



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE
MINISTERE DE L'ENSEIGNEMENT SUPERIEURE ET DE LA RECHERCHE
SCIENTIFIQUE

UNIVERSITE IBN KHALDOUN - TIARET

MÉMOIRE

Présenté à:

FACULTÉ MATHÉMATIQUES ET INFORMATIQUE
DÉPARTEMENT D'INFORMATIQUE

Pour l'obtention du diplôme de:

MASTER

Spécialité : Réseaux et Télécommunications

Par :

GARN HADJIRA & BLIDI FARAH FERIAL


Sur le thème

Application de la Théorie de l'Évidence à la Fusion de Données Multi-Capteurs dans les Véhicules Autonomes

Soutenu publiquement le 17/ 06 / 2025 à Tiaret devant le jury composé de :

Mme KERMAS	Nawal	MCB	Université Ibn Khaldoun	Président
Mr BOUALEM	Adda	MCA	Université Ibn Khaldoun	Encadreur
Mr BERBER	Elmehdi	MAA	Université Ibn Khaldoun	Examineur

2024 -2025



Remerciements

Nous remercions tout d'abord ALLAH tout-puissant de nous avoir données la santé, la patience et le courage pour mener à bien ce mémoire .

Nous remercions nos chers parents qui ont toujours été là pour nous .

Nous remercions nos sœurs et nos frères pour leurs encouragements .


Nous tenons à témoigner notre plus profonde gratitude à notre encadrant,

Monsieur BOUALEM Adda , qui a dirigé ce travail, pour nous avoir proposées un sujet aussi passionnant et intéressant. Sa disponibilité permanente et son aide nous ont été d'un soutien précieux, dont nous lui sommes particulièrement reconnaissants . Sa compétence et ses conseils nous ont été d'un grand secours. Encore merci !

Par ailleurs, nous tenons à exprimer nos vifs remerciements aux membres du jury : Mme KERMAS Nawal et Monsieur BERBER Elmehdi, qui ont consacré de leur temps pour examiner et juger notre travail de façon minutieuse .

D'autre part, nous adressons une chaleureuse pensée à toute l'équipe pédagogique du Département d'Informatique .

Enfin, un grand merci à toute personne nous ayant aidées et guidées pour la réalisation de ce travail.



Résumé

Dans ce projet de fin d'études, nous avons travaillé sur la fusion de données provenant de capteurs utilisés dans les véhicules autonomes, comme les radars, caméras et lidars. Ces capteurs peuvent être imprécis ou donner des informations différentes sur une même situation. L'objectif principal de notre travail était de mettre en place une méthode permettant de mieux comprendre l'environnement autour du véhicule, malgré ces incertitudes. Pour cela, nous avons utilisé la théorie de l'évidence (appelée aussi théorie de Dempster-Shafer), en nous concentrant sur trois types d'objets à reconnaître : un véhicule, un piéton, ou un objet immobile. Nous avons testé notre approche sur des données générées de manière aléatoire, puis analysé les résultats à l'aide de plusieurs mesures comme la précision, le rappel (recall) et le taux d'efficacité. Les résultats montrent que notre méthode permet une meilleure prise de décision et améliore la fiabilité de la perception du véhicule dans des situations incertaines.

Mots-clés : Véhicules autonomes, Fusion de données, Capteurs incertains, Perception, Prise de décision.

Abstract

In this final year project, we worked on combining data from sensors used in autonomous vehicles, such as radars, cameras, and LiDARs. These sensors can sometimes be inaccurate or give different information about the same situation. The main goal was to develop a method to better understand the vehicle's surroundings, even when the sensor data is uncertain. To do this, we used evidence theory (also known as Dempster-Shafer theory), focusing on detecting three types of objects: vehicles, pedestrians, and static objects. We tested our approach on randomly generated data and evaluated the results using several metrics such as precision, recall, and efficiency rate. The results show that our method improves decision-making and enhances the reliability of the vehicle's perception in uncertain conditions.

Keywords: Autonomous vehicles, Data fusion, Uncertain sensors, Perception, Decision-making.

المخلص

في مشروع نهاية الدراسة، عملنا على دمج البيانات الناجمة من أجهزة الاستشعار المستخدمة في المركبات الذاتية القيادة، مثل الرادارات، الكاميرات، والليدار. هذه الأجهزة قد تعطي أحياناً معلومات غير دقيقة أو متضاربة حول نفس الوضع. كان الهدف الرئيسي هو تطوير طريقة تساعد المركبة على فهم محيطها بشكل أفضل، حتى في ظل وجود شك أو غموض في البيانات. لتحقيق ذلك، استخدمنا نظرية الأدلة (المعروفة أيضاً باسم نظرية دمبسترشافر)، مع التركيز على التعرف على ثلاثة أنواع من الكائنات: مركبة، أو مشاة، أو جسم ثابت. قمنا باختبار طريقتنا على بيانات تم توليدها عشوائياً، وقمنا بتحليل النتائج باستخدام عدة مؤشرات مثل الدقة، الاسترجاع، ومعدل الكفاءة. وقد أظهرت النتائج أن طريقتنا تُحسن من عملية اتخاذ القرار وتزيد من موثوقية إدراك المركبة في ظروف غير مؤكدة.

الكلمات المفتاحية: المركبات الذاتية القيادة، دمج البيانات، أجهزة استشعار غير مؤكدة، الإدراك، اتخاذ القرار.

Sommaire

Liste des Figures	v
Liste des Tables	vi
Liste des Abréviations	vii
Introduction Générale	2
1 Introduction au Véhicules Autonomes	5
1.1 Définition	5
1.2 Classification d'autonomie des véhicules	5
1.3 Concepts	6
1.4 Avantages potentiels	7
1.5 Défis et les incertitudes	8
1.5.1 Problème de la Fusion des données de perception	8
1.6 Conclusion	8
2 État de L'art sur la fusion des données dans les Véhicules Autonomes	10
2.1 Introduction	10
2.2 Stratégies de Fusion des Données de Perception	10
2.2.1 Stratégies de Fusion Statique	10
2.2.2 Stratégies de fusion adaptative	11
2.2.3 Stratégies de fusion contextuelles	12
2.2.4 Stratégies de fusion augmentées par l'IA	13
2.3 Conclusion	14
3 Théorie de L'évidence	16
3.1 Théories de l'incertitude dans la gestion des situations incertaines	16
3.2 Théorie de L'évidence	18
3.2.1 Cadre de discernement :	18
3.2.2 Fonction de croyance et de plausibilité :	18
3.2.3 Combinaison d'information avec la TDS :	20
3.2.4 Prise de décision par la TDS :	21
3.2.5 Exemple de Déroulement de Théorie de L'évidence	22
3.3 Conclusion	25
4 Méthodologie & Réalisation et Analyse de Résultats	27
4.1 Méthodologie	27
4.1.1 Choix du langage de programmation	27
4.1.2 Approche de fusion multi-capteurs à base de TDS	28
4.1.3 Conception de notre approche	28
4.2 Présentation de notre stratégie de Fusion des données de perception à base de théorie de l'évidence	30
4.3 Evaluation de notre Stratégie	36

4.4 Conclusion	37
Conclusions et Perspectives	39

Table des figures

1.1	les niveaux d'autonomie d'un véhicule	6
1.2	Les Capteurs Multisources.	6
1.3	Interactions V2X : Communication entre véhicules, piétons et infrastructure ITS.	7
1.4	Enchaînement des étapes de théorie de l'évidence.	7
2.1	La Classification de Stratégies de Fusion de Données de Perception dans les Véhicules Autonomes	11
3.1	(a) La relation entre les Théories de l'incertain (b) Lien étroit entre les données incertaines et les théories correspondantes	17
3.2	Processus de Décision à base de Théorie de Dempster-Shafer [1].	21
4.1	PyCharm Community Edition 2024.2.4.	27
4.2	Diagramme de classes de l'architecture proposée.	29
4.3	Diagramme d'activités du processus de fusion.	29
4.4	Notre Modèle de fusion à base Théorie de l'évidence.	31
4.5	L'interface "À propos" de l'application proposée.	32
4.6	L'interface "Menu Principal" de l'application proposée.	32
4.7	Les dimensions Imprécises des Obstacles à Détecter.	33
4.8	L'objet Détecté est Piéton.	34
4.9	L'objet Détecté est Objet Immobile.	34
4.10	L'objet détecté est Véhicule.	35
4.11	Résultats d'évaluation statistique du système de fusion	35
4.12	Base de Données de 2000 scénarios pour évaluer notre stratégie.	36

Liste des tableaux

2.1	Défis et limitations des stratégies de fusion actuelles	14
4.1	Evaluation par les paramètres Statistique de fusion de données par DST	37

Liste des Abréviations

BDD	base de donnes
Bel	Bileve Function
Cr	Fonction de Croyance
IA	intelligence artificielle
ITS	Intelligent Transportation System
LIDAR	Light DetectionAnd Ranging
PI	Fonction de Pleusibilité
RADAR	RadioDetectionAnd Ranging
RSU	Road Side Unit
SAE	societya utomotive engineers
SN	Sensor Network
TDS	Théorie de Dempster Shafer
TN	Telecommunication Network
UAV	Unmanned Aerial Vehicle
UMB	Unscented Moving-Baseline
V2I	Vehicle To Infrastructure
V2V	Vehicle To Vehicle

Introduction Générale

Background

Les véhicules autonomes représentent une avancée technologique majeure susceptible de transformer durablement le secteur des transports. Leur développement s'accompagne toutefois de plusieurs défis techniques et sécuritaires qu'il est indispensable de maîtriser pour garantir un fonctionnement fiable, sûr et efficace.

Trois enjeux principaux se dégagent. Le premier concerne la perception de l'environnement, qui repose sur la capacité des capteurs embarqués (caméras, radars, lidars) à détecter et interpréter, avec précision les éléments du milieu en temps réel. La qualité de cette perception est déterminante pour la prise de décision du véhicule.

Le second défi est lié à la communication, aussi bien entre véhicules (V2V) qu'avec les infrastructures environnantes (V2I). Cette communication doit être rapide, stable, sécurisée et standardisée, afin d'assurer un échange d'informations fiable et continu.

Enfin, la sécurité constitue un enjeu transversal, englobant la résistance aux cyberattaques, la fiabilité des systèmes embarqués et la protection des données personnelles, afin de prévenir tout risque pour les usagers comme pour le système global.

Problématique

Face à ces défis, des solutions intégrées sont en cours de développement, visant à améliorer les performances des systèmes embarqués tout en garantissant un haut niveau de sûreté et de résilience. Ces travaux s'inscrivent dans une dynamique de recherche continue pour accompagner l'essor sécurisé et durable des véhicules autonomes.

Plan du mémoire

Le mémoire de ce PFE est structuré comme suit :

Une introduction générale qui présente le sujet, son importance dans le contexte des véhicules autonomes, ainsi que la problématique, les objectifs, et les questions de recherche associées.

Le chapitre 1, Généralités sur les véhicules autonomes, introduit les concepts de base des véhicules autonomes, leur évolution technologique, ainsi que les enjeux liés à leur développement.

Le chapitre 2 présente un État de l'art et une revue des technologies actuelles des véhicules autonomes, des méthodes de fusion de données, et une analyse critique des approches existantes face à l'incertitude.

Le chapitre 3 aborde la théorie de l'évidence (Dempster-Shafer Theory). Il donne une Présentation des fondements théoriques de cette théorie, et son application à la gestion de l'incertitude dans les systèmes de fusion.

Le chapitre 4 présente la méthodologie et les résultats de notre travail. C'est une description de la démarche expérimentale, du modèle proposé, des résultats obtenus, et de leur évaluation comparative.

Enfin, on termine notre travail par une section qui conclut et résume notre contribution, et propose des perspectives pouvant être des pistes possibles pour de futurs travaux.

Chapitre 1

Généralités sur Les Véhicules Autonomes

Chapitre 1

Introduction au Véhicules Autonomes

Ce chapitre présente les bases essentielles des véhicules autonomes, en mettant en évidence leurs bénéfices, leurs contraintes, ainsi que les principaux défis à relever pour assurer leur évolution dans les années à venir.

1.1 Définition

Les véhicules autonomes, également appelés véhicules automatisés ou sans conducteur, représentent une innovation majeure dans le domaine des transports. Ils utilisent des technologies avancées pour se déplacer sans intervention humaine, en combinant des capteurs, des logiciels d'intelligence artificielle (IA), des systèmes de localisation et des réseaux de communication.

1.2 Classification d'autonomie des véhicules

La SAE (Society of Automotive Engineers) a classé les véhicules autonomes selon une échelle de 0 à 5. Elle a établi une taxonomie de six niveaux (0-5) pour les véhicules autonomes, allant de l'absence totale d'automatisation à l'autonomie complète. Cette classification est basée sur les capacités du véhicule, les niveaux supérieurs nécessitant des technologies et une consommation d'énergie plus avancées [2].

- **Niveau 0** : Aucune automatisation (le conducteur contrôle tout).
- **Niveau 1** : Assistance à la conduite (ex. régulateur de vitesse adaptatif).
- **Niveau 2** : Automatisation partielle (le véhicule gère la direction et la vitesse, mais le conducteur doit rester vigilant).
- **Niveau 3** : Automatisation conditionnelle (le véhicule gère la conduite dans certaines conditions, mais peut demander au conducteur de reprendre le contrôle).
- **Niveau 4** : Automatisation élevée (le véhicule fonctionne de manière autonome dans des environnements spécifiques, sans intervention humaine).
- **Niveau 5** : Automatisation complète (le véhicule est entièrement autonome dans toutes les conditions).

