

الجمهورية الجزائرية الديمقراطية الشعبية
REPUBLICUE ALGERIENNE DEMOCRATIQUE ET POPULAIRES
وزارة التعليم العالي والبحث العلمي
MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA
RECHERCHE SCIENTIFIQUE

*Université SAAD DAHLEB -Blida 1-
Institut D'aéronautique Et Des Etudes Spatiales IAES
Département Construction Aéronautique*



Mémoire de fin d'études



En vue de l'obtention de diplôme de
Master en aéronautique

OPTION : Avionique

Thème

*Détection Des Signatures Sonores Des Drones En Utilisant
L'apprentissage Automatique Des Arbres De Décisions*

Préparer et présenter par :

➤ Mlle. BOUGACI Hayat

Proposé et dirigé par :

➤ Pr. CHEGGAGA Nawel
➤ Dr. KRIM Mohammed

Soutenu devant le jury composé de :

- *Président du jury* : Mme BENCHEIKH Saliha
- *Examinatrice* : Mme OTHMANE Fadhela

Promotion 2024/2025

Remerciement

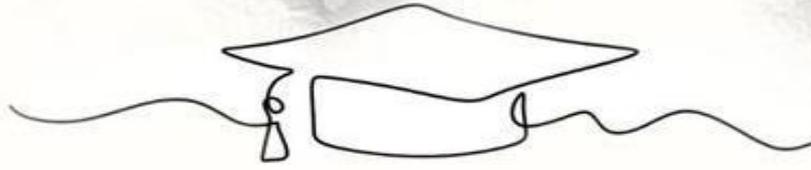
*N*ous commençons tout d'abord par remercier *ALLAH* pour toutes Ses bénédictions, pour la force, la volonté, et le courage qu'Il nous a donnés, durant ces longues années d'étude.

Je tiens à exprimer mes plus sincères remerciements à mes encadrants, Madame CHEGGAGA Nawel et Monsieur KRIM Mohammed, pour l'attention qu'ils ont portée à mon travail tout au long de ce projet. Leur encadrement rigoureux, leurs conseils judicieux, ainsi que leur disponibilité et leur bienveillance ont grandement contribué à l'aboutissement de ce mémoire. Leur expertise et leur implication ont été pour moi une source précieuse d'enrichissement, tant sur le plan scientifique que personnel.

Nous remercions également les membres du jury, qui ont accepté d'évaluer ce travail et à leur tête, qui nous a fait l'honneur de présider le jury de ce mémoire.

Nous remercions, également, l'ensemble des enseignants qui ont assuré notre formation tout au long de notre cursus universitaire :

Enfin, nous remercions, tous ceux qui de près ou de loin, ont contribué à la réalisation de ce travail.



Dédicaces

J'offre ce modeste travail :

A mes chers parents,

Qui m'ont toujours poussé et motivé dans mes études. Sans eux, je n'aurais certainement pas fait d'étude longues. Ce projet fin d'études représente donc l'aboutissement du soutien et des encouragements qu'ils m'ont prodigués tout au long de ma scolarité. Qu'ils en soient remerciés par cette trop modeste dédicace.

Je dédie aussi ce modeste travail :

A mon cher frère ; Brahim

A mes chères sœurs ; Meriem et Manel

A tous mes amis, collègues, et toutes les personnes qui m'ont aidée accompagnés dans l'élaboration de ce travail académique, je vous remercie de tout cœur.

Que ce mémoire soit le témoignage de ma reconnaissance. Chacun d'entre vous a joué un rôle essentiel dans ma réussite, et je vous en suis profondément reconnaissante.

Ce travail est aussi le vôtre.

Avec tout mon amour et ma reconnaissance.

