de montrer clairement les contours et les formes dans les images de routes. Lorsqu'une route se détériore, elle crée des gradients et des structures particulières qui peuvent être vues à travers les histogrammes d'orientations des gradients. Les informations obtenues sont ensuite utilisées pour aider les classifieurs SVM et ANN à faire la différence entre les routes endommagées et celles qui sont en bon état. Cette méthode est choisie parce qu'elle décrit bien les formes et les contours des nids-de-poule. Elle fonctionne également bien même lorsque la lumière change ou quando il y a du bruit dans les scènes réelles. [35]



Figure 3.4 . Exemple d'application du HOG sur une image présentant un nid de poule

3.3.1.4. Classification

La classification est une étape très importante dans notre système de détection des nids-de-poule. Elle permet de déterminer automatiquement si une image de chaussée est un nid-de-poule ou non. Pour cela, nous utilisons des caractéristiques spéciales qui sont extraites par les descripteurs LBP et HOG. Nous avons utilisé deux méthodes de classification pour voir laquelle fonctionne le mieux. La première méthode s'appelle la Machine à Vecteurs de Support, ou SVM. Cette méthode utilise un noyau linéaire qui permet de séparer facilement les différentes classes. Elle est également très efficace pour calculer les données de caractéristiques. La deuxième méthode s'appelle les Réseaux de Neurones Artificiels, ou ANN. Cette méthode est capable d'apprendre des relations complexes entre les caractéristiques d'entrée et les classes de sortie. En utilisant ces deux méthodes, nous pouvons comparer leurs performances et trouver la meilleure approche pour détecter automatiquement les dégradations routières [36][37].

3.3.1.5. Métriques de mesure :

Pour évaluer les performances du modèle de classification, des métriques de mesures telles que Accuracy, Precision et Recall ont été mises en œuvre. En effet, ces mesures permettent d'évaluer la performance du modèle dans sa capacité à différencier avec précision les images de nids-de-poule et les images de chaussée normale.

Les métriques de mesures (précision, spécificité et sensibilité) peuvent être dérivées à partir d'un outil fondamental en classification supervisée : la matrice de confusion.

- 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 de classification binaire (classe positive vs classe négative), comme illustré dans le Tableau 3.1. [38]

Tableau 3.1 : matrice de confusion

Predit \ Valeur réelle	Nid-de-poule(1)	Sans nid-de poule(0)
Nid-de-poule (1)	Tp (true positive)	FN (False Negative)
sans nid-de-poule(0)	Fp (Flase positive)	TN (True Negative)

A – Accuracy :

L'accuracy est la mesure du taux de réussite global du modèle face à tous les échantillons mis en tests.

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

Avec :

TP : Vrais positifs.

TN : Vrais négatifs.

FP : Faux positifs.

FN : Faux négatifs.

Une valeur élevée de l'Accuracy indique que le modèle effectue correctement la majorité des classifications.

B – Precision :

La précision mesure la proportion des prédictions positives qui sont réellement positives.

$$Precision = \frac{TP}{TP+FP} \quad (3.2)$$

Une précision élevée signifie que lorsque le modèle détecte un nid-de-poule, cette détection est généralement correcte.

C – Recall (Rappel) :

Le recall (ou taux de rappel) mesure la capacité du modèle à identifier tous les exemples positifs présents dans les données.

$$Recall = \frac{TP}{TP+FN} \quad (3.3)$$

Une valeur élevée du Recall indique que le modèle parvient à détecter la majorité des nids-de-poule présents dans les images.

3.3.1.6. Résultats et performances des classificateurs

Les expérimentations ont été réalisées sur deux versions de la base de données : une base non équilibrée et une base équilibrée. Les performances des méthodes d'extraction de caractéristiques LBP, HOG et LBP+HOG ont été évaluées à l'aide des classifieurs SVM et ANN selon les métriques Accuracy, Recall et Precision.

A. Jeu de données non équilibré :

D'après les résultats obtenus selon le tableau 1 ci-dessous, la méthode LBP présente les performances les plus faibles. Avec le classifieur SVM, elle atteint une accuracy de 80 % et une précision de seulement 58.33 %. Cette faible valeur indique la présence d'un nombre relativement élevé de fausses détections de nids-de-poule.