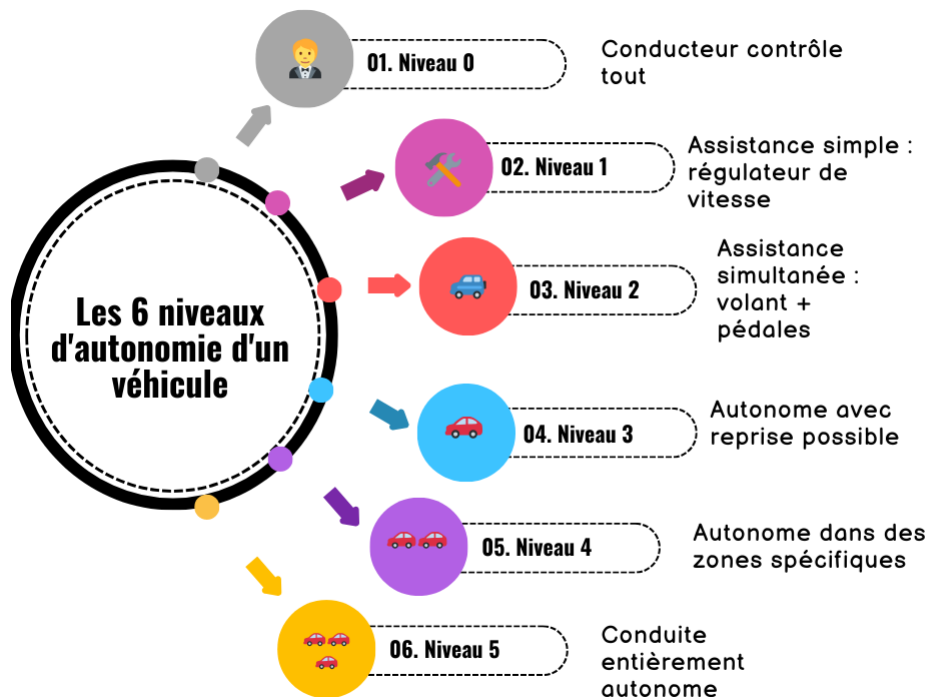


FIGURE 1.1: les niveaux d'autonomie d'un véhicule

1.3 Concepts

Les véhicules autonomes reposent sur plusieurs technologies, comme illustré dans la FIGURE 1.2 :

- **Capteurs** : Caméras, lidars, radars et ultrasons pour détecter l'environnement.




FIGURE 1.2: Les Capteurs Multisources.

[3]

- **Systèmes de localisation** : GPS de haute précision et cartes 3D pour se repérer.
- **Intelligence artificielle** : Algorithmes de traitement d'images, apprentissage profond (deep learning) et prise de décision.

- **Connectivité** : Communication entre véhicules (V2V) et avec l'infrastructure (V2I) pour une meilleure coordination (FIGURE 1.3).




FIGURE 1.3: Interactions V2X : Communication entre véhicules, piétons et infrastructure ITS.

- **Systèmes de contrôle** : Gestion de la direction, de l'accélération et du freinage (FIGURE 1.4).




FIGURE 1.4: Enchaînement des étapes de théorie de l'évidence.

[3]

1.4 Avantages potentiels

Parmi les avantages potentiels on cite:

- **Sécurité** : Réduction des accidents causés par l'erreur humaine (90% des accidents sont dus à des erreurs humaines).
- **Efficacité** : Optimisation des trajets, réduction des embouteillages et économie de carburant.
- **Accessibilité** : Mobilité pour les personnes âgées, handicapées ou sans permis.
- **Impact environnemental** : Promotion des véhicules électriques et réduction des émissions de CO₂.

1.5 Défis et les incertitudes

Parmi les défis et les limites, on cite:

- Sécurité et fiabilité : Risques liés aux défaillances techniques ou aux cyberattaques.
- Réglementation : Cadre légal encore en développement dans de nombreux pays.
- Acceptation sociale : Méfiance du public envers la technologie.
- Coûts : Prix élevé des technologies et de l'infrastructure nécessaire.
- Questions éthiques : Prise de décision dans des situations critiques (ex. dilemme du tramway).

1.5.1 Problème de la Fusion des données de perception

Le principal défi des véhicules autonomes réside dans la fusion des données incertaines collectées par les capteurs et la prise de décision appropriée en temps réel afin d'assurer une conduite précise, sûre et sans accidents. Cependant, cette technologie présente certaines faiblesses, parmi lesquelles :

- Tous les capteurs présentent des limitations qui peuvent les rendre inutilisables dans certaines conditions (masquages, portée réduite, biais, imprécisions, etc.).
- Une défaillance d'un capteur peut survenir à tout moment.
- La fusion multicapteur permet de combiner les données de plusieurs capteurs afin d'obtenir une information globale plus fiable et pertinente.
- Dans un véhicule autonome et connecté, cette fusion est essentielle pour assurer les différentes tâches de perception.
- Exemples d'application de la fusion multicapteur :
 - Détection et suivi des obstacles : fusion des données d'un capteur laser et d'une caméra, ou d'un radar et d'une caméra.
 - Localisation globale du véhicule : fusion des données de GNSS (localisation par satellite), d'INS (navigation inertielle) et d'odométrie (mesure du déplacement des roues).

1.6 Conclusion

Ce chapitre a posé les jalons essentiels relatifs aux véhicules autonomes, en soulignant les incertitudes engendrées par la fusion des données de perception. Le chapitre suivant s'attachera à présenter un état de l'art des travaux existants, en mettant particulièrement l'accent sur la Théorie de l'Évidence, qui constituera le cadre méthodologique de notre approche.

Chapitre 2
État de L'art sur la fusion des
données dans les Véhicules
Autonomes

Chapitre 2

État de L'art sur la fusion des données dans les Véhicules Autonomes

2.1 Introduction

Dans ce chapitre, nous présentons une classification structurée des approches de fusion des données appliquées aux véhicules autonomes. Cette classification repose sur quatre grandes catégories [4] : (a) Fusion basée sur des stratégies statiques, qui repose sur des règles prédéfinies et une intégration déterministe des données ; (b) Fusion basée sur des stratégies adaptatives, qui ajuste dynamiquement les paramètres de fusion en fonction des conditions environnementales et de la fiabilité des capteurs ; (c) Fusion basée sur des stratégies sensibles au contexte, qui intègre des informations contextuelles pour améliorer la robustesse et la pertinence des décisions ; (d) Stratégies de fusion augmentées par l'IA, qui exploitent les capacités des modèles d'apprentissage automatique et d'intelligence artificielle pour optimiser le processus de fusion et renforcer la prise de décision autonome. Cette classification permet de mieux comprendre les tendances actuelles et les défis liés à la fusion des données dans les systèmes de conduite autonome.

2.2 Stratégies de Fusion des Données de Perception

FIGURE. 2.1 illustre la structure de classification proposée par ce travail pour les stratégies de fusion de données et les algorithmes correspondants dans les véhicules autonomes.

2.2.1 Stratégies de Fusion Statique

- **Définition** : Les techniques de fusion de données intègrent des informations provenant de plusieurs sources afin d'améliorer la classification et la prise de décision [5]. Ces approches peuvent être classées en fonction du niveau de fusion : bas, intermédiaire ou élevé [6].
- **Avantages** : Faciles à implémenter et à traiter, elles offrent une simplicité de mise en œuvre.
- **Limites** : Elles manquent de flexibilité et ne s'adaptent pas aux environnements dynamiques.
- **Exemples d'algorithmes** :

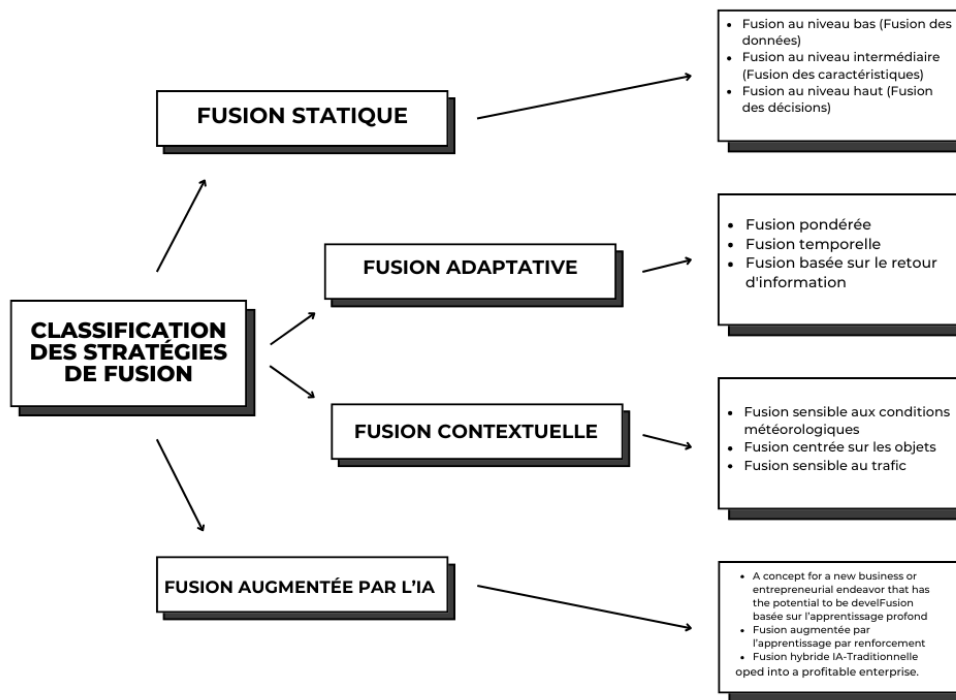


FIGURE 2.1: La Classification de Stratégies de Fusion de Données de Perception dans les Véhicules Autonomes

- Filtre de Kalman (fusion de bas niveau).
- Analyse en composantes principales pour la fusion de caractéristiques.
- Vote majoritaire pour la fusion au niveau décisionnel.

Les techniques d'assurance qualité statiques et dynamiques sont souvent combinées pour exploiter les effets de synergie, avec l'intégration et la compilation comme principales dimensions de combinaison [7].

Dans le domaine du traitement d'images, la fusion d'images multi-exposition (MEF) a suscité un vif intérêt en raison de sa capacité à améliorer la plage dynamique en intégrant des images prises avec différents niveaux d'exposition [8]. Les avancées récentes en analyse multi-échelle et en apprentissage profond ont considérablement amélioré les méthodes MEF [8].

La combinaison des analyses statiques et dynamiques est l'une des approches les plus courantes, généralement réalisée de manière intégrée [7]. Globalement, les stratégies de fusion de données continuent d'évoluer, offrant des performances améliorées dans divers domaines, allant de la classification des motifs au traitement d'images.

2.2.2 Stratégies de fusion adaptative

- **Définition** : Ces stratégies ajustent dynamiquement les poids et les méthodes de fusion en fonction de la fiabilité des capteurs et des conditions environnementales.
- **Avantages** : Elles sont résilientes face aux défaillances des capteurs et s'adaptent efficacement au bruit.

- **Exemples d'algorithmes :**

- Fusion pondérée des capteurs : ajuste les poids en fonction des niveaux de confiance en temps réel.
- Fusion temporelle : combine les informations sur une période pour améliorer la précision (par exemple, les réseaux de convolution temporelle).
- Mécanismes de rétroaction : utilisent les retours de la couche de contrôle pour affiner les paramètres de fusion.

Les stratégies de fusion adaptative ajustent dynamiquement les poids et les méthodes en fonction de la fiabilité des capteurs et des conditions environnementales. Ces approches offrent une résilience aux pannes de capteurs et s'adaptent efficacement au bruit [9].

Divers algorithmes illustrent la fusion adaptative, notamment la fusion pondérée des capteurs, qui ajuste les poids en fonction des niveaux de confiance en temps réel [3]. La fusion temporelle, comme les réseaux de convolution temporelle, combine les informations au fil du temps afin d'améliorer la précision. Les mécanismes de rétroaction exploitent les entrées de la couche de contrôle pour affiner les paramètres de fusion [10].

2.2.3 Stratégies de fusion contextuelles

- **Définition :** Ces approches intègrent le contexte environnemental (météo, trafic, etc.) pour optimiser les décisions de fusion.
- **Avantages :** Elles améliorent la robustesse du système dans des conditions adverses.
- **Exemples d'algorithmes :**
 - Fusion adaptée à la météo : bascule entre les capteurs en fonction des conditions météorologiques (par exemple, utilisation du radar par temps de brouillard).
 - Fusion centrée sur les objets : concentre les ressources de calcul sur les objets critiques (par exemple, les véhicules à proximité). Exemple : Fusion de données basée sur des preuves pour une perception robuste des véhicules autonomes [4].
 - Fusion adaptée au trafic : utilise les données V2X (vehicle-to-everything) pour prioriser les flux de fusion pertinents.

Les stratégies de fusion contextuelle dans les systèmes de fusion d'informations intègrent le contexte environnemental et opérationnel afin d'améliorer la robustesse et l'adaptabilité. Ces approches exploitent les informations contextuelles à différents niveaux, allant des contraintes physiques aux relations dynamiques [11]. Elles permettent d'améliorer l'estimation des entités et des situations dans divers domaines d'application, notamment l'intelligence ambiante, la défense et la cybersécurité [12].

Parmi les avancées récentes, ContextualFusion propose une approche de fusion basée sur les réseaux de convolution à portes (Gated Convolutional Fusion), qui adapte la fusion des capteurs en fonction du contexte opérationnel. Cette approche améliore considérablement la détection d'objets en 3D, notamment dans

des conditions défavorables [13]. Des travaux antérieurs, comme ceux de Nimier [14], ont proposé de combiner les informations symboliques et numériques dans les algorithmes de fusion afin d'adapter les performances du système à différents contextes. Cette méthode privilégie les mesures nominales des capteurs tout en réduisant l'impact des données aberrantes.