Hayat

المخلص

يرتكز العمل على استخدام مجموعات بيانات مخصصة للتعليم والتحقق، بالإضافة إلى تطوير نظام ذكي قائم على خوارزميات شجرة القرار (Decision Tree) يتيح الكشف عن أصوات الطائرات بدون طيار وتصنيفها ضمن بيئة حضرية معقدة، اعتمادًا على توقيعاتها الصوتية الخاصة: التردد، السعة، والتغيرات الزمنية. تم تقييم نموذجين من التعلم: شجرة القرار، وهي بسيطة وقابلة للتفسير، لكنها أقل كفاءة وتُظهر التباينًا متكررًا بين الفئات؛ و (Random Forest)، الذي أظهر متانة ودقة أفضل في بيئة حضرية معقدة. الهدف هو المساهمة في تحسين خوارزميات الكشف الصوتي للطائرات بدون طيار، خصوصًا في البيئة الحضرية، حيث لا تزال عملية التعرف عليها تمثل تحديًا بسبب كثافة وتنوع الأصوات المحيطة.

كلمات مفتاحية: شجرة القرار، الكشف الصوتي، التصنيف، الطائرات بدون طيار، الذكاء الاصطناعي.

Abstract

The work is based on the use of datasets dedicated to training and validation, as well as the development of an intelligent system based on Decision Tree algorithms, enabling the detection and classification of drone sounds within a complex urban environment, based on their specific acoustic signatures: frequency, amplitude, and temporal variations. Two supervised learning models were evaluated: the Decision Tree, which is simple and interpretable but less efficient, with frequent confusions between classes; and the Random Forest, which demonstrated greater robustness and accuracy in a complex urban environment. The objective is to contribute to the improvement of acoustic drone detection algorithms, particularly in urban areas, where their identification remains a challenge due to the density and diversity of ambient sounds.

Keywords: Decision Tree, acoustic detection, classification, drones, artificial intelligence.

Résumé

Le travail repose sur l'utilisation de jeux de données dédiés à l'apprentissage et à la validation, ainsi que sur le développement d'un système intelligent basé sur les arbres de décision (Decision Tree), permettant de détecter et de classer les sons de drones au sein d'un environnement urbain complexe, en se fondant sur leurs signatures acoustiques spécifiques : fréquence, amplitude et variations sonores. Deux modèles d'apprentissage supervisé ont été évalués : le Decision Tree, simple et interprétable, mais moins performant avec des confusions fréquentes entre classes ; et le Random Forest, qui a montré une meilleure robustesse et précision dans un environnement urbain complexe. L'objectif est de contribuer à l'amélioration des algorithmes de détection acoustique des drones, notamment en milieu urbain, où leur identification reste un défi en raison de la densité et de la diversité des sons ambiants.

Mots-clés : Arbres de décision, détection acoustique, classification, drones, intelligence artificielle.

Table des figures

Figure 1.1: drones à voile fixe	4
Figure 1.2: drone a aile battante [14]	5
Figure 1.3: Drone mono-rotor	5
Figure 1.4: types de birotor [15].....	6
Figure 1.5: drone tri-rotor [16].....	6
Figure 1.6: Exemples des drones à Rotors multiples	7
Figure 1.7: Drone hybride	7
Figure 1.8: spectre de masse des différents drones selon le classement américain.....	8
Figure 1.9: classification des drones selon l'endurance [18].....	9
Figure 1.10: cartographie par drone	10
Figure 1.11: système de détection de drones par RADAR.....	13
Figure 1.12:système de détection de drones Radio Fréquence [34].....	13
Figure 1.13: Schéma synoptique de la méthode de détection acoustique [33].....	14
Figure 2.1: Schéma de décomposition du domaine de l'intelligence artificielle et de ces sous-domaines [37].....	19
Figure 2.2: Types d'apprentissages en apprentissage automatique [41].....	20
Figure 2.3:schéma représente quelques exemples d'algorithmes d'apprentissage automatique [41]	21
Figure 2.4: schéma générale d'un réseau de neurone [41].....	21
Figure 2.5: Exemple d'un Arbre de Décision	23
Figure 2.6:Exemple d'Architecture d'un Arbre de Décision [47].....	24
Figure 3.1:Exemple fréquence fondamentale et harmoniques d'une signature acoustique [56]	30
Figure 3.2:Directivité en fonction de la fréquence pour une source harmonique [57]	30
Figure 3.3: Spectrogramme du signal audio capturant la signature acoustique du drone lors de l'expérience en extérieur [59]	31
Figure 3.4: Exemple d'une représentation temporelle et fréquentielle (2D et 3D) du son de drone [60]	32
Figure 3.5: Aperçu du dataset UrbanSound8K tel qu'il apparaît sur la plateforme Kaggle [62].	33
Figure 3.6: Aperçu du Dataset-balanced-n-weighted-final tel qu'il apparaît sur la plateforme Kaggle	34
Figure 3.7: représentation de quelques sons des drones dans le domaine temporel	36
Figure 3.8: représentation temporelle de quelques exemples des sons urbains	36
Figure 3.9 : spectrogrammes de différents sons de drones	38
Figure 3.10: spectrogrammes de différents sons urbains	39
Figure 3.11: Extraits MFCCs de divers sons de drones	42
Figure 3.12: Illustration de l'extraction des MFCCs sur des enregistrements variés	43
Figure 4.1: matrice de confusion de modèle d'arbre de décision	51
Figure 4.2: matrice de confusion de modèle Random forest.....	54