Tableau 3.2. : performance de classification dans le cas de la base de données non équilibrée :

Methode d'extraction	SVM			ANN		
	Accuracy (%)	Recall(%)	Precision (%)	Accuracy(%)	Recall(%)	Précision(%)
LBP	80,00	84,00	58,33	85,26	72,00	72,00
HOG	93,68	84,00	91,30	91,58	92,00	79,31
LBP + HOG	93,68	84,00	91 ,30	91,58	88,00	81,48

Les descripteurs HOG et LBP+HOG offrent des résultats nettement supérieurs. Avec le classifieur SVM, ils obtiennent tous deux une accuracy de 93,68 % et une précision de 91,30 %, montrant une meilleure capacité à distinguer les images contenant des nids-de-poule des images normales.

Pour le classifieur ANN, les meilleures performances en termes d'accuracy sont également obtenues avec HOG et Concaténation des vecteurs de caractéristiques LBP et HOG (91,58 %). Cependant, HOG présente le meilleur rappel (92 %), ce qui signifie qu'il détecte davantage de nids-de-poule réels. La combinaison LBP+HOG obtient un rappel légèrement inférieur (88 %), mais conserve une bonne précision (81,48 %).

Ces résultats montrent que, sur un jeu de données non équilibré, les caractéristiques de gradient extraites par HOG sont plus discriminantes que les informations de texture fournies par LBP.

La Figure 3.5 présente une comparaison des performances des méthodes LBP et HOG en termes d'Accuracy, de Precision et de Recall, dans le cas d'une base de données non équilibrée.

Ce graphique compare les performances de deux modèles (SVM et ANN) selon les critères Accuracy, recall et précision. On remarque globalement que le modèle SVM obtient de meilleurs résultats et des scores plus élevés que le modèle ANN.




Figure 3.5 : Comparaison des méthodes LBP et HOG selon les mesures de performance Accuracy, Precision et Recall (cas Base de données non équilibrée).

B. Base de données équilibrées

Après équilibrage (data-augmentation) de la base de données, une amélioration générale des performances est observée (tableau 3.3).

Tableau 3.3. : performance de classification dans le cas de la base de données équilibrée :

Méthode d'extraction	SVM			ANN		
	Accuracy (%)	Recall(%)	Precision (%)	Accuracy(%)	Recall(%)	Précision(%)
LBP	87,88	87,88	87 ,88	90,91	89,39	92,19
HOG	90,91	98,48	85,53	89,39	98,48	83,33
LBP+HOG	90,91	98,48	85,53	90,91	85,53	98,48

Selon les résultats présentés dans le tableau 3.3 , le classifieur SVM obtient une accuracy de 87,88 % avec le descripteur LBP, tandis que les méthodes HOG et la concaténation des caractéristiques LBP et HOG atteignent une performance supérieure avec une accuracy de 90,91 %. De plus, ces deux dernières approches enregistrent un rappel de 98,48 %, témoignant d'une très bonne capacité à identifier les images contenant des nids-de-poule. Néanmoins, leur précision de 85,53 % indique la présence de quelques faux positifs, c'est-à-dire des images de routes normales classées à tort comme dégradées. Avec le classifieur ANN, les résultats montrent une amélioration de LBP, qui atteint une accuracy de 90,91 % et une précision de 92,19 %. La méthode HOG conserve le meilleur rappel (98,48

%), démontrant sa grande efficacité pour détecter les défauts de chaussée. La Concaténation des vecteurs de caractéristiques LBP et HOG obtient également une accuracy élevée de 90,91 % et la meilleure précision (98,48 %), ce qui indique une très bonne fiabilité des classifications positives.

L'équilibrage de la base a donc permis d'améliorer la capacité de généralisation des modèles et de réduire l'influence du déséquilibre entre les classes.

La figure 3.6 ci-dessous présente une comparaison des performances des méthodes LBP et HOG en termes d'Accuracy, de Precision et de Recall, dans le cas d'une base de données équilibrée.

Cette figure présente une comparaison des performances des trois méthodes d'extraction de caractéristiques (LBP, HOG et LBP+HOG) avec les classificateurs SVM et ANN. Les résultats montrent que les meilleures performances sont obtenues avec l'extracteur HOG et la combinaison LBP+HOG. Avec le classificateur SVM, ces deux approches atteignent un rappel de 98,48 %, traduisant une excellente capacité à détecter les nids-de-poule. De même, le classificateur ANN obtient un rappel de 98,48 % avec l'extracteur HOG, tandis que la combinaison LBP+HOG permet d'atteindre une précision de 98,48 %, ce qui reflète une très bonne fiabilité dans la classification des images.