Grâce à ces stratégies de fusion basées sur le contexte, la robustesse des systèmes est considérablement renforcée dans diverses conditions environnementales, ce qui les rend essentielles pour des applications comme les véhicules autonomes évoluant dans des scénarios variés.

2.2.4 Stratégies de fusion augmentées par l'IA

- **Définition :** Ces stratégies exploitent l'apprentissage profond (deep learning) et l'apprentissage par renforcement pour optimiser la fusion à tous les niveaux.
- **Avantages :** Haut degré d'adaptabilité, scalabilité et capacité à apprendre des modèles complexes.
- **Exemples d'algorithmes :**
 - Fusion basée sur l'apprentissage profond : utilise des réseaux de neurones convolutifs (CNN) et récurrents (RNN) pour traiter les données des capteurs de manière holistique (par exemple, extraction de caractéristiques et fusion).
 - Apprentissage par renforcement : optimise les stratégies de fusion en fonction de systèmes de récompense (par exemple, évitement de collisions).
 - Fusion hybride IA-traditionnelle : combine des modèles basés sur l'IA avec des méthodes traditionnelles pour une meilleure interprétabilité.

Les recherches récentes soulignent l'importance des stratégies de fusion adaptative des données dans les systèmes de conduite autonome. Les systèmes de Conduite Autonome Augmentée par l'Infrastructure (IAAD) intègrent l'informatique embarquée et celle en bord de route afin d'améliorer la sécurité et la fiabilité [15, 16]. Pour faire face aux fluctuations du réseau, de nouvelles méthodes de fusion, telles que la "fusion inter-frames" et la "fusion de planification", viennent compléter la "fusion intra-frame" traditionnelle [16].

Dans le domaine aérospatial, les systèmes de Fusion d'Informations par Intelligence Artificielle (AIFIA) exploitent les techniques d'IA et d'apprentissage automatique (ML) pour améliorer les contrôles avioniques et la surveillance de l'état structurel [17]. Par ailleurs, les approches d'apprentissage profond, comme CentralNet, proposent une fusion multilevel des capteurs, équilibrant les stratégies de fusion précoce et tardive [18].

Ces stratégies de fusion augmentées par l'IA démontrent une grande adaptabilité et évolutivité, ainsi qu'une capacité à apprendre des modèles complexes. Elles combinent des techniques d'apprentissage profond, telles que les réseaux de neurones convolutionnels et récurrents, avec des méthodes traditionnelles, ce qui améliore les performances sur divers ensembles de données multimodales et dans des scénarios réels de conduite autonome.

Le TABLEAU 2.1 résume une synthèse des principaux défis et limitations identifiés dans les travaux récents, offrant ainsi une perspective comparative.

TABLE 2.1: Défis et limitations des stratégies de fusion actuelles

Réf.	Défi	Observations / Limitations
[19]	Calibration et synchronisation	Les imprécisions de calibration affectent négativement la performance de la fusion contextuelle.
[20]	Latence dans la fusion coopérative	Les délais de communication compromettent la perception en temps réel.
[21]	Conditions météorologiques défavorables	La perception environnementale se détériore en cas de pluie et de brouillard.
[22]	Complexité computationnelle	Les stratégies de fusion basées sur l'apprentissage profond sont coûteuses en calcul.
[23]	Passage à l'échelle	Les cadres de fusion ont du mal à gérer des environnements dynamiques à haute densité.
[24]	Gestion des pannes de capteurs	Faible généralisation face à divers scénarios de défaillance.
[25]	Standardisation	Absence de cadres normatifs unifiés pour la fusion des données.
[26]	Bruit et valeurs aberrantes	Les techniques de filtrage robustes augmentent la charge de traitement.

Malgré ces défis, la recherche continue de progresser en développant de nouveaux algorithmes, des architectures plus avancées et des cadres robustes, préparant ainsi l'arrivée de la prochaine génération de systèmes autonomes.

2.3 Conclusion

Dans ce chapitre, nous avons étudié les principales méthodes de fusion de données pour les véhicules autonomes, réparties en quatre types : statiques, adaptatives, contextuelles et basées sur l'IA. Cette analyse a permis de souligner leurs atouts, leurs limites, ainsi que les défis liés à l'incertitude des capteurs. Le chapitre suivant présentera la théorie de l'évidence, une approche mathématique conçue pour mieux modéliser l'incertitude et renforcer la fiabilité des décisions.

Chapitre 3

Théorie de L'évidence

Chapitre 3

Théorie de L'évidence

Introduction

L'intégration des théories de l'incertain est essentielle pour améliorer la fiabilité et la sécurité des véhicules autonomes. En combinant différentes approches, ces systèmes peuvent mieux appréhender leur environnement, prendre des décisions robustes et gérer les situations ambiguës de manière plus efficace. Ce chapitre consiste à présenter la théorie de l'évidence, et son impact dans sur la fusion des données de perception.

3.1 Théories de l'incertitude dans la gestion des situations incertaines

Les théories de l'incertitude jouent un rôle clé dans la gestion des situations imprévisibles en facilitant la prise de décision face à des informations partielles ou ambiguës. Elles permettent d'anticiper les risques, d'élaborer des stratégies flexibles et d'analyser les comportements humains face à l'aléatoire. En gestion, elles constituent un levier essentiel pour concevoir des approches adaptatives et optimiser la prise de décision dans des environnements complexes et dynamiques.

Les véhicules autonomes évoluent dans des environnements complexes et dynamiques où l'incertitude est omniprésente. Cette incertitude peut provenir de plusieurs sources, notamment :

- Les capteurs, dont les mesures sont souvent bruitées ou incomplètes.
- L'environnement dynamique, incluant les comportements imprévisibles des piétons et des autres véhicules.
- L'interprétation des données, qui peut être sujette à des erreurs en raison des limites des algorithmes de perception et de fusion de données.

Pour faire face à ces défis, plusieurs théories de l'incertain sont utilisées dans le traitement des problèmes en véhicules autonomes :

- Théorie des probabilités Elle est couramment utilisée pour modéliser l'incertitude en prenant en compte des distributions de probabilité sur les états possibles [27]. Les algorithmes comme les filtres de Kalman ou les filtres particuliers permettent d'estimer l'état du véhicule et de son environnement avec un certain degré de confiance.
- Théorie des ensembles flous qui permettent de gérer l'incertitude liée à l'imprécision des données. Contrairement à la logique classique binaire, cette

approche permet de représenter des degrés d'appartenance aux différentes classes d'objets détectés, améliorant ainsi la prise de décision en cas de doute [28, 29].

- Théorie des possibilités Alternative aux probabilités classiques, elle est particulièrement adaptée aux contextes où les données disponibles ne permettent pas de définir des distributions probabilistes précises. Elle s'avère efficace pour traiter les perceptions ambiguës et fusionner des informations issues de capteurs hétérogènes [30].
- Théorie de Dempster-Shafer qui permet d'agrèger plusieurs sources d'informations en attribuant des masses de croyance aux différentes hypothèses possibles. Elle est particulièrement performante dans le cadre de la fusion de données issues de capteurs multiples, améliorant ainsi la fiabilité des décisions prises en environnement incertain [31].
- Réseaux Bayésiens Les réseaux bayésiens modélisent les relations de causalité entre différentes variables tout en intégrant les incertitudes associées. Leur capacité d'inférence probabiliste en fait un outil clé dans les systèmes de perception et de prise de décision, notamment pour les véhicules autonomes et l'intelligence artificielle.
- Apprentissage automatique et gestion de l'incertitude L'apprentissage automatique, notamment les approches en apprentissage profond, intègre des mécanismes avancés pour la gestion de l'incertitude. Les modèles bayésiens profonds et les méthodes probabilistes en apprentissage par renforcement permettent d'améliorer la robustesse des systèmes décisionnels dans des environnements dynamiques et complexes.

Ainsi, l'application des théories de l'incertitude, telles que la théorie de l'évidence, dépasse la simple modélisation des scénarios de conduite : elle optimise les algorithmes de fusion d'informations multisources, améliore la gestion des conflits entre capteurs et renforce la fiabilité des prises de décision dans des contextes dynamiques et partiellement observables. FIGURE 3.1.(a) montre la relation entre les théories de l'incertain, tandis que la relation entre les types de données incertaines est illustrée par FIGURE 3.1.(b). Plus de détails sur les relations entre ces théories est donnée par [32, 33].

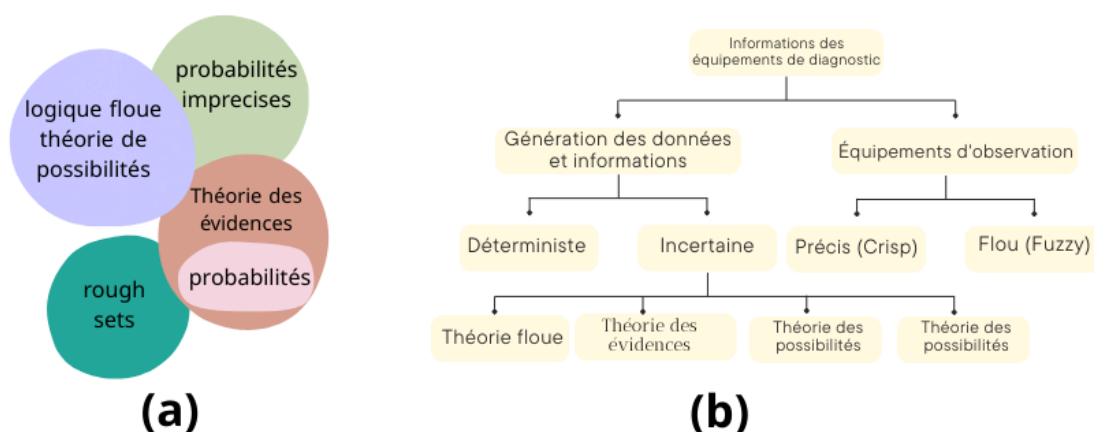


FIGURE 3.1: (a) La relation entre les Théories de l'incertain (b) Lien étroit entre les données incertaines et les théories correspondantes

3.2 Théorie de L'évidence

Le traitement de la théorie de l'évidence (ou de Dempster-Shafer) pour résoudre le problème de l'appariement de données géographiques issues de différentes bases.

Les bases de données géographiques contiennent souvent des données imprécises ou incertaines (incohérences, valeurs manquantes, données conflictuelles).

L'objectif est de fusionner ces données pour obtenir une information plus fiable. Cela nécessite un processus d'appariement (identifier des objets correspondants dans deux bases différentes).

3.2.1 Cadre de discernement :

La théorie de l'évidence (Dempster-Shafer) repose sur un cadre de discernement Ω , qui est l'ensemble des hypothèses possibles servant à résoudre un problème.

- **Univers de Décernement:** L'univers de discernement ou L'ensemble de discernement est définie par eq. (3.1).

$$\Omega = \{H_1, H_2, \dots, H_n\} \quad (3.1)$$

où :

- n est le nombre total d'hypothèses.
- Ω représente des hypothèses **exclusives** et **exhaustives**.
- Chaque H_i (où $i \in \{1, \dots, n\}$) est une hypothèse élémentaire, c'est-à-dire une possibilité de base qui ne peut être décomposée davantage dans le cadre du problème étudié.
- Toutes les parties de Ω forment le *power set* 2^Ω , soit l'ensemble de tous les sous-ensembles de Ω .
- Chaque sous-ensemble dans 2^Ω représente une *proposition disjonctive* (union de plusieurs hypothèses).

Exemple :

Considérons $\Omega = H_1, H_2$, l'ensemble des hypothèses H_1 et H_2 . Le nombre total de sous-ensembles de Ω est donné par eq. 3.2:

$$2^\Omega = \{\emptyset, \{H_1\}, \{H_2\}, \{H_1, H_2\}\} \quad (3.2)$$

3.2.2 Fonction de croyance et de plausibilité :

Dans le cadre de la théorie des fonctions de croyance, une décision pertinente repose sur l'utilisation de la fonction de croyance et de la fonction de plausibilité.

- **Fonction de croyance :** La fonction de croyance (notée $Cr(A)$ ou $Bel(A)$) permet d'attribuer un degré de croyance (entre 0 et 1) à une hypothèse A dans un cadre de discernement (Ω). Elle est dérivée des fonctions de masse et reflète toutes les raisons soutenant directement A .

La croyance ($Bel(A)$) est calculée par la somme des probabilités associées aux propositions (B) strictement incluses dans (A) (eq. 3.3):

$$Bel(A) = Cr(A) = \sum_{B_i \subseteq A} m(B_i) \quad (3.3)$$

Propriétés fondamentales :

- $Cr(\emptyset) = 0$: aucune croyance pour l'ensemble vide.
- $Cr(\Omega) = 1$: certitude totale dans Ω .
- $Cr(A \cup B) = Cr(A) + Cr(B)$ si $A \cap B = \emptyset$.