Liste Des Tableaux

Tableau 1.1: Types des drones selon la portée	9
Tableau 1.2: Exemples d'utilisations illégal des drone	12
Tableau 1.3: Les avantages et les inconvénients des différents systèmes de détection [33]....	15
Tableau 4.1: résultats comparatifs des classifieurs	50
Tableau 4.2: rapport de classification de classifieur arbre de décision	50
Tableau 4.3: rapport de classification de classifieur Random forest.....	53
Tableau 4.4: comparaison des performances de deux les deux modèles	56

Abréviation et Acronymes

2D/3D	Deux/Trois Dimensions
BF	Basse fréquence
CNN	Convolutional Neural Network
DL	Deep Learning
EO/IR	Électro-Optique / Infrarouge
FFT	Fast Fourier Transform
FN	False Negative
FP	False Positive
GAN	Generative Adversarial Network
GPS	Global Positioning System
HF	Haute Fréquence
IA	Intelligence Artificielle
LSTM	Long Short-Term Memory
MFCCs	Mel-Frequency Cepstral Coefficients
ML	Machine Learning
RF	Radio Frequency
RNN	Recurrent Neural Network
SDDD	Système de Détection et de Défense contre les Drones
STFT	Short-Time Fourier Transform
TN	True Negative
TP	True Positive
UAV	Unmanned Aerial Vehicle

Table des matières

Remerciement	
Dédicace	
Résumé	
Table des matières	
Table des figures	
Liste Des Tableaux	
Abréviations et Acronymes	
Introduction Générale.....	1
Chapitre 1 : Généralités sur les Drones	3
1.1. Classification des drones	4
1.2.1. Classification selon la structure.....	4
1.2.2. Classification selon la taille et le poids	7
1.2.3. Classification selon l'autonomie	8
1.2.4. Classification selon la portée.....	9
1.3. Domaines d'applications :	10
1.3.1. Applications militaires	10
1.3.2. Applications civiles	10
1.3.3. Les impacts négatifs des drones	11
1.4. Les méthodes de détection	12
1.4.1. Détection RADAR	12
1.4.2. Détection Radio Fréquence	13
1.4.3. Détection optique	14
1.4.4. Détection acoustique	14
1.5. Limitations et performances des méthodes de détection.....	15
1.6. Détection Acoustique en Milieu Urbain.....	16
1.7. Conclusion.....	17
Chapitre 2 : Les Arbres De Décision	18
2.1. Apprentissage automatique	19
2.1.1. Apprentissage supervisé	20
2.1.2. Apprentissage non-supervisé.....	20
2.1.3. Apprentissage par renforcement.....	20
2.3. Apprentissage profond	21
2.4. L'application de AI pour la détection acoustique	22
2.5. Les Arbres de Discision	23