Figure 3.6 : Comparaison des méthodes LBP et HOG selon les mesures de performance Accuracy, Precision et Recall (cas Base de données équilibrée).

C. Influence de l'équilibrage de la base de données sur les performances de classification

Au début de cette étude, la base de données téléchargée depuis Kaggle a été soumise à une étape de nettoyage visant à supprimer les images de mauvaise qualité ainsi que celles présentant un étiquetage erroné. À l'issue de ce prétraitement, le jeu de données est devenu déséquilibré, comprenant 300 images de routes normales contre seulement 159 images de nids-de-poule.

L'apprentissage réalisé sur cette base déséquilibrée a produit des résultats acceptables, mais les performances restaient limitées. Cette situation s'explique par le déséquilibre entre les deux classes, qui pousse les classifieurs à favoriser la classe majoritaire (route normal) en défavorisant la classe minoritaire (nids-de-poule). Le modèle a donc davantage appris les caractéristiques des routes normales que celles des nids-de-poule, ce qui a affecté sa capacité à détecter correctement tous les défauts de chaussée.

Afin de remédier à ce problème, une étape d'augmentation des données a été réalisée. Les images de la classe minoritaire ont été enrichies à l'aide de techniques d'augmentation d'images, notamment la rotation. De nouvelles images de nids-de-poule ont ainsi été générées afin d'obtenir un jeu de données équilibré. Le jeu de données final comportait 220 images de routes normales et 220 images de nids-de-poule.

Les résultats obtenus sur cette base équilibrée montrent une amélioration globale des performances des classifieurs SVM et ANN (tableau 3.3). Cette amélioration confirme que l'équilibrage des classes permet au modèle d'apprendre de manière plus équitable les caractéristiques des deux catégories d'images, ce qui conduit à une meilleure capacité de détection des nids-de-poule et à une augmentation des valeurs d'Accuracy, de Recall et de Precision

3.3.2. Partie implémentation sur Raspberry Pi5

3.3.2.1. Présentation de la plateforme Raspberry Pi5

Le Raspberry Pi 5 (figure 3.7) est la dernière génération de la célèbre carte monocarte de la Fondation Raspberry Pi. Il s'agit d'un ordinateur compact et puissant, conçu pour les applications embarquées, l'edge computing, l'intelligence artificielle et le traitement d'images en temps réel. Dans notre système de détection des nids-de-poule, le Raspberry Pi 5 constitue le cœur du traitement embarqué : il acquiert les images depuis la caméra, exécute les

algorithmes de vision par ordinateur et de classification, puis pilote la sortie de signalisation (LED).

Grâce à son processeur haute performance, à sa mémoire vive importante et à son support des interfaces modernes (USB 3.0, GPIO, CSI pour caméra), le Raspberry Pi 5 permet d'exécuter efficacement des modèles d'apprentissage automatique tout en maintenant une faible consommation énergétique, ce qui le rend idéal pour une intégration sur véhicule. [39]




Figure 3.7 : Architecture d'un Raspberry Pi 5

- Caractéristiques principales

- **Processeur** : Broadcom BCM2712 quad-core Cortex-A76 (64 bits) cadencé à 2,4 GHz.
- **Mémoire vive** : disponibles en 4 Go, 8 Go.
- **Graphiques** : VideoCore VII GPU avec prise en charge OpenGL ES 3.1, Vulkan 1.2.
- **Connectivité** : Wi-Fi 6, Bluetooth 5.0, Gigabit Ethernet.

- **Interfaces** : 2 × USB 3.0, 2 × USB 2.0, 2 × micro-HDMI (jusqu'à 4K@60fps), GPIO 40 broches, CSI (caméra), DSI (écran).
- **Alimentation** : via USB-C (5 V / 5 A recommandé).
- **Stockage** : carte microSD (haute vitesse recommandée).
- **Système d'exploitation** : Raspberry Pi OS (basé sur Debian), compatible avec Python, OpenCV, TensorFlow, scikit-learn, etc.

3.3.2.2. La caméra Web 812H

La caméra Web 812H est une webcam Full HD destinée aux applications de visioconférence, d'enseignement à distance, de streaming et de communication vidéo.