Explication :

- $Bel(A)$ représente la borne inférieure de la vraisemblance.
 - Une fonction de croyance nulle $Cr = Bel = 0$ indique une ignorance totale sur l'hypothèse A .
- **Fonction de plausibilité :** La **plausibilité (PI)** mesure le degré maximal de vraisemblance d'une hypothèse A . Elle correspond à la somme des probabilités des ensembles (B) qui ont une intersection non nulle avec A ($B \cap A \neq \emptyset$). Formellement, elle est définie par eq. 3.4:

$$Pl(A) = \sum_{A \cap B_i \neq \emptyset} m(B_i) \quad (3.4)$$

Relations et interprétations :

La plausibilité (eq. 3.5) peut être calculée à partir de :

- La fonction de masse m , comme dans la définition de Dempster.
- La fonction de croyance de l'événement complémentaire A^c :

$$Pl(A) = 1 - Cr(A^c) \quad (3.5)$$

Le couple (Cr, Pl) représente :

- $Cr(A)$: la probabilité minimale de l'hypothèse A (croyance).
- $Pl(A)$: la probabilité maximale de l'hypothèse A (plausibilité).

- **Initialisation des masses :**

Dans la théorie de Dempster-Shafer (TDS), l'attribution des masses de croyances initiales est une étape critique réalisée par un expert. Elle consiste à assigner des degrés de croyance (masses) à chaque hypothèse en vue d'une prise de décision optimale. Une mauvaise initialisation peut entraîner des décisions erronées ou des conflits.

Méthodes pour déterminer les masses

Plusieurs méthodes peuvent être utilisées pour déterminer ces masses, notamment :

- Les fonctions de vraisemblance construites à partir d'ensembles de données d'apprentissage, comme celles basées sur des distributions gaussiennes [31].
- Les mesures de distance (euclidienne, toponymique, sémantique, etc.) utilisées dans l'algorithme des K -plus proches voisins.

- Les représentations floues pour modéliser les incertitudes [34, 35, 36, 27].

Ces approches permettent de guider efficacement l'initialisation des masses dans des contextes variés.

3.2.3 Combinaison d'information avec la TDS :

La combinaison d'informations provenant de sources distinctes est essentielle pour prendre des décisions éclairées. Pour ce faire, plusieurs règles de combinaison sont utilisées, notamment :

- **Règle de combinaison de Dempster :**

La règle de combinaison de Dempster est la méthode la plus courante. Elle combine les sources d'informations en utilisant l'opérateur de conjonction de Dempster, symbolisé par \oplus . Cette méthode permet de fusionner deux sources d'informations en fonction de leurs jeux de masses respectifs, exprimant des degrés de confiance sur un ensemble d'hypothèses [37].

- **Méthodes alternatives :**

La théorie de l'évidence fait appel à divers opérateurs de combinaison documentés dans la littérature, notamment :

- Méthode de Yager [38], qui propose un opérateur de combinaison différent.
- Méthode de Dubois et Prade [39], basée sur des opérateurs disjonctifs.
- Méthode d'Inagaki [40].
- Méthode de Smets basée sur la Théorie des ensembles de Dempster (TDS) en monde ouvert[41].
- Un opérateur de Combinaison Matricielle de Boualem, Dahmani et Maatoug [42]

- **Combinaison des sources d'informations :**

La combinaison de deux sources d'informations, notées A_1 et A_2 , s'effectue en multipliant les masses associées à leurs intersections (FIGURE 3.2). Si ces sources sont disjointes, leur intersection est vide et un facteur de normalisation, λ_c , est utilisé pour ajuster le résultat (eq. 3.6).

$$m_1 \oplus m_2(A) = \begin{cases} 0 & \text{si } A = \emptyset, \\ \frac{\sum_{A_1 \cap A_2 = A} m_1(A_1) \times m_2(A_2)}{1 - \lambda_c} & \text{si } A \neq \emptyset, \end{cases} \quad (3.6)$$

où $\lambda_c = \sum_{A_1 \cap A_2 = \emptyset} m_1(A_1) \times m_2(A_2)$ représente le conflit entre les sources, appelé aussi ignorance, et il est utilisé comme facteur de normalisation.

Remarque Nous avons utilisé la normalisation avec le facteur d'ignorance k plutôt qu'une normalisation à l'unité, étant donné que, malgré la diversité des opérateurs de combinaison disponibles, le résultat décisionnel demeure inchangé.

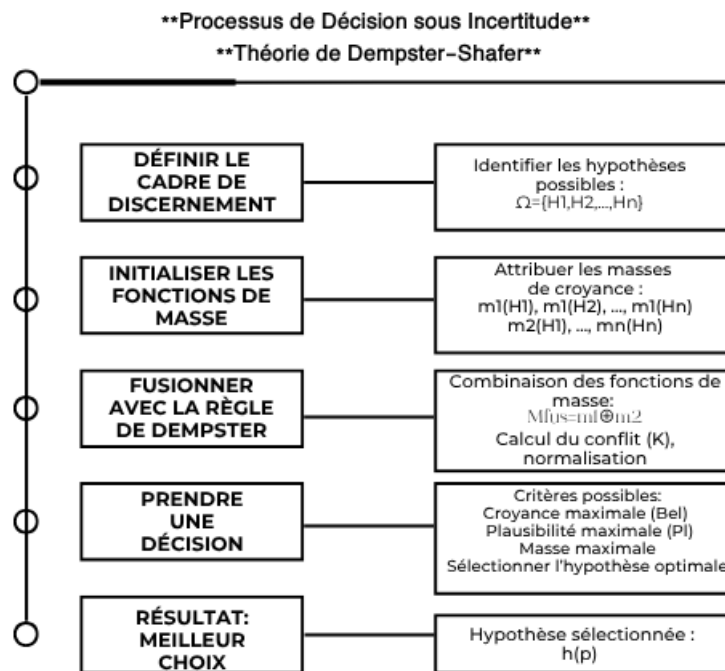


FIGURE 3.2: Processus de Décision à base de Théorie de Dempster-Shafer [1].

3.2.4 Prise de décision par la TDS :

La prise de décision dans la théorie des systèmes de croyance (TDS) repose sur des critères différents de ceux utilisés dans le cadre bayésien, où la règle principale est le maximum a posteriori (MAP). En TDS, deux grandeurs sont disponibles : la **crédibilité** et la **plausibilité**. Plusieurs règles de décision sont proposées, notamment :

- Décision avec le Maximum de plausibilité (eq. 3.7),

$$Pl(A) = \sum_{A \cap B_i \neq \emptyset} m(B_i) \quad (3.7)$$

- Décision avec le Maximum de crédibilité (eq. 3.8)

$$Cr(A) = \sum_{A \in B} m(B) \quad (3.8)$$

- Règles basées sur l'intervalle de confiance (Voir la section "l'intervalle de Confiance"),
- Probabilité pignistique : La règle du maximum de crédibilité est généralement considérée comme prudente, mais elle tend à sous-estimer l'incertitude. À l'inverse, la règle du maximum de plausibilité peut s'avérer trop risquée. L'idéal est donc de choisir une solution intermédiaire, située entre crédibilité et plausibilité. Cependant, le choix de la règle de décision reste dépendant du contexte et des spécificités du problème étudié.

La probabilité pignistique constitue justement une mesure subjective intermédiaire entre crédibilité et plausibilité. Elle est définie par la relation suivante (équation 3.9) :

$$P(A) = \sum_{X \in 2^\Omega} \frac{|X \cap A|}{|X|} m(X) \quad (3.9)$$

Où $|X|$ représente le nombre d'hypothèses formant la proposition X , et $m(X)$ est la fonction de masse de la proposition X .

3.2.5 Exemple de Déroulement de Théorie de L'évidence

Problème: Supposons qu'un véhicule autonome rencontre un objet à une distance de 10 mètres. La fusion d'informations est effectuée en utilisant la règle de combinaison de Dempster-Shafer avec les fonctions de masse fournies par trois sources d'information; la Caméra, le Radar et le Lidar pour les hypothèses suivantes: $\{Camera(C), Lيدر(L), Radar(R)\}$.

- **Étape 1** (Sélection du cadre de discernement) : $\Omega = \{V, P, O, N\}$

avec : Véhicule = V, Piéton = P, Objet immobile = O, et Aucune détection = N.

Remarque: nous avons pris que l'hypothèse que "Aucune détection" représente l'ignorance dans notre cas d'étude.

- **Étape 2** (Attribution des fonctions de masse) : **Caméra** : Les données sont imprécises en raison du brouillard, mais elles suggèrent la présence possible d'un piéton avec une fonction de croyance de 0.2, d'un véhicule avec 0.55, d'un objet immobile avec 0, aucune détection avec 0.05 et et pour véhicule et piéton à la fois est 0.2. L'initialisation des masses est définie par eq. 3.10.

$$m_C : \begin{cases} m(V) = 0.55 \\ m(P) = 0.2 \\ m(V \cup P) = 0.2 \\ m(N) = 0.05 \end{cases} \quad (3.10)$$

Radar : Le radar détecte un grand objet et assigne une fonction de croyance de 0.64 pour un véhicule, 0 pour un piéton, 0.13 pour un objet immobile, Véhicule et piéton et objet à la fois est 0.18, et aucune détection avec 0.05. L'initialisation des masses est définie par eq. 3.11.

$$m_R : \begin{cases} m(V) = 0.64 \\ m(O) = 0.13 \\ m(V \cup P \cup O) = 0.18 \\ m(N) = 0.05 \end{cases} \quad (3.11)$$

Lidar : Le lidar est incertain en raison de la pluie, mais il détecte un obstacle immobile avec une fonction de croyance de 0.35, un véhicule avec 0, et un piéton avec 0.35, aucune détection avec 0.10, et la croyance de détecter un véhicule et piéton à la fois est 0.2. L'initialisation des masses est définie par eq. 3.12).

$$m_L : \begin{cases} m(P) = 0.35 \\ m(O) = 0.35 \\ m(V \cup P \cup O) = 0.2 \\ m(N) = 0.10 \end{cases} \quad (3.12)$$

- **Étape 3** (Fusion des masses des Caméra, Lider et Radar): On applique la règle de Dempster entre m_C et m_R , on obtient:

Calcul du facteur de conflit K : Le facteur de conflit est définie par eq. 3.13.

$$K = \sum_{X \cap Y = \emptyset} m_1(X) \cdot m_2(Y) \quad (3.13)$$

Dans notre cas, K est définie par eq. 3.14:

$$K = \begin{cases} m_C(V) \cdot m_R(O) + m_C(V) \cdot m_R(N) + \\ m_C(P) \cdot m_R(V) + m_C(P) \cdot m_R(O) + m_C(P) \cdot m_R(N) + \\ m_C(V \cup P) \cdot m_R(O) + m_C(V \cup P) \cdot m_R(N) + \\ m_C(N) \cdot m_R(V) + m_C(N) \cdot m_R(O) + m_C(N) \cdot m_R(V \cup P \cup O) \end{cases} \quad (3.14)$$

$$K = \begin{cases} (0.55 \cdot 0.13) + (0.55 \cdot 0.05) + \\ (0.2 \cdot 0.64) + (0.02 \cdot 0.13) + (0.2 \cdot 0.05) + \\ (0.2 \cdot 0.13) + (0.2 \cdot 0.05) + \\ (0.05 \cdot 0.64) + (0.05 \cdot 0.13) + (0.05 \cdot 0.18) \end{cases} \quad (3.15)$$

$$K = \begin{cases} 0.0715 + 0.0275 + 0.128 + 0.026 + 0.01 + \\ 0.026 + 0.01 + 0.032 + 0.0065 + 0.009 = 0.3465 \end{cases} \quad (3.16)$$

La combinaison est réalisée en 2 parties :

– **Partie 1 : Fusion de la Caméra et du Radar**

En appliquant la règle de Dempster 3.17 :

$$K_{CR} = \sum_{A \cap B = \emptyset} m_C(A) \cdot m_R(B). \quad (3.17)$$

Les fonctions de masse combinées deviennent (eq. 3.18):

$$m_{CR} : \begin{cases} m_{CR}(V) = 0.55 \cdot 0.64 + 0.55 \cdot 0.18 + 0.2 \cdot 0.64 = 0.579, \\ m_{CR}(P) = 0.2 \cdot 0.18 = 0.036, \\ m_{CR}(V \cup P) = 0.2 \cdot 0.18 = 0.036, \\ m_{CR}(N) = 0.05 \cdot 0.05 = 0.0025 \end{cases} \quad (3.18)$$

Après normalisation, les fonctions de masse combinées deviennent (eq. 3.19):

$$m_{CR} : \begin{cases} m_{CR}(V) = 0.579 / (1 - 0.3465) = 0.886, \\ m_{CR}(P) = 0.036 / (1 - 0.3465) = 0.055, \\ m_{CR}(V \cup P) = 0.036 / (1 - 0.3465) = 0.055, \\ m_{CR}(N) = 0.0025 / (1 - 0.3465) = 0.004 \end{cases} \quad (3.19)$$

– **Partie 2 : Fusion de m_{CR} avec le Lidar**

En appliquant la règle de combinaison :

$$K_{CRL} = \sum_{A \cap B = \emptyset} m_{CR}(A) \cdot m_L(B). \quad (3.20)$$

- **Résultat de fusion:** Après la fusion, les fonctions de masse finales fusionnées sont :

$$m_{CRL} : \begin{cases} m_{CRL}(V) = 0.1772, \\ m_{CRL}(P) = 0.0495, \\ m_{CRL}(V \cup P) = 0.011, \\ m_{CRL}(N) = 0.0004 \end{cases} \quad (3.21)$$

Avec $K = 0.7619$

Étape 4 (Normalisation) Après la combinaison de toutes les sources, on normalise les valeurs pour que leur somme soit égale à 1.