Table des matières

2.5.1. Architecture des arbres de décision	23
2.5.2. Avantages et limites	24
2.5.3. La justification de choix des arbres de décision.....	24
2.6. Utilisation des arbres de décisions pour la détection acoustique des drones	25
2.7. Conclusion :.....	27
Chapitre 3 : Etude Acoustique des Drones.....	28
3.1. Définition de l’empreinte acoustique	29
3.2. Caractéristique acoustique des drones.....	29
3.3. Spectre acoustique des drones	31
3.3.1. Soustraction spectrale.....	31
3.3.2. La transformée de Fourier rapide (FFT).....	31
3.3.3. Spectrogrammes (STFT)	31
3.4. Influence de la vitesse sur le spectre acoustique des drones	32
3.4.1. Influence de la vitesse de rotation des hélices.....	32
3.4.2. Influence de la vitesse de déplacement du drone	33
3.5. Logiciel de programmation	33
3.6. La collecte et prétraitement des données.....	33
3.6.1. Description de datasets.....	33
3.6.2 Visualisation des données	35
3.7. Conclusion.....	45
Chapitre 4 : Développement du Modèle d’Intelligence Artificielle.....	46
4.1. Modèles et comparaison	48
4.2. Résultats et discussion.....	50
4.2.1. Résultats comparatifs des classifieurs	50
4.2.2 Évaluation des performances et interprétation des résultats de l’arbre de décision	50
4.2.3 Évaluation des performances et interprétation des résultats de Randomforest.....	53
4.2.4. Analyse comparative entre Random Forest et Arbre de Décision	56
4.3. Conclusion.....	57
Conclusion Générale	58
Bibliographie.....	61

Introduction Générale

Introduction générale

Avec l'essor technologique, les drones ont connu une expansion remarquable dans divers domaines tels que la surveillance, l'agriculture, la cartographie et la logistique [1]. Leur utilisation croissante pose toutefois des problèmes en matière de sécurité et de régulation de l'espace aérien. En effet, la prolifération des drones, qu'ils soient commerciaux, civils ou militaires [2], soulève des enjeux majeurs. Si leurs applications sont multiples et bénéfiques, les drones peuvent également être détournés de leur usage premier et être utilisés à des fins malveillantes [3], allant de l'atteinte à la vie privée et l'intrusion dans des zones sensibles, jusqu'au trafic de marchandises illégales (drogues, armes) [4] et aux attaques terroristes. Face à ces risques potentiels, il devient ainsi primordial de mettre en place des systèmes performants permettant de détecter et d'identifier ces appareils avec précision, afin de garantir la sécurité des personnes et des biens [5].

Les méthodes usuelles de détection des drones reposent sur divers capteurs, notamment visuels, thermiques et radar [6]. Toutefois, ces techniques présentent certaines limites en cas de mauvaises conditions météorologiques ou de faible visibilité, en particulier en milieu urbain où les obstacles et les interférences peuvent réduire leur efficacité [6]. Dans ce contexte, la détection acoustique se distingue comme une alternative intéressante. Elle permet d'identifier les drones en analysant leurs signatures sonores spécifiques [7], indépendamment des conditions de luminosité ou de la présence d'obstacles physiques [8]. Il existe également d'autres approches hybrides de détection, combinant par exemple l'acoustique et la vision, le radar et l'analyse audio, ou encore la radiofréquence et l'imagerie thermique, souvent renforcées par des techniques d'intelligence artificielle pour une meilleure fiabilité. Cette approche offre ainsi une solution adaptée aux environnements complexes où les autres techniques atteignent leurs limites. [7,8]

L'intégration de l'intelligence artificielle dans le domaine de la détection acoustique représente une avancée significative [8]. Les algorithmes d'apprentissage automatique permettent d'améliorer la précision et la rapidité de la classification des signatures sonores, en distinguant les bruits des drones de ceux générés par d'autres sources sonores comme les véhicules, les conversations humaines ou encore les bruits industriels. Parmi les différentes techniques de classification disponibles, les arbres de décision apparaissent comme une solution efficace [9] grâce à leur capacité à traiter des données complexes tout en restant interprétables. En segmentant les caractéristiques sonores en fonction de critères spécifiques, ces modèles permettent d'optimiser l'identification des drones en minimisant les erreurs de classification [9].