Dotée d'un capteur de 2 mégapixels, elle fournit des images d'une résolution de 1920 × 1080 pixels (1080p) à une cadence de 30 images par seconde, assurant ainsi une qualité visuelle satisfaisante. Son angle de vision de 90° permet de couvrir une zone relativement étendue, ce qui la rend adaptée à diverses situations d'acquisition. Alimentée directement par le port USB (5 V), elle prend en charge les formats vidéo MJPEG et H.264, offrant une bonne compatibilité avec les applications de traitement et de diffusion vidéo. Selon les conditions d'utilisation, son fonctionnement optimal est assuré pour des distances comprises entre 1,5 et 5 mètres. [40]



Figure 3.8 : une photo du Camera web 812H

3.3.2.3 Diode électroluminescente (LED)

Les diodes électroluminescentes (DEL) sont des composants électriques de petite taille qui produisent de la lumière. Elles opèrent en associant des sortes de semiconducteurs complémentaires. Traditionnellement, les LED sont employées pour signaler la condition des dispositifs. Elles peuvent signaler si un dispositif est sous tension, hors tension ou en mode veille. Un certain nombre de LED peuvent signaler un niveau d'entrée ou de sortie, à l'instar du volume sur une console de mixage. [41]




Figure 3.9 : une photo d'une diode électroluminescente (DEL)

3.3.2.4. Configuration du Raspberry Pi5

Pour la mise en œuvre du système de détection des nids-de-poule en temps réel, nous avons d'abord préparé et configuré la plateforme Raspberry Pi afin de permettre l'implémentation et l'exécution du modèle de classification. Déploiement du système sur une carte Raspberry Pi 5 sous Linux après l'entraînement et l'évaluation du modèle sur PC.

- Choix de la plateforme pour son faible coût, sa faible consommation énergétique et ses capacités de traitement en temps réel.
- Installation de Raspberry Pi OS sur une carte microSD, puis configuration et mise à jour du système.
- Activation et test du module caméra pour vérifier la qualité des images acquises.
- Mise en place d'un environnement Python avec installation des bibliothèques : OpenCV, NumPy, Scikit-learn, LBP et HOG.
- Transfert du modèle de classification entraîné vers la Raspberry Pi.
- Résultat final : système embarqué autonome capable de détecter les nids-de-poule en temps réel.

Partie soft Raspberry :

1. **Poste de travail** : nous avons utilisé l'ordinateur pour développer le système, écrire le code et le connecter au circuit afin de tester le programme.
2. **Langage de programmation** : nous avons utilisé le langage python pour le traitement d'images et leurs classifications.
3. **Python** : Python est un langage de programmation polyvalent et accessible, largement utilisé pour le développement d'applications dans divers domaines tels que le

développement web, l'analyse de données, la robotique et l'intelligence artificielle. Il est particulièrement apprécié pour sa simplicité de syntaxe, proche du langage naturel, ce qui facilite son apprentissage et sa compréhension, notamment pour les débutants.

Grâce à sa richesse en bibliothèques et à sa grande flexibilité, Python permet de réaliser des projets complexes de manière efficace, tout en réduisant la quantité de code nécessaire. Cette simplicité, combinée à sa puissance, en fait un outil incontournable pour le prototypage rapide et le développement de solutions concrètes dans des délais réduits. [42]




Figure 3.10 : environnement python

4. Bibliothèques utilisées

Plusieurs bibliothèques ont été utilisées afin d'assurer le bon fonctionnement du programme :

- **OpenCV** : bibliothèque principale dédiée au traitement d'images, à l'acquisition via caméra ainsi qu'à la détection de formes et d'anomalies telles que les nids-de-poule.
- **NumPy** : bibliothèque utilisée pour la manipulation et le traitement des données sous forme de matrices et de tableaux multidimensionnels.
- **TensorFlow** : utilisée pour la conception et l'entraînement du modèle d'apprentissage profond permettant de détecter la présence ou l'absence d'un nid-de-poule.
- **RPi.GPIO / gpiozero** : bibliothèques permettant le contrôle des broches GPIO de la Raspberry Pi, notamment pour l'activation d'une LED en fonction du résultat de la détection.