Après normalisation, les fonctions de masse finaux fusionnées sont :

$$m_{CRL} : \begin{cases} m_{CRL}(V) = 0.1772 / (1 - 0.7619) = 0.744 \\ m_{CRL}(P) = 0.0495 / (1 - 0.7619) = 0.208 \\ m_{CRL}(V \cup P) = 0.011 / (1 - 0.7619) = 0.046 \\ m_{CRL}(N) = 0.0004 / (1 - 0.7619) = 0.002 \end{cases} \quad (3.22)$$

Étape 5: (Prise de décision) La décision finale est prise en sélectionnant l'hypothèse avec:

- Décision par Fonction de Croyance (eq. 3.8): Puisque $Cr(A) = 0.744 > 0.208 > 0.046 > 0.002$, donc l'objet détecté est "véhicule".
- Décision par Fonction de Plausibilité

La fonction de plausibilité est définie par eq. 3.23.

$$Pl(A) = 1 - Bel(\neg A) \quad (3.23)$$

Dans notre cas, les résultats suivants ont été obtenus (eq.3.24 et eq.3.25) :

$$Bel(\neg V) = m(P) + m(N) = 0.208 + 0.002 = 0.21 \quad (3.24)$$

Donc :

$$Pl(V) = 1 - 0.21 = 0.79 \quad (3.25)$$

Donc, la plausibilité de l'hypothèse **véhicule** est **0.79**.

- Décision par Probabilité Pignistic

$$P(V) = \sum_{X \in 2^\Omega} \frac{|X \cap V|}{|X|} m(X) \quad (3.26)$$

Dans notre cas, nous trouvons (eq. 3.27):

$$P(V) \begin{cases} = m(V) + \frac{1}{2} \cdot m(V \cup P) \\ = 0.744 + 0.023 \\ = 0.767 \end{cases} \quad (3.27)$$

Donc, la probabilité de l'hypothèse **véhicule** est **0.767**.

- Décision par Intervalle de Confiance L'intervalle de confiance n'est pas défini comme dans la statistique classique (où l'on utilise des distributions de probabilité). À la place, on définit un intervalle de croyance, qui est déterminé par les fonctions de croyance (Bel) et de plausibilité (Pl). Il est donnée par eq. 3.28:

$$IC = [Cr, Pl] \quad (3.28)$$

Où :

Pl (fonction de croyance) représente le degré minimal de support en faveur de A , c'est-à-dire la somme des masses de croyance qui soutiennent entièrement A . $Pl(A)$ (fonction de plausibilité) représente le degré maximal auquel A peut être vrai, c'est-à-dire la somme des masses qui ne contredisent pas A . Ainsi, l'intervalle définie par eq. 3.28 encadre la probabilité réelle de A , mais sans la connaître exactement.

Remarque:

- * Si l'intervalle est étroit ($IC \approx Pl(A)$), cela signifie que l'incertitude est faible et que notre confiance en A est élevée.
- * Si l'intervalle est large, cela indique une forte incertitude sur A , ce qui reflète un manque d'information ou des sources conflictuelles.

Alors, dans cet exemple est donnée par eq. 3.29:

$$IC = [0.744, 0.79] \quad (3.29)$$

L'objet détecté est "Véhicule", car la probabilité réelle d'identification du véhicule se situe entre 74% et 79%.

3.3 Conclusion

Dans ce chapitre, nous avons approfondi la théorie de l'évidence, un cadre formel issu des mathématiques probabilistes permettant de gérer l'incertitude et l'imperfection des informations. Cette théorie repose sur les fonctions de croyance, qui modélisent la confiance accordée à une hypothèse en intégrant des degrés de plausibilité et de fiabilité. En s'appuyant sur les masses d'évidence et des règles de combinaison, elle permet un traitement rigoureux et cohérent des données incertaines, facilitant ainsi la prise de décision dans des environnements complexes. Le chapitre suivant introduira notre approche basée sur la théorie de l'évidence. Nous y exposerons en détail la méthodologie employée, la conception du modèle et les étapes de sa modélisation. Enfin, nous concluons par une analyse approfondie des simulations réalisées et des résultats obtenus.

Chapitre 4

Méthodologie & Réalisation et

Analyse de Résultats

Chapitre 4

Méthodologie & Réalisation et Analyse de Résultats

Introduction

Dans ce chapitre, nous présentons la méthodologie adoptée, suivie d'une conception simplifiée et d'une description de notre application. Enfin, nous concluons par une analyse des résultats obtenus et un résumé des principaux éléments abordés.

4.1 Méthodologie

4.1.1 Choix du langage de programmation

PyCharm est un IDE qui s'intègre à IPython Notebook, dispose d'une console Python interactive et prend en charge Anaconda ainsi que plusieurs packages scientifiques. PyCharm permet également de créer des environnements virtuels pour Python avec Anaconda.

Nous avons utilisé Anaconda avec le langage Python comme environnement de développement, et PyCharm Community Edition 2024.2.4 comme éditeur de code source pour implémenter et évaluer notre modèle (FIGURE 4.1).



FIGURE 4.1: PyCharm Community Edition 2024.2.4.

C'est un Editeur de Développement intégré (IDE) performant, capable de gérer efficacement plusieurs fichiers Python, des fichiers de données multiples, différentes versions du projet, ainsi que des fonctionnalités avancées de débogage et d'organisation du code.

Parmi les nombreux IDE disponibles pour le langage Python, notre choix s'est porté sur PyCharm Community Edition. Cette version gratuite, bien que plus légère que la version professionnelle, offre une large gamme de fonctionnalités essentielles telles que :

- La gestion de projets multi-fichiers,
- L'intégration Git,

- La gestion des environnements virtuels,
- et une interface conviviale.

Ces caractéristiques en font un outil robuste et adapté au contexte d'un projet de notre PFE.

4.1.2 Approche de fusion multi-capteurs à base de TDS

Notre approche méthodologique s'appuie sur une architecture multi-capteurs intégrée au véhicule autonome, combinant les données issues de trois technologies complémentaires :

- Caméras pour la reconnaissance visuelle
- Radars pour la détection à moyenne portée
- Lidar pour la cartographie précise de l'environnement

Pour exploiter au mieux ces données hétérogènes, nous avons implémenté la théorie de Dempster-Shafer, un cadre mathématique particulièrement adapté pour :

- Représenter les incertitudes de mesure
- Fusionner les croyances probabilistes
- Détecter les conflits entre capteurs
- Classifier les objets (véhicules, piétons, obstacles fixes)

4.1.3 Conception de notre approche

Notre approche de fusion de données basée sur la théorie de l'évidence (DST) a été conçue selon une méthodologie rigoureuse, illustrée par les diagrammes suivants : Le diagramme de classes (FIGURE 4.2) présente les principales entités de notre système :

- **SensorModule** : Classe abstraite représentant les différents capteurs (Camera, Radar, Lidar)
- **EvidenceProcessor** : Gère le calcul des fonctions de masse
- **DataFusion** : Implémente les règles de combinaison (Dempster-Shafer)
- **DecisionModule** : Prend la décision finale basée sur les croyances fusionnées

Le diagramme d'activités (FIGURE 4.3) illustre le cycle complet de fonctionnement du système de fusion DST, depuis la saisie des données jusqu'à l'affichage des résultats, en passant par le traitement. Il met en évidence un flux de traitement cohérent ainsi qu'une interaction fluide entre l'utilisateur et le système. Ce diagramme représente les tâches suivantes :

1. L'acquisition des données des différents capteurs,
2. Le prétraitement et extraction des caractéristiques,

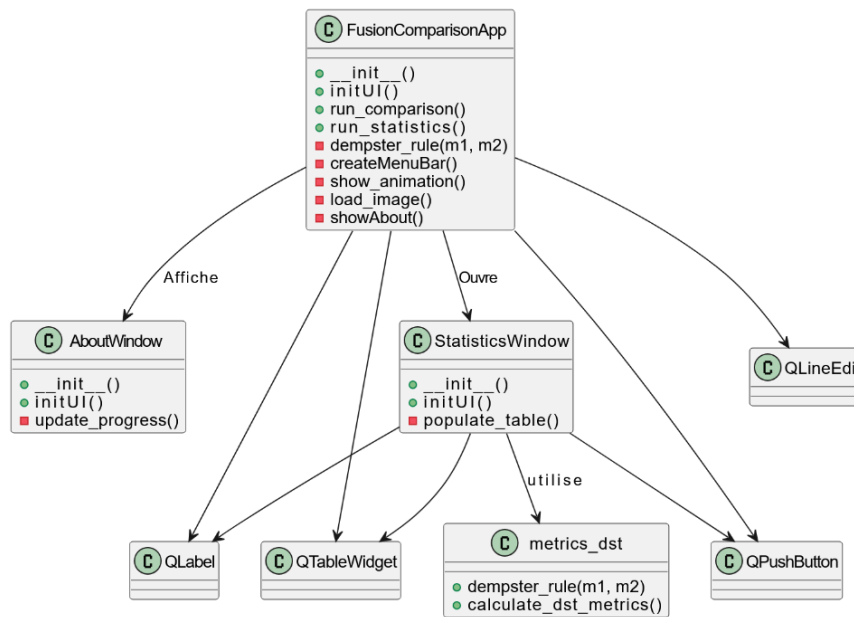


FIGURE 4.2: Diagramme de classes de l'architecture proposée.

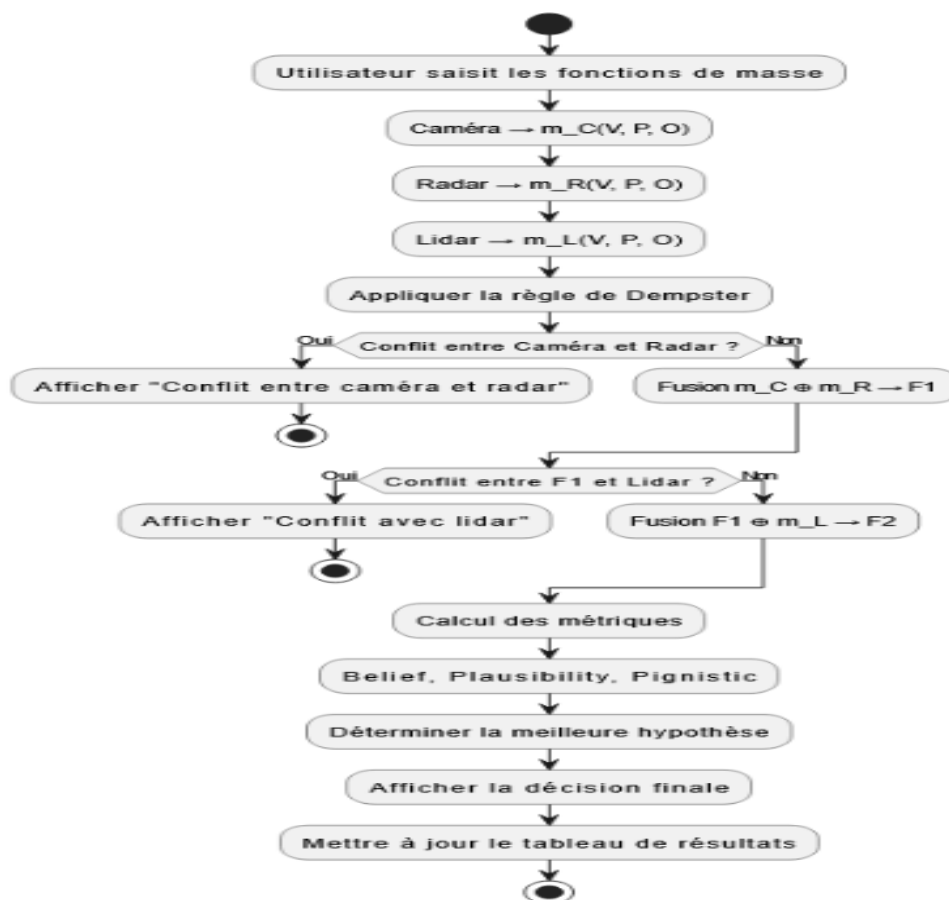


FIGURE 4.3: Diagramme d'activités du processus de fusion.

3. Le calcul des fonctions de masse pour chaque source,
4. La combinaison des évidences selon les règles DST,
5. et la normalisation et prise de décision.

Notre conception intègre trois niveaux de traitement :

Niveau bas niveau : Traitement sensoriel spécifique (images, points cloud, etc.)

Niveau intermédiaire : Calcul des mesures d'évidence et caractéristiques

Niveau décisionnel : Fusion et interprétation des résultats

L'architecture logicielle repose sur :

- Un framework modulaire en Python 3.9.
- Utilisation intensive de NumPy pour les calculs matriciels avec PyCharm 2024.2.4 (Community Edition).
- Interface graphique développée avec PyQt5.

Cette conception permet une intégration transparente de nouveaux capteurs dans les véhicules autonomes et l'extension des règles de fusion, tout en maintenant des performances temps réel adaptées aux contraintes des véhicules autonomes.

4.2 Présentation de notre stratégie de Fusion des données de perception à base de théorie de l'évidence

La conception de notre système s'articule autour d'une architecture modulaire. Chaque capteur est traité indépendamment dans un premier temps, puis les données sont fusionnées à l'aide d'un module central. Nous avons utilisé Python avec Anaconda comme environnement de développement, et PyCharm Community Edition pour le codage. La simulation a été réalisée à l'aide de scénarios virtuels simulant des situations réelles : détection de piétons à un carrefour, véhicules en mouvement et objets statiques. Les résultats intermédiaires (positions, vitesses, classes d'objets) sont capturés et analysés à chaque étape.

FIGURE 4.4 illustre les étapes basées sur la théorie de l'évidence utilisées pour fusionner les données perçues par différentes sources d'information, notamment le Radar, le Lidar et les Caméras au niveau du véhicule autonome.