Le présent travail vise à développer un système permettant la détection des drones en milieu urbain en s'appuyant sur l'analyse des signatures acoustiques et l'apprentissage automatique fondé sur les arbres de décision. Pour y parvenir, il est essentiel de suivre plusieurs étapes, le choix de l'outil de machine Learning, l'élaboration de l'architecteur puis la séparation des données et apprentissage, enfin validation et teste de robustesse grâce à des paramètres utilisés dans le domaine, notamment la collecte et le traitement des données sonores. L'objectif est de démontrer la pertinence de cette approche dans un environnement urbain, où les méthodes traditionnelles de détection présentent certaines limitations.

Afin d'approfondir cette étude, ce mémoire est structuré en quatre chapitres :

Introduction Générale

- Le premier chapitre introduit les drones d'une façon générale en abordant leur classification, leurs caractéristiques et leurs applications, y compris les usages dangereux. On présente également les différentes méthodes de détection et leurs limitations, avec un focus sur la détection acoustique et ses défis en milieu urbain.
- Le deuxième chapitre, nous présentons brièvement l'intelligence artificielle et l'apprentissage automatique, puis nous justifions l'usage des arbres de décision pour la détection acoustique des drones, en raison de leur efficacité et de leur simplicité d'implémentation.
- Le troisième nous nous intéressons aux aspects acoustiques des drones ainsi qu'aux jeux de données utilisés. Nous décrivons les caractéristiques sonores, les étapes de préparation des données, ainsi que les représentations temporelles et fréquentielles qui permettent une meilleure compréhension des signaux.
- Le dernier chapitre, nous développons les modèles de, que nous évaluons sur nos jeux de données. Nous discutons également des résultats obtenus et des pistes d'amélioration possibles.

Et on termine le travail par une conclusion générale et perspectives

Chapitre 1 : Généralités sur les Drones

1. Généralités sur les Drones

Introduction

Les drones, également appelés UAV (Unmanned Aerial Vehicles) [10], désignent des aéronefs sans pilote capables d'exécuter diverses missions de manière autonome ou semi-autonome [11] grâce à des systèmes embarqués de navigation et de contrôle. Initialement développés à des fins militaires [11], ils ont évolué pour devenir des outils indispensables dans de nombreux secteurs, allant de la défense à des applications civiles variées [1].

Les drones ont été développés pour suppléer l'homme dans des environnements hostiles ou à risque [1], réduisant ainsi l'exposition des opérateurs aux dangers. Dans le domaine militaire, ils sont principalement utilisés pour la reconnaissance et les opérations stratégiques, tandis que dans le secteur civil, ils apportent des avantages dans divers domaines tels que l'inspection et la surveillance.

Ainsi, La flexibilité des drones nécessite des systèmes avancés de détection pour assurer un usage sécurisé [4]. Leur intégration dans l'espace aérien impose une gestion rigoureuse du trafic et l'adoption de technologies adaptées. Tandis que la réglementation évolue pour limiter les risques liés à la sécurité et à la protection des données, des autorités telles que l'EASA (Agence de la sécurité aérienne de l'Union européenne) [12] et l'OACI (Organisation de l'aviation civile internationale) imposent des cadres législatifs et techniques afin d'encadrer l'intégration des drones dans l'espace aérien de manière harmonisée et sécurisée.

1.1. Classification des drones

La classification des drones est un exercice complexe, car ils se distinguent par une multitude de caractéristiques, ce qui permet d'envisager une classification basée sur divers critères pertinents.