5. Outils de développement

- **Spyder** : est un environnement de développement intégré (IDE) dédié au langage Python, principalement utilisé pour le calcul scientifique et l'analyse de données. Il offre des fonctionnalités telles que l'édition de code, le débogage, l'exécution interactive ainsi que la visualisation des variables. Développé par la communauté scientifique et intégré à la distribution Anaconda, il est compatible avec Windows, macOS et Linux et constitue un outil apprécié pour le développement et la recherche en Python. [43]
- **Terminal** : Le terminal est une interface en ligne de commande permettant l'interaction entre l'utilisateur et le système d'exploitation. Dans les environnements Unix/Linux, il donne accès à un shell permettant l'exécution de commandes, la gestion du système et l'automatisation des tâches. Il constitue ainsi un outil essentiel pour le développement et l'administration des systèmes informatiques. [44]

3.3.3. Résultats de la classification en temps réel

Afin d'évaluer les performances du système en conditions réelles, plusieurs images représentant les deux classes ont été utilisées : des images de chaussées présentant des nids-de-poule et des images de routes en bon état. Ces images ont été présentées successivement devant la caméra du système afin de simuler un fonctionnement en temps réel.

Le processus de traitement suit une séquence bien définie. À chaque intervalle de temps, la caméra capture une image de la scène. Cette image est ensuite transmise au système embarqué où elle subit les différentes étapes de traitement, notamment le prétraitement, l'extraction des caractéristiques et la classification à l'aide du modèle entraîné.

En fonction du résultat obtenu par le classificateur, une décision est prise automatiquement. Si un nid-de-poule est détecté, la LED s'allume afin de signaler la présence d'une dégradation de la chaussée. Dans le cas contraire, la LED reste éteinte, indiquant que la route est en bon état.

Ce fonctionnement en temps réel permet de valider l'efficacité du système développé, ainsi que sa capacité à effectuer une détection automatique et rapide des anomalies de la chaussée dans un environnement embarqué.

La figure ci-dessous illustrent le matériel utilisé dans notre système de détection et de classification des nids-de-poule basé sur l'apprentissage automatique, dans le cadre des

Systèmes de Transport Intelligents (STI). Elles présentent les principaux composants matériels du dispositif, notamment la plateforme embarquée Raspberry Pi 5 ainsi que la caméra embarquée installée sur un véhicule. Ce matériel constitue l'unité principale du système et permet l'acquisition des images de la chaussée ainsi que l'exécution des algorithmes de traitement et de classification en conditions réelles.




Figure 3.11 : Matériel utilisé dans le système de détection et de classification des nids-de-poule basé sur l'apprentissage automatique

3.4. Conclusion

Dans ce chapitre, nous avons présenté la phase pratique du projet consacrée à la mise en œuvre du système de détection automatique des nids-de-poule. Nous avons décrit l'architecture matérielle et logicielle adoptée, basée sur une plateforme embarquée Raspberry Pi 5, une caméra pour l'acquisition des images et une LED pour l'indication des résultats. Le processus global du système a ensuite été détaillé, allant de la capture des images à leur

traitement par des techniques de vision par ordinateur et leur classification à l'aide d'algorithmes de Machine Learning. Enfin, l'intégration du modèle sur la plateforme embarquée a permis d'obtenir un système fonctionnel capable d'effectuer une détection en temps réel.

Ainsi, ce chapitre a permis de valider la faisabilité de la solution proposée et de démontrer l'efficacité de l'approche adoptée dans un environnement embarqué. Il a également mis en évidence l'importance de l'équilibrage des classes dans la base de données, lequel constitue un facteur essentiel pour obtenir des performances de classification élevées, améliorer la capacité de généralisation du modèle et garantir une détection fiable des nids-de-poule.



Conclusion générale et perspectives

L'objectif principal de ce travail était de concevoir et de mettre en œuvre un système intelligent capable de détecter automatiquement les nids-de-poule à partir d'images de la chaussée. Cette problématique s'inscrit dans le contexte des systèmes de transport intelligents, dont l'ambition est d'améliorer la sécurité routière, la mobilité et la gestion des infrastructures grâce aux technologies numériques et à l'intelligence artificielle.

Dans un premier temps, nous avons étudié les concepts fondamentaux des systèmes de transport intelligents ainsi que les technologies qui les composent. Cette étude a permis de mettre en évidence l'importance croissante de l'automatisation et de l'analyse des données dans la surveillance et la maintenance des infrastructures routières.