Dans le cadre du développement de notre application, nous avons adopté une hypothèse de détection singlotant, stipulant qu'à chaque instant, un seul objet est détecté — qu'il s'agisse d'un piéton, d'un véhicule ou d'un objet immobile. Cette approche repose sur une hypothèse singulière, simplifiant la modélisation et l'analyse des scénarios de détection. Pour évaluer les différentes étapes de notre modèle, nous avons développé une application dédiée, illustrée à la FIGURE 4.5. Le menu principal de cette application est illustré par FIGURE 4.6. Cette application comporte "la fusion par DSF à base manuelle", "la fusion par DSF à base de scénarios", et "L'évaluation par les métriques statistiques".

Ces étapes sont:

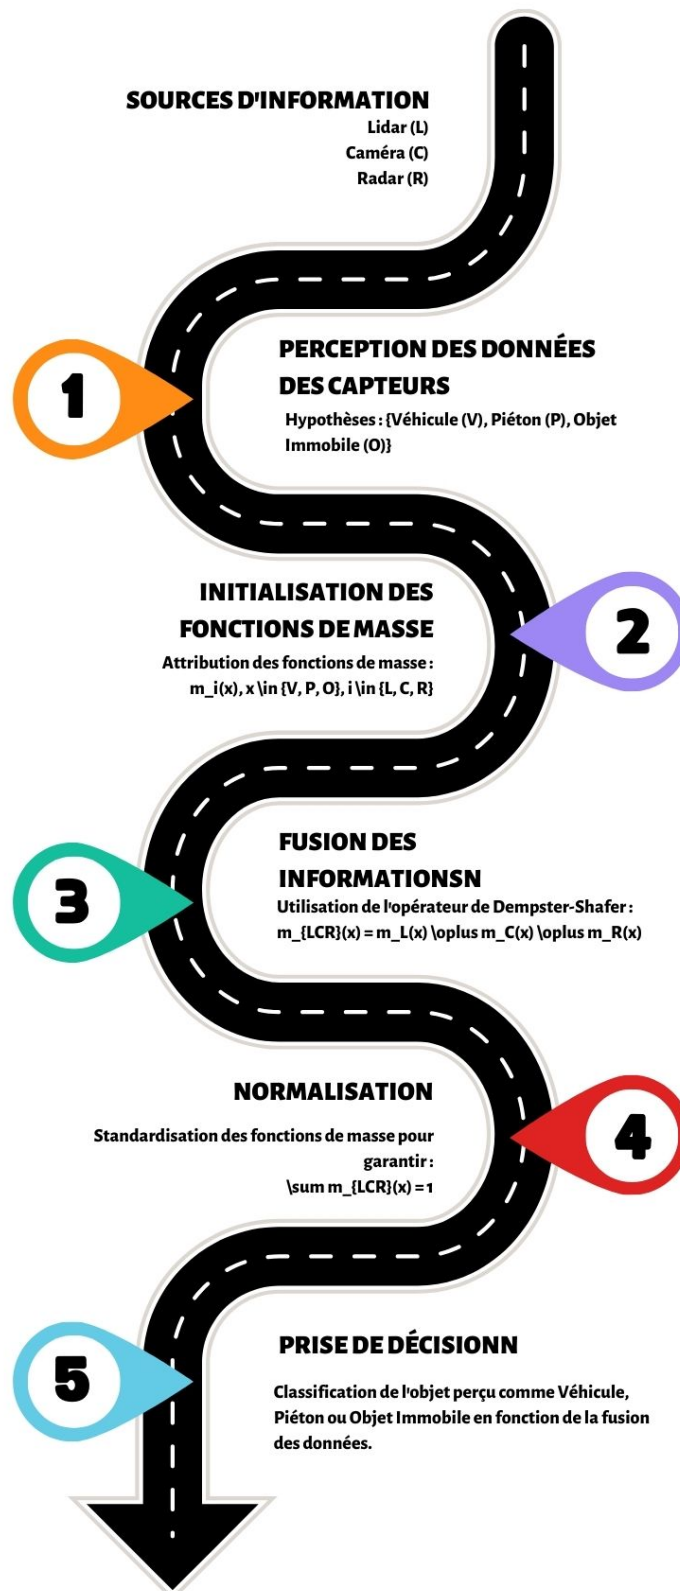


FIGURE 4.4: Notre Modèle de fusion à base Théorie de l'évidence.



FIGURE 4.5: L'interface "À propos" de l'application proposée.

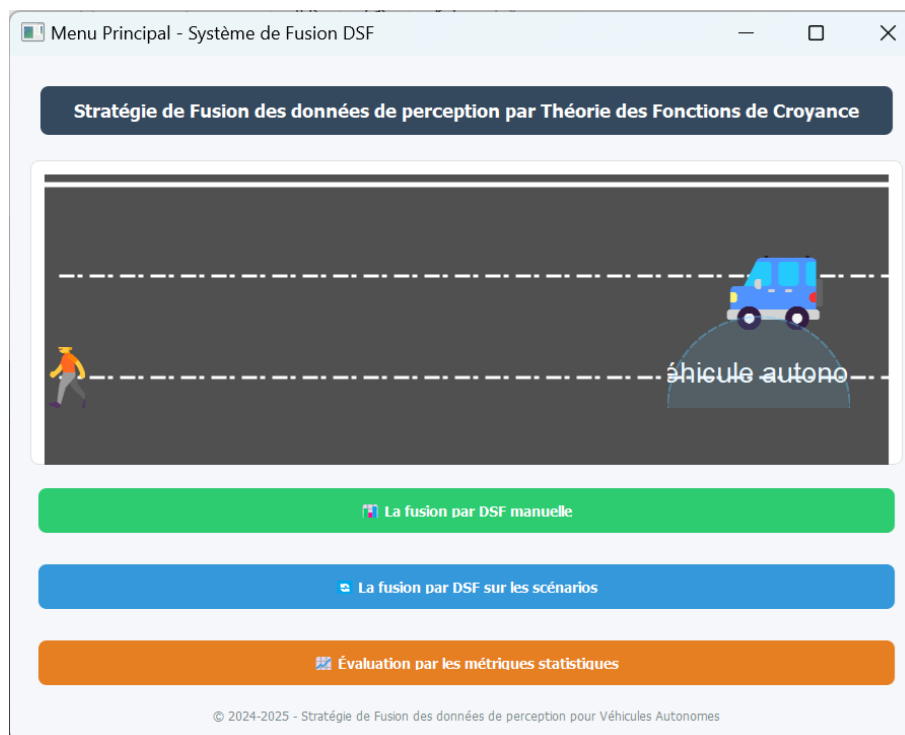


FIGURE 4.6: L'interface "Menu Principal" de l'application proposée.

- **Étape 1 (Sélection de l'univers de discernement)** : La sélection des sources d'information est une étape essentielle pour l'application de la théorie de l'évidence (FIGURE 4.4). Dans notre étude de cas, les sources considérées sont les suivantes :
 - Les caméras, installées sur les côtés du véhicule autonome,
 - Le radar, généralement positionné à l'avant du véhicule, pouvant être unique ou multiple selon les configurations, et servant à capter l'ensemble de la route,
 - Le LiDAR, monté sur le toit du véhicule, offrant une perception tridimensionnelle de l'environnement.

Notre modèle repose sur la définition des hypothèses possibles concernant les objets présents sur la route, afin de permettre la fusion des données perçues à l'aide de la théorie de l'évidence.

- **Étape 2 (Initialisation de fonctions de masse)** : FIGURE 4.7 montre l'interface de saisir les croyances selon les sources d'information Caméra, Radar et Lidar.

Nous avons supposé qu'il est possible d'attribuer des degrés de croyance aux hypothèses suivantes : « L'objet détecté est un véhicule », « L'objet détecté est un piéton », et « L'objet détecté est un obstacle immobile », en nous appuyant sur les dimensions prédéfinies propres à chaque type d'obstacle possible (FIGURE 4.7).




FIGURE 4.7: Les dimensions Imprécises des Obstacles à Détecter.

- **Étape 3 (Fusion des fonctions de masse)** : La fusion des fonctions de croyance est réalisée à l'aide de l'opérateur de Dempster-Shafer, reconnu pour son efficacité dans ce type de combinaison. Toutefois, cette méthode peut produire des fonctions de masse dont la somme dépasse 1. Dans ce cas, une étape de normalisation devient nécessaire afin de faciliter la prise de décision.
- **Étape 4 (Normalisation des fonctions de masse)** :
- **Étape 5 (Prise de Décision)** : après une fusion soit cas par cas (un seul scénario) ou la fusion des 2000 scénarios, la décision pertinente est réalisée (FIGURE 4.10).

La figure ci-dessus (FIGURE 4.11) présente les métriques d'évaluation obtenues après l'application de la méthode de fusion basée sur la théorie de Dempster-Shafer. On observe une exactitude de 78,86%, une précision de

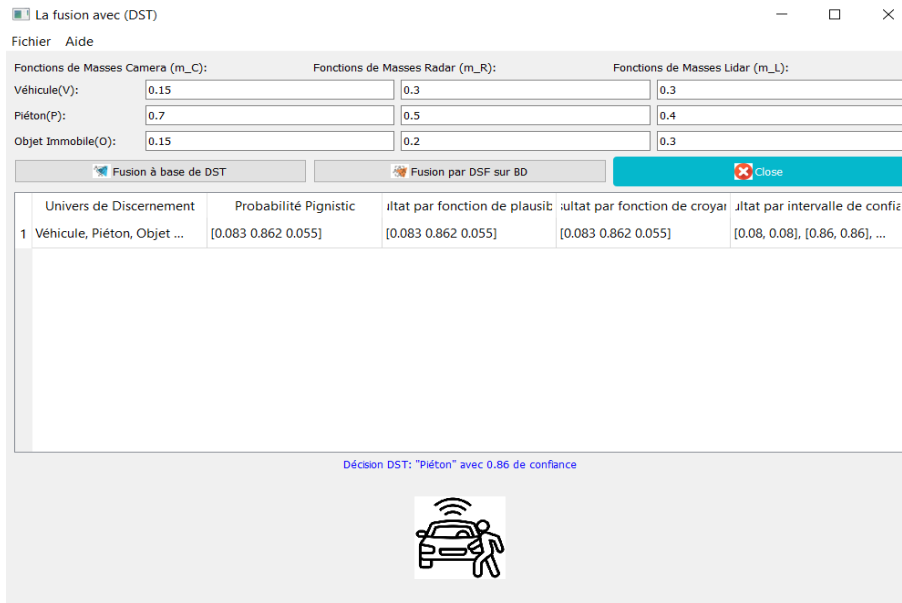


FIGURE 4.8: L'objet Détecté est Piéton.

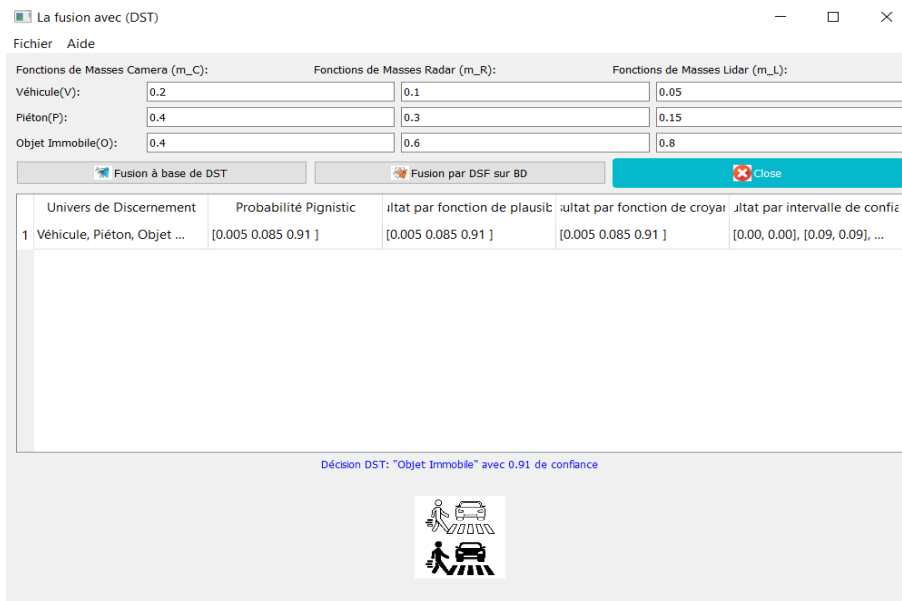


FIGURE 4.9: L'objet Détecté est Objet Immobilé.

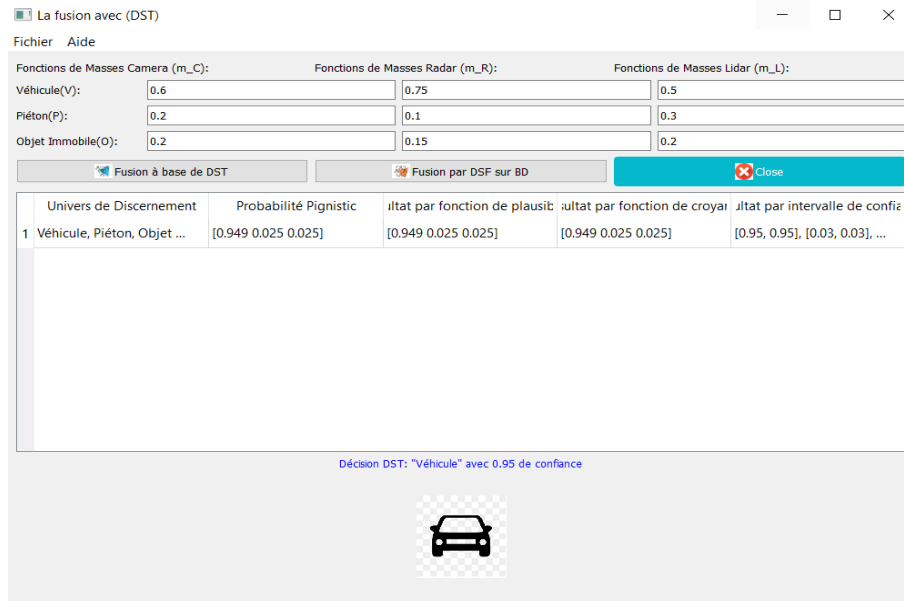


FIGURE 4.10: L'objet détecté est Véhicule.