1.2.1. Classification selon la structure

La classification se repose sur leur conception aérodynamique et la manière dont ils génèrent leur portance et leur propulsion. On distingue trois grandes catégories :

a) Voilures fixe

Ce genre de drone, similaires à des avions miniatures comme le montre la Figure 1.1, se composent d'ailes, d'un fuselage, d'un empennage et d'hélices. Cette conception leur confère une autonomie de vol supérieure. [13]

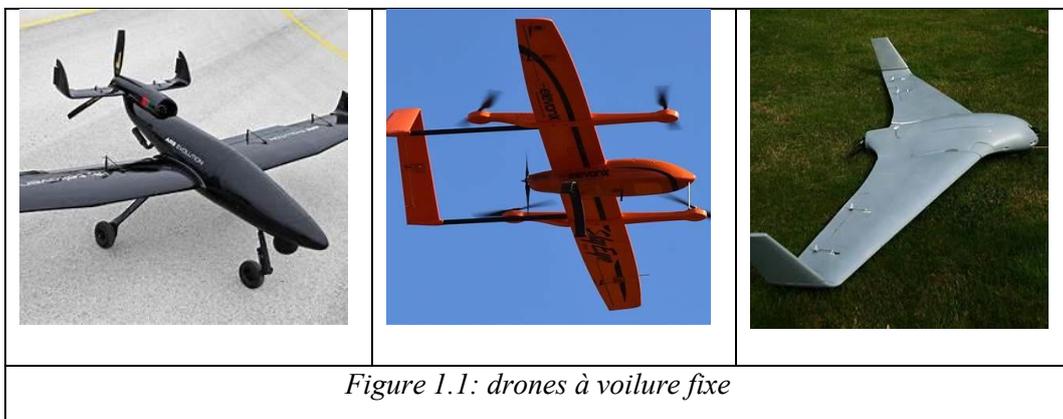


Figure 1.1: drones à voilure fixe

b) Drone à aile battante

Inspirée de la biomécanique des insectes comme le présente la Figure 1.2, cette famille de drones utilise un système de propulsion à ailes battantes. Cette architecture permet d'obtenir un vol stationnaire stable et une agilité de manœuvre comparable à celle des insectes. [13]

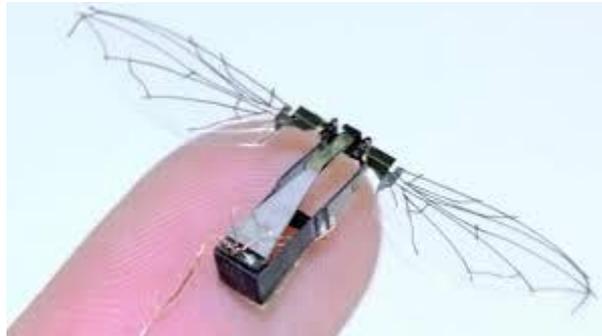


Figure 1.2: drone a aile battante [14]

c) Drone à voilure tournante

Les drones à voilures tournantes, offrent une capacité de décollage et d'atterrissage vertical, éliminant ainsi le besoin d'infrastructure de piste. Leur architecture de propulsion, basée sur des rotors multiples, permet un vol stationnaire précis et un vol à basse vitesse et basse altitude. La configuration de ce drone varie en fonction du nombre de rotors, influençant directement leurs performances en termes de portance, de manœuvrabilité et d'autonomie [13].

Nous pouvons alors classer les drones à voilure tournante en quatre catégories

- Les mono-rotors
- Les birotors
- Les tri-rotors
- Les rotors multiples

➤ Les mono-rotors

Les mono-rotors sont équipés d'un rotor principal qui assure leur décollage et leur atterrissage comme l'exemple montré dans la Figure 1.3. Ils se déclinent en trois sous-catégories, définies en fonction de la configuration adoptée pour contrôler leurs déplacements sur les différents axes (translation et rotation) et pour compenser l'effet du couple de réaction généré par le rotor principal. [13]



Figure 1.3: Drone mono-rotor

➤ **Les birotors**

Les birotors contrarotatifs sont équipés de deux rotors tournant en sens opposé à une vitesse identique. Ils se déclinent en trois sous-catégories, en fonction de la configuration adoptée pour assurer les déplacements du drone sur ses différents axes. [13]

- Les birotors à pas cyclique et collectif
- Les birotors augmentés d'une ou plusieurs hélices.
- Les birotors utilisant des volets.