Dans un second temps, nous avons présenté les principes de la vision par ordinateur et du Machine Learning appliqués à la détection des défauts routiers. Les méthodes d'extraction de caractéristiques LBP et HOG ainsi que les classificateurs SVM et ANN ont été étudiés et évalués afin d'identifier les approches les plus adaptées à notre problématique.

Il a également mis en évidence l'importance de l'équilibrage des classes dans la base de données, lequel constitue un facteur essentiel pour obtenir des performances de classification élevées, améliorer la capacité de généralisation du modèle et garantir une détection fiable des nids-de-poule.

Enfin, nous avons développé et implémenté un système embarqué reposant sur une plateforme Raspberry Pi 5 associée à une caméra d'acquisition d'images. Le système réalisé est capable de capturer des images de la chaussée, d'effectuer leur traitement, d'extraire les caractéristiques pertinentes et de classifier automatiquement les scènes afin de détecter la présence ou l'absence de nids-de-poule. Les expérimentations réalisées en temps réel ont permis de valider la faisabilité de la solution proposée et de démontrer son efficacité dans un environnement embarqué.

Les résultats obtenus montrent que l'association des techniques de vision par ordinateur et des algorithmes d'apprentissage automatique constitue une approche prometteuse pour la surveillance automatisée de l'état des routes. Cette solution peut contribuer à améliorer la sécurité des usagers et à faciliter les opérations de maintenance préventive des infrastructures routières.

Perspectives

Malgré les résultats encourageants obtenus, plusieurs perspectives d'amélioration peuvent être envisagées :

- Enrichir la base de données d'images afin d'augmenter la diversité des conditions d'éclairage, des types de chaussées et des dégradations rencontrées.
- Étudier l'utilisation de modèles d'apprentissage profond (Deep Learning), notamment les réseaux de neurones convolutifs (CNN), afin d'améliorer davantage les performances de détection.
- Étendre le système à la détection d'autres défauts routiers tels que les fissures, les affaissements ou les déformations de la chaussée.
- Intégrer un module de géolocalisation GPS permettant de localiser automatiquement les défauts détectés.

Référence :

- [1] Intelligent Transportation Systems R. Gordon, *Intelligent Transportation Systems: Functional Design for Effective Traffic Management*. Springer, 2010.
- [2] IEEE Intelligent Transportation Systems Society, *Intelligent Transportation Systems Handbook*, Wiley-IEEE Press, 2015.
- [3] organisation internationale de normalisation (iso)
Lien: [https:// www.iso.org/fr/transport/str-systemes-transport-intelligent](https://www.iso.org/fr/transport/str-systemes-transport-intelligent) Thème: transport/ systèmes de transport intelligents (sti)
- [4] :Fundamentals of Intelligent Transportation Systems Planning
M. A. Chowdhury and A. Sadek, *Fundamentals of Intelligent Transportation Systems Planning*. Artech House, 2003.
- [5] : H. Wang, Y. Peng, and X. Zhang, "City Brain: Practice of Large-Scale Artificial Intelligence in Urban Governance," *Alibaba Cloud White Paper*, 2020.(Alibaba Group)
- [6] Land Transport Authority (LTA), *Smart Mobility 2030: ITS Strategic Plan for Singapore*, Singapore, 2014.
- [7] Oslo Municipality, *Climate and Energy Strategy for Oslo*, 2020.
- [8] Dirección General de Tráfico (DGT), *Intelligent Transport Systems and Smart Roads in Spain*, Madrid, 2021.
- [9] CEREMA, *Les systèmes de transport intelligents au service de la mobilité urbaine*, France, 2021.
- [10] : Computer Vision: Algorithms and Applications R. Szeliski, *Computer Vision: Algorithms and Applications*, 2nd ed. Springer, 2022.
- [11] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [12] Vision par ordinateur et perception automobile Computer Vision: Algorithms and Applications R. Szeliski, *Computer Vision: Algorithms and Applications*, 2nd ed. Springer, 2022.
- [13] Intelligent Transportation Systems R. Gordon, *Intelligent Transportation Systems: Functional Design for Effective Traffic Management*. Springer, 2010.
- [14] Fusion de capteurs et perception en véhicules intelligents Computer Vision: Algorithms and Applications R. Szeliski, *Computer Vision: Algorithms and Applications*, 2nd ed. Springer, 2022.