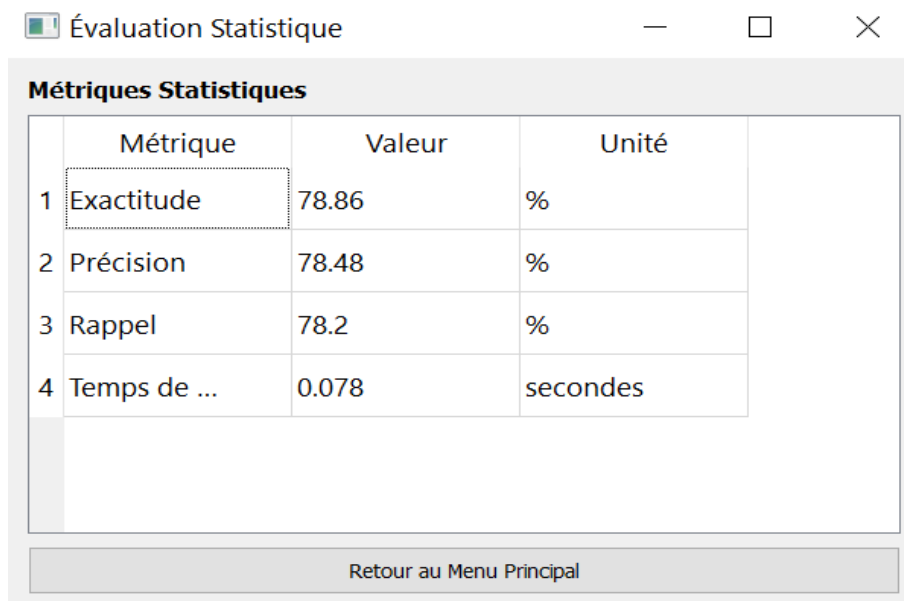


FIGURE 4.11: Résultats d'évaluation statistique du système de fusion

78,48% et un rappel de 78,2%, ce qui démontre une performance équilibrée du système. De plus, le temps de traitement moyen est très faible, de l'ordre de 0,078 seconde, ce qui le rend adapté à une utilisation en temps réel dans le contexte des véhicules autonomes.

4.3 Evaluation de notre Stratégie

Nous avons évalué notre approche sur une base de données comprenant 2000 scénarios (voir FIGURE 4.12), dans laquelle la colonne "Reference" indique la décision validée par un expert. Cette base est constituée des attributs suivants : Id, CVehicle, CPedestrian, CObjectStataire, LVehicle, LPedestrian, LObjectStataire, RVehicle, RPedestrian, RObjectStataire, et Reference. Chaque valeur attribuée à ces paramètres représente le degré de croyance exprimé par des experts, compris entre 0 et 1, concernant la détection des éléments par le véhicule autonome.

L'évaluation consiste à comparer les résultats trouvés par l'application de Théorie de Dempster-Shafer avec les valeurs de l'espèrt utilisant les métriques de statistique: Précision, Rappel, Efficacité et pourcentage de similarité (eq. 4.1, eq.4.2 et eq.4.3). Ces métriques sont calculées comme suit :

$$Precision = \frac{Vrai\ Prositif}{Vrai\ Prositif + Faux\ Prositif} \tag{4.1}$$

$$Rappel = \frac{Vrai\ Prositif}{Vrai\ Prositif + Faux\ Negatif} \tag{4.2}$$

$$Efficacite = \frac{Vrai\ Prositif + Vrai\ Negatif}{Vrai\ Prositif + Vrai\ Negatif + Faux\ Positif + Faux\ Negatif} \tag{4.3}$$

datacorrected2000Rowsupdated											
	Id	CVehicle	CPedestrian	CObjectSta...	LVehicle	LPedestrian	LObjectSta...	RVehicle	RPedestrian	RObjectSta...	Reference
	Number	Number	Number	Number	Number	Number	Number	Number	Number	Number	Categorical
1	Id	CVehicle	CPedestrian	CObjectSta...	LVehicle	LPedestrian	LObjectSta...	RVehicle	RPedestrian	RObjectSta...	Reference
2	1	0.81472368...	0.74486785...	0.42706234...	0.23225475...	0.67912166...	0.15381413...	0.58122966...	0.34301568...	0.97160313...	Pedestrian
3	2	0.90579193...	0.89226718...	0.95537210...	0.73983222...	0.48550273...	0.96179491...	0.07060392...	0.89484293...	0.58112392...	Object Stat...
4	3	0.12698681...	0.24260338...	0.72424703...	0.88899234...	0.03471835...	0.87625467...	0.37424631...	0.50416004...	0.96838641...	Object Stat...
5	4	0.91337585...	0.12959697...	0.58089171...	0.85980762...	0.11443962...	0.48862927...	0.03358962...	0.56222343...	0.04143837...	Vehicle
6	5	0.63235924...	0.22506788...	0.54025790...	0.59706078...	0.07662511...	0.40707653...	0.40614308...	0.78934454...	0.18862822...	Vehicle
7	6	0.09754040...	0.35001391...	0.70544119...	0.65475214...	0.60782467...	0.12657631...	0.65795811...	0.35092831...	0.51976005...	Vehicle
8	7	0.27849821...	0.28708461...	0.00502888...	0.91501399...	0.23346585...	0.92542528...	0.57524054...	0.22018002...	0.64085391...	Vehicle
9	8	0.54688151...	0.92748800...	0.78251577...	0.43318308...	0.14201144...	0.00558112...	0.97595623...	0.82283218...	0.34073132...	Vehicle
10	9	0.95750683...	0.05131375...	0.92685957...	0.28976075...	0.53017319...	0.18638840...	0.44163933...	0.07604194...	0.64832981...	Object Stat...
11	10	0.96488853...	0.59266675...	0.00829565...	0.63188230...	0.93030133...	0.32406103...	0.77783697...	0.08218567...	0.35543796...	Vehicle
12	11	0.15761308...	0.16289890...	0.82462834...	0.29542183...	0.61690277...	0.05018660...	0.56945842...	0.30971615...	0.85043002...	Object Stat...
13	12	0.97059278...	0.83840576...	0.76733586...	0.62202879...	0.68989191...	0.14453685...	0.02109978...	0.85549558...	0.54280468...	Pedestrian
14	13	0.95716694...	0.16756093...	0.99713689...	0.04753419...	0.23442586...	0.72936943...	0.51227355...	0.47429733...	0.67308008...	Object Stat...
15	14	0.48537564...	0.50220061...	0.22765307...	0.99460989...	0.20684385...	0.48227960...	0.40755214...	0.32423713...	0.25657257...	Vehicle
16	15	0.80028046...	0.99932947...	0.91954220...	0.20676414...	0.03736626...	0.33806474...	0.21983707...	0.46004381...	0.12133827...	Pedestrian
17	16	0.14188633...	0.35540715...	0.64199930...	0.60736395...	0.66336496...	0.23676704...	0.23046066...	0.67417460...	0.04060644...	Pedestrian
18	17	0.42176128...	0.04707770...	0.10532018...	0.34763032...	0.50725457...	0.45086320...	0.43854978...	0.57406187...	0.88794313...	Object Stat...
19	18	0.91573552...	0.21366058...	0.26816091...	0.71773706...	0.48580044...	0.18545098...	0.91989383...	0.84282523...	0.75318731...	Vehicle

FIGURE 4.12: Base de Données de 2000 scénarios pour évaluer notre stratégie.

L'évaluation à l'aide des métriques statistiques (Précision, Rappel et Efficacité) démontre leur pertinence pour l'analyse de ce type de scénarios. Le calcul des métriques de statistique comme; Précision, Rappel et efficacité est illustré dans TABLE 4.1. Nous avons obtenu ces résultats grâce au processus de prétraitement

TABLE 4.1: Evaluation par les paramètres Statistique de fusion de données par DST

Object	Percentage (%)	Précision (%)	Rappel (%)	Efficacité (%)
Véhicule	32.55	100.00	100.00	100.00
Piéton	33.85	100.00	100.00	100.00
Objet Immobilie	33.60	100.00	100.00	100.00

appliqué à la base de données, visant à équilibrer les pourcentages entre les Véhicules, les Piétons et les Objets immobiles.

4.4 Conclusion

Dans ce chapitre, nous avons exploré plusieurs concepts fondamentaux, en mettant particulièrement l'accent sur leur mise en œuvre concrète au sein de notre application. Chaque notion a été présentée de manière détaillée et individualisée, afin d'en faciliter la compréhension. Nous avons également décrit les langages de programmation et les logiciels utilisés lors du développement, en justifiant leur choix selon les besoins spécifiques du projet. La base de données adoptée a également été présentée, en soulignant son rôle essentiel dans le bon fonctionnement de l'application ainsi que l'intégration harmonieuse des différentes technologies. Enfin, une évaluation globale de notre approche a été réalisée, permettant ainsi de mesurer l'efficacité de l'implémentation proposée.

Conclusion Générale et Perspectives

Dans ce rapport de Projet de Fin d'Études (PFE), nous avons effectué une revue de la littérature sur le problème de fusion de données perceptionnées par les différents capteurs (Caméras, Radars et Lidars) dans les véhicules autonomes, en présentant les stratégies de fusions des données dans le véhicules autonomes proposées dans les travaux antérieurs. L'étude approfondie de ce problème et la proposition de stratégies pertinentes contribuent de manière efficace à résoudre les problèmes de fusion des données de perception.

L'application de la Théorie de l'Évidence (Dempster-Shafer, DST) à la fusion de données multi-capteurs dans les véhicules autonomes représente une avancée majeure pour la gestion des incertitudes et des conflits sensoriels. Contrairement aux approches probabilistes traditionnelles, la DST offre une modélisation plus flexible des croyances, permettant de distinguer entre l'ignorance, l'incertitude et les données contradictoires.

Les principaux atouts de cette méthode incluent :

- Une représentation robuste de l'incertitude, essentielle pour des environnements dynamiques et imprévisibles.
- Une capacité à fusionner des données hétérogènes (lidars, radars, caméras) tout en pondérant leur fiabilité.
- Une résilience accrue face aux conflits sensoriels, grâce à des règles de combinaison adaptatives (Dempster-Shafer, Yager, PCR).

Ce travail de recherche a donné lieu à une proposition formelle soumise à évaluation, qui n'a malheureusement pas été accepté. La page de titre avec la liste des auteurs est fournie en annexe à titre de référence :

- Adda Boualem, Marwane Ayaida, Nadhir Messai, Yassin El Hillali, Hadjira Guarni, Ferial Blidi Farah, « Deterministic and Uncertain Data Fusion Strategies and Algorithms in Autonomous Vehicles: Classification and Comparison », *International Journal of Vehicular Communications*, 2025, page 1. (Voir L'annexe).

Cet article propose une classification fondée sur les stratégies déterministes et incertaines, afin de résumer l'ensemble des approches, mécanismes et techniques présentés dans la littérature. L'objectif est de contribuer à une amélioration plus fiable de la fusion des données de perception dans le contexte des véhicules autonomes. Cependant, des défis persistent, notamment la complexité calculatoire liée à l'explosion combinatoire des hypothèses, ainsi que la nécessité d'une adaptation dynamique des poids des capteurs en fonction des conditions environnementales.

Pour une intégration optimale dans les systèmes autonomes, des travaux futurs pourraient explorer :

- L'optimisation des algorithmes (réduction de la complexité, méthodes approximatives).

- L'apprentissage automatique pour ajuster automatiquement les masses de croyance.
- Des architectures hybrides combinant DST avec d'autres méthodes (filtres de Kalman, réseaux bayésiens).

En définitive, la DST constitue un outil puissant pour améliorer la fiabilité et la sécurité des véhicules autonomes, mais son déploiement à grande échelle nécessitera des améliorations tant algorithmiques que matérielles. Son potentiel reste néanmoins incontestable pour faire face aux défis complexes de la perception multi-capteurs.

Annexes

Deterministic and Uncertain Data Fusion Strategies and Algorithms in Autonomous Vehicles: Classification and Comparison

1st Adda Boualem
Tiaret University, Computer
Science Department, Algeria
adda.boualem@univ-tiaret.dz

2nd Marwane Ayaida
Univ. Polytechnique Hauts-de-
France, CNRS, Univ. Lille, UMR 8520
IEMN, F-59313 Valenciennes, France
marwane.ayaida@uphf.fr

3th Nadhir Messai
Université de Reims Champagne-
Ardenne, CReSTIC
Nadhir.Messai@univ-reims.fr

4rd Yassin El Hillali
Univ. Polytechnique Hauts-de-
France, CNRS, Univ. Lille, UMR 8520
IEMN, F-59313 Valenciennes, France
yassin.elhillali@uphf.fr

5th Garn Hadjira
Tiaret University, Computer
Science Department, Algeria
hadjira.garn@univ-tiaret.dz

6th Blidi Farah Ferial
Tiaret University, Computer
Science Department, Algeria
farahFerial.blidi@univ-tiaret.dz

Abstract—Data fusion is pivotal in autonomous vehicles, enabling robust perception by combining information from diverse sensors such as cameras, LiDAR, and radar. Despite significant advancements, selecting and optimizing appropriate fusion strategies remains challenging due to the trade-offs between accuracy, computational efficiency, and real-world applicability. This work presents a comprehensive classification and comparison of the data fusion strategies and algorithms used in autonomous vehicles, including low-level, mid-level, and high-level fusion approaches. We define the context of sensor data fusion, outline existing challenges, such as sensor reliability, environmental variability, and processing constraints, and provide an in-depth evaluation of key algorithms regarding performance, scalability, and robustness.