La Figure 1.4 présente quelques exemples de drones birotors

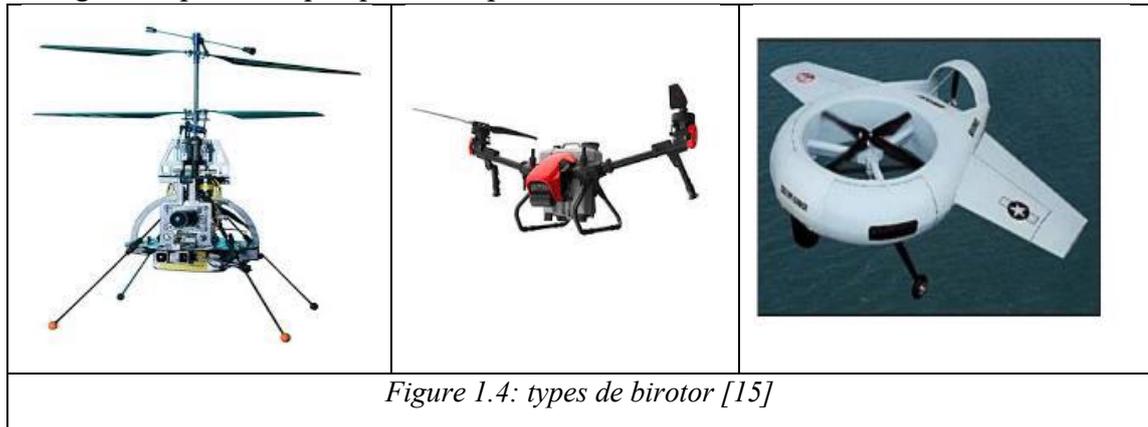


Figure 1.4: types de birotor [15]

➤ **Les tri-rotors**

Ils sont équipés de deux rotors avant tournant en sens opposé pour ajuster le tangage, ainsi que d'un rotor arrière permettant de contrôler le roulis, Comme illustré dans la Figure 1.5. Leur fonctionnement s'apparente à celui d'un quadrirotor, bien que leurs performances en vol soient moins optimales. [13]



Figure 1.5: drone tri-rotor [16]

➤ **Les rotors multiples**

Ces robots volants sont le plus souvent dotés de quatre rotors, bien que certaines variantes en possèdent six ou même huit, on peut observer dans la Figure 1.6 quelques exemples de ce type. [13]



d) Drone hybrides

Ces versions hybrides combinent les avantages des modèles à voilure fixe (temps de vol plus long) avec ceux des modèles à rotors (capacité de vol stationnaire), comme illustré dans la Figure 1.7 Ce concept a été testé depuis les années 1960 sans grand succès. Cependant, avec l'apparition de capteurs de nouvelle génération (gyroscopes et accéléromètres), il a connu un nouvel élan et une orientation plus prometteuse.



Figure 1.7: Drone hybride

1.2.2. Classification selon la taille et le poids

Les drones peuvent être classés selon leur taille et leur poids, des critères influençant leur autonomie, leurs performances et leurs applications. Dans cette catégorie on distingue quatre types de drones.

a) Petits drones

Aussi appelés micro-drones, ces petits drones mesurent entre 1 cm et 50 cm et ont un poids généralement inférieur à 250 g. Leur petite taille leur permet d'exécuter des missions spécifiques que les drones plus grands ne peuvent pas réaliser. Parmi eux, on distingue les nano-drones (< 15 cm, < 50 g)

b) Mini drones

Ces drones sont légèrement plus grands que les micro-drones, avec une taille comprise entre 50 cm et 2 m et un poids allant de 250 g à 25 kg

c) Drones moyens

Ils ressemblent à des avions miniatures et ont une taille supérieure à 2 m, avec un poids d'environ 25 kg à 200 kg. Ces drones, plus légers que les avions

d) Grands drones

Ces drones lourds ont une envergure similaire à celle des avions, avec un poids supérieur à 200 kg et une taille qui peut dépasser 10 m.