- [15] Vision par ordinateur et traitement d'images Digital Image Processing
R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, 4th ed. Pearson, 2018.
- [16] LiDAR et perception 3D en systèmes intelligents Autonomous Driving
M. Maurer, J. C. Gerdes, B. Lenz, and H. Winner, *Autonomous Driving: Technical, Legal and Social Aspects*. Springer, 2016.
- [17] Capteurs inertiels et systèmes de transport intelligents Autonomous Driving
M. Maurer, J. C. Gerdes, B. Lenz, and H. Winner, *Autonomous Driving: Technical, Legal and Social Aspects*. Springer, 2016.
- [18] Vision par ordinateur et Deep Learning Deep Learning I. Goodfellow et al., *Deep Learning*. MIT Press, 2016.
- [19] G. Dimitrakopoulos, P. Demestichas, "Intelligent Transportation Systems", IEEE Communications Surveys & Tutorials, 2010.
- [20] Tom M. Mitchell, *Machine Learning*, McGraw-Hill, New York, 1997.
- [21] Raj Rajkumar, William M. Shanker et Lyle Brown, "On the Road to Autonomous Vehicles: Challenges and Opportunities", *IEEE Computer*, vol. 49, no. 12, pp. 62–68, 2016.
- [22] Christopher M. Bishop, *Pattern Recognition and Machine Learning*, Springer, 2006.
- [24] Richard Szeliski, *Computer Vision: Algorithms and Applications*, 2nd ed., Springer, 2022.
- [25] : T. Ojala, M. Pietikäinen, and D. Harwood. A comparative study of texture measures with classification based on feature distribution. *Pattern Recognition*, vol. 29, no. 1, pp. 51–59, 1996.
- [26] N. Dalal and B. Triggs. Histograms of oriented gradients for human detection. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, vol. 1, pp. 886–893, San Diego, CA, USA, 2005.
- [27] Duda, R. O., Hart, P. E., & Stork, D. G. (2001). *Pattern Classification* (2nd ed.). New York: John Wiley & Sons.
- [28] Corinna Cortes, & Vladimir Vapnik (1995). *Support-Vector Networks*. *Machine Learning*, 20(3), 273–297.

[29] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, NJ, USA: Prentice Hall, 2009.

[30] Wang, J., Meng, Q., Shang, P., & Saada, M. (2021). *Road surface real-time detection based on Raspberry Pi and recurrent neural networks*. Transactions of the Institute of Measurement and Control, 43(11), 2540–2550. <https://doi.org/10.1177/01423312211003372>. Cette étude présente un système embarqué utilisant une plateforme Raspberry Pi pour l'acquisition, le traitement et la classification en temps réel de l'état de la chaussée

[31] Ahmed, S. U., Ayaz, H., Rizvi, S. A. S., Hashmi, M. H., Humayon, M., & Salam, M. S. (2024). Pothole Detection using Computer Vision and Raspberry Pi. *Journal of Computing & Biomedical Informatics*, 7(1), 690–695.

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

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

[100] : kaggle : (<http://www.kaggle.com/serach> photole+in%3adastaset

[34] Timo Ojala, Matti Pietikäinen & Topi Mäenpää (2002). *Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 24(7), 971–987.

[35] Navneet Dalal & Bill Triggs (2005). *Histograms of Oriented Gradients for Human Detection*. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 886–893.

[36] Corinna Cortes & Vladimir Vapnik (1995). *Support-Vector Networks*. IEEE Transactions on Machine Learning, 20(3), 273–297.

[37] Simon Haykin (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson Education.

[38] Introduction to Information Retrieval, Christopher D. Manning, Prabhakar Raghavan & Hinrich Schütze (2008). *Introduction to Information Retrieval*. Cambridge University Press.

[39] Raspberry Pi Documentation – Raspberry Pi 5 Specifications. Raspberry Pi Foundation, 2025.

[40] Fujikam. (2020). *FUJIKAM 812H Full HD Webcam – Technical Specifications*. Documentation technique du produit.

- [41] E. Fred Schubert (2006). *Light-Emitting Diodes* (2nd ed.). Cambridge University Press.
- [42] Guido van Rossum & Fred L. Drake Jr. (2009). *Python 3 Reference Manual*. CreateSpace.
- [43] Pierre Raybaut (2009). *Spyder-Project: Scientific Python Development Environment*. Disponible sur le projet Spyder.
- [44] William Shotts (2019). *The Linux Command Line: A Complete Introduction* (2nd ed.). No Starch Press.