Our contribution lies in offering a structured framework for understanding fusion strategies and highlighting the gaps in current methodologies. Through comparative analysis, we demonstrate how different algorithms perform under varying conditions, emphasizing their limitations and opportunities for improvement. This study establishes a strong foundation for our subsequent work, Evidence-Based Data Fusion for Robust Autonomous Vehicle Per-

ception, where we propose an innovative evidence-based approach that improves fusion accuracy and reliability. By addressing the shortcomings identified in this review, we aim to pave the way for a more robust and efficient autonomous vehicle system.

Index Terms—Autonomous Vehicles; Perception; Data Fusion Algorithms; Deterministic and Uncertain Data Fusion Strategies

I. INTRODUCTION

Autonomous vehicles (AVs) are revolutionizing modern transportation systems by offering the promise of enhanced safety, efficiency, and convenience. Through the integration of advanced sensors, artificial intelligence (AI), and communication technologies, AVs are expected to reduce human error, optimize traffic flow, and decrease environmental impact. However, the journey toward fully autonomous driving is fraught with challenges, particularly in perception, decision-making, and data integration. Achieving robust environmental awareness, precise object detection, and reliable decision-making in diverse and unpredictable scenarios re-

Bibliographie

- [1] A. Olteanu-Raimond, “Fusion de connaissances imparfaites pour l’appariement de données géographiques : proposition d’une approche s’appuyant sur la théorie des fonctions de croyance. (imperfect knowledge fusion for matching geographical data : approach based on belief theory),” Ph.D. dissertation, University of Paris-Est, France, 2008. [Online]. Available: <https://tel.archives-ouvertes.fr/tel-00469407>
- [2] K. Rajashekara, “Energy impacts of autonomous vehicles - present and the future,” *iEnergy*, vol. 3, no. 2, pp. 73–74, Jun. 2024.
- [3] C. Beugnon, T. Singh, J. Llinas, and R. Saha, “Adaptive track fusion in a multisensor environment,” in *Proceedings of the Third International Conference on Information Fusion*. IEEE, 2000, pp. TUC2/24–TUC2/31 vol.1.
- [4] A. Boualem, M. Dehbi, M. A. B. Tiali, M. Ayaida, and N. Messai, “Evidence-based data fusion for robust autonomous vehicle perception,” in *EEE International Conference on Communications (ICC): Communication Software and Multimedia Symposium*, Montreal, Canada, 8-12 June 2025, pp. 1–6.
- [5] F. Castanedo, “A review of data fusion techniques,” *The Scientific World Journal*, vol. 2013, no. 1, Jan. 2013.
- [6] U. Mangai, S. Samanta, S. Das, and P. Chowdhury, “A survey of decision fusion and feature fusion strategies for pattern classification,” *IETE Technical Review*, vol. 27, no. 4, p. 293, 2010.
- [7] F. Elberzhager, J. Manch, and V. T. N. Nha, “A systematic mapping study on the combination of static and dynamic quality assurance techniques,” *Information and Software Technology*, vol. 54, no. 1, pp. 1–15, Jan. 2012.
- [8] F. Xu, J. Liu, Y. Song, H. Sun, and X. Wang, “Multi-exposure image fusion techniques: A comprehensive review,” *Remote Sensing*, vol. 14, no. 3, p. 771, Feb. 2022. [Online]. Available: <http://dx.doi.org/10.3390/rs14030771>
- [9] V. Nimier and K. Benameur, *Adaptive Fusion*. Springer International Publishing, 2019, pp. 587–606.
- [10] W.-L. Chu, C.-C. Tu, and B.-L. Jian, “Avafn-adaptive variational autoencoder fusion network for multispectral image,” *Multimedia Tools and Applications*, vol. 83, no. 41, pp. 89 297–89 315, Oct. 2024.
- [11] L. Snidaro, J. Garcà, and J. Llinas, “Context-based information fusion: A survey and discussion,” *Information Fusion*, vol. 25, pp. 16–31, Sep. 2015.
- [12] J. Gomez-Romero, J. Garcia, M. Kandfer, J. Llinas, J. M. Molina, M. A. Patricio, M. Prentice, and S. C. Shapiro, “Strategies and techniques for use and exploitation of contextual information in high-level fusion architectures,” in

- 2010 13th International Conference on Information Fusion. IEEE, Jul. 2010, pp. 1–8.
- [13] S. Sural, N. Sahu, and R. R. Rajkumar, “Contextualfusion: Context-based multi-sensor fusion for 3d object detection in adverse operating conditions,” in *2024 IEEE Intelligent Vehicles Symposium (IV)*. IEEE, Jun. 2024, pp. 1534–1541.
- [14] G. Poizat, C. Säve, G. Serres, and J. Saury, “Analyse du partage d’informations contextuelles dans deux formes d’interaction sportives : coopérative et concurrentielle,” in *Le travail humain*, vol. Vol. 71, no. 4. CAIRN, Jan. 2009, pp. 323–357.
- [15] S. Liu, J. Wang, Z. Wang, B. Yu, W. Hu, Y. Liu, J. Tang, S. L. Song, C. Liu, and Y. Hu, “Brief industry paper: The necessity of adaptive data fusion in infrastructure-augmented autonomous driving system,” in *2022 IEEE 28th Real-Time and Embedded Technology and Applications Symposium (RTAS)*. IEEE, May 2022.
- [16] J. Wang, Z. Wang, B. Yu, J. Tang, S. L. Song, C. Liu, and Y. Hu, “Data fusion in infrastructure-augmented autonomous driving system: Why? where? and how?” *IEEE Internet of Things Journal*, vol. 10, no. 18, pp. 15 857–15 871, Sep. 2023.
- [17] E. Blasch, D. Shen, G. Chen, C. C. Insaurrealde, and R. Niu, “Artificial intelligence fusion of information for aerospace (aifia) systems,” in *2022 IEEE Aerospace Conference (AERO)*. IEEE, Mar. 2022, pp. 1–8.
- [18] V. Vielzeuf, A. Lechervy, S. Pateux, and F. Jurie, “Multilevel sensor fusion with deep learning,” *IEEE Sensors Letters*, vol. 3, no. 1, pp. 1–4, Jan. 2019.
- [19] A. V. Malawade, T. Mortlock, and M. A. Al Faruque, “Hydrافusion: Context-aware selective sensor fusion for robust and efficient autonomous vehicle perception,” in *2022 ACM/IEEE 13th International Conference on Cyber-Physical Systems (IC3PS)*. IEEE, May 2022, pp. 68–79.
- [20] C. Xiang, C. Feng, X. Xie, B. Shi, H. Lu, Y. Lv, M. Yang, and Z. Niu, “Multi-sensor fusion and cooperative perception for autonomous driving: A review,” *IEEE Intelligent Transportation Systems Magazine*, vol. 15, no. 5, pp. 36–58, Sep. 2023.
- [21] I. Sumalatha, P. Chaturvedi, G. R. R. S. Patil, H. P. Thethi, and A. A. Hameed, “Autonomous multi-sensor fusion techniques for environmental perception in self-driving vehicles,” in *2024 International Conference on Communication, Computer Sciences and Engineering (IC3SE)*. IEEE, May 2024, pp. 1146–1151.
- [22] A. Thakur and S. K. Mishra, “An in-depth evaluation of deep learning-enabled adaptive approaches for detecting obstacles using sensor-fused data in autonomous vehicles,” *Engineering Applications of Artificial Intelligence*, vol. 133, p. 108550, Jul. 2024.
- [23] A. Fekry, A. M. Kamel, Y. Elhalwagy, and A. Abosekeen, “Deep learning-based strategies for integrated autonomous navigation: A review,” in *2024 International Telecommunications Conference (ITC-Egypt)*. IEEE, Jul. 2024, pp. 692–697.

- [24] A. El-Dalahmeh, M. El-Dalahmeh, and J. Li, “Enhanced vehicle detection through multi-sensor fusion utilizing yolo-nas and faster r-cnn,” in *2024 International Joint Conference on Neural Networks (IJCNN)*. IEEE, Jun. 2024, pp. 1–6. [Online]. Available: <http://dx.doi.org/10.1109/IJCNN60899.2024.10651024>
- [25] S. AlZuabi and Y. Jararweh, “Data fusion in autonomous vehicles research, literature tracing from imaginary idea to smart surrounding community,” in *2020 Fifth International Conference on Fog and Mobile Edge Computing (FMEC)*. IEEE, Apr. 2020.
- [26] H. Gao, B. Cheng, J. Wang, K. Li, J. Zhao, and D. Li, “Object classification using cnn-based fusion of vision and lidar in autonomous vehicle environment,” *IEEE Transactions on Industrial Informatics*, vol. 14, no. 9, pp. 4224–4231, Sep. 2018. [Online]. Available: <http://dx.doi.org/10.1109/TII.2018.2822828>
- [27] A. Boualem, H. B. Douma, and S. dine Mehloul, “Deterministic and uncertainty-based coverage classification models in wsns: A survey,” in *6th International Conference on Artificial Intelligence in Renewable Energetic Systems*, 2022, p. 1–6.
- [28] A. Boualem, Y. Dahmani, M. Ayaida, and C. de Runz, “A new fuzzy/evidential approach to address the area coverage problem in mobile wireless sensor networks,” in *Proceedings of the 34th ACM/SIGAPP Symposium on Applied Computing*, ser. SAC19. ACM, Apr. 2019, pp. 2430–2433.
- [29] A. Boualem, M. Ayaida, C. de Runz, H. Kholidy, and H. Sedjelmaci, “Sm-vsn-3c: a new starlings model-based virtual sensor networks for coverage, connectivity, and data communication,” *Cluster Computing*, vol. 27, no. 10, pp. 13 777–13 793, Jul. 2024.
- [30] A. Boualem, C. D. Runz, M. Ayaida, and H. Akdag, “A fuzzy/possibility approach for area coverage in wireless sensor networks,” *Soft Computing*, may 2023. [Online]. Available: <https://doi.org/10.1007%2Fs00500-023-08406-3>
- [31] A. Boualem, “Stratégies d’amélioration de la couverture dans les réseaux de capteurs sans fil,” Thèse de doctorat en Informatique, école supérieur d’informatique, ESI, Alger, Algerien, 2021.
- [32] A. boualem, “A comparative study of deterministic and uncertain area coverage strategies in wsns,” *Journal of Communications*, vol. 01, pp. 1–16, jun 2025.
- [33] A. Boualem, M. Dehbi, M. A. B. Tiali, M. Ayaida, and N. Messai, “Evidence-based data fusion for robust autonomous vehicle perception,” in *IEEE International Conference on Communications (ICC): Communication Software and Multimedia Symposium*. IEEE, 2024.
- [34] A. Boualem, Y. Dahmani, M. Ayaida, and C. D. Runz, “A new fuzzy/evidential approach to address the area coverage problem in mobile wireless sensor networks,” in *The 34th ACM/SIGAPP Symposium on Applied Computing (SAC’19)*, Limassol, Cyprus. ACM, New York, NY, USA, April 8–12 2019, pp. 2430–2433.

- [35] A. Boualem, C. D. Runz, and M. Ayaida, "An evidential approach for area coverage in mobile wireless sensor networks," *International Journal of Fuzzy System Applications (IJFSA)*, vol. 10, no. 3, pp. 121–133, March 2021.
- [36] A. Boualem, H. Boumediene, and S. dine Mehloul, "Deterministic and uncertainty-based coverage classification models in wsns: A survey," in *6th International Conference on Artificial Intelligence in Renewable Energetic Systems (C-AIRES2022)*, no. 6, Tamenrasset, Algeria, November, 20-22 2022, pp. 1–7.
- [37] A. Boualem, "Théorie de l'évidence et de la logique floue: Application à l'appariement de données géographiques," Master's thesis, 2013, mémoire de magister. [Online]. Available: <https://www.ccdz.cerist.dz/admin/notice.php?id=00000000000000839484000087>
- [38] R. R. Yager, "On ordered weighted averaging aggregation operators in multicriteria decisionmaking," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 18, no. 1, pp. 183–190, 1988.
- [39] D. Dubois and H. Prade, "Representation and combination of uncertainty with belief functions and possibility measures," *Computational Intelligence*, vol. 4, pp. 244–264, 1988.
- [40] T. Inagaki, "Interdependence between safety-control policy and multiple-sensor schemes via Dempster-Shafer theory," *IEEE Transactions on Reliability*, vol. 40, no. 2, pp. 182–188, 1991.
- [41] P. Smets, "Imperfect information: Imprecision - uncertainty," in *Uncertainty Management in Information Systems: From Needs to Solutions*, A. Motro and P. Smets, Eds. Boston, MA: Kluwer Academic Publishers, 1997, pp. 225–254.
- [42] A. Boualem, Y. Dahmani, and A. Maatoug, "The combination operator of information sources by a new expressive matrix," *Journal of Geographic Information System*, vol. 07, no. 04, pp. 430–437, 2015.