On peut définir ce mode de classification selon le schéma spectral dans la Figure 1.8

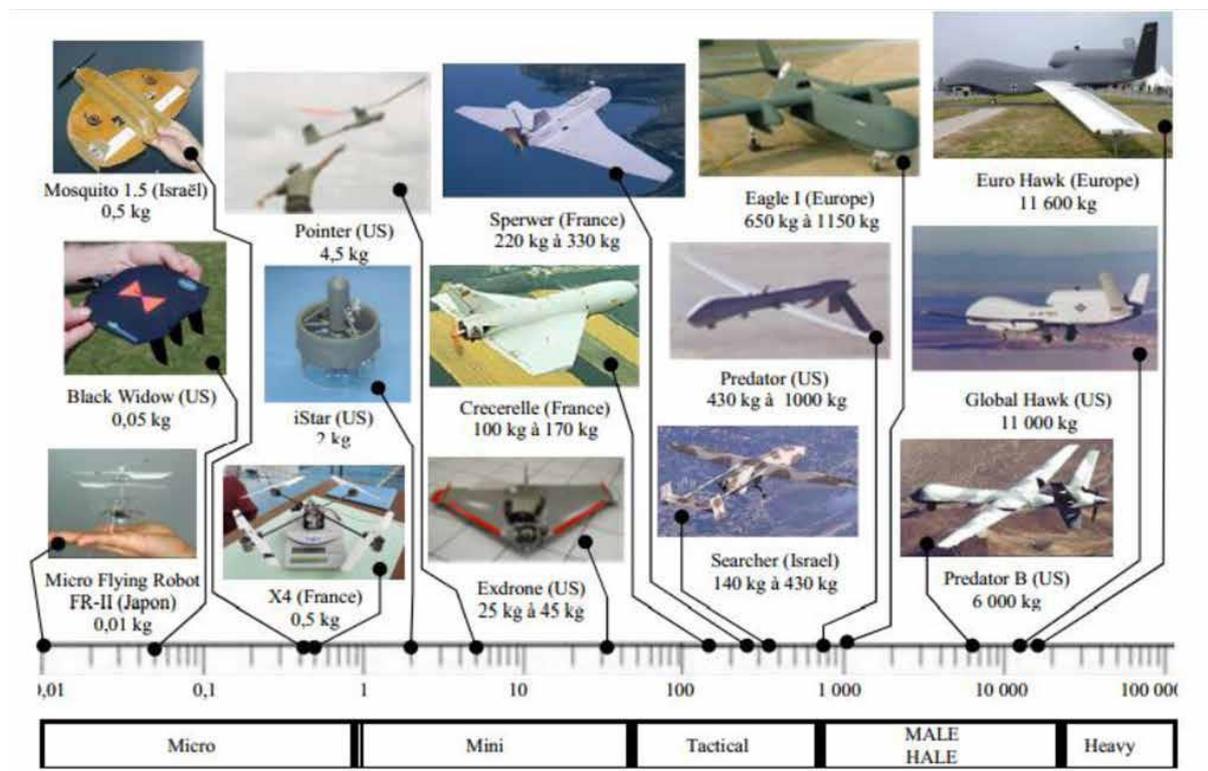


Figure 1.8: spectre de masse des différents drones selon le classement américain

1.2.3. Classification selon l'autonomie

Les drones peuvent être classés en fonction de leur niveau d'autonomie, qui détermine leur capacité à exécuter des tâches. Cette classification comprend :

a) Drones à contrôle manuel :

Ces drones nécessitent une intervention humaine constante pour piloter leur vol et prendre des décisions. [17]

b) Drones semi-autonomes :

Capables d'exécuter certaines tâches de manière indépendante, ces drones peuvent, par exemple, maintenir une position stationnaire, suivre des points de passage GPS ou éviter des obstacles. [17]

c) Drones autonomes :

Fonctionnant avec une intervention humaine minimale, ces drones peuvent réaliser des missions complexes telles que la cartographie, l'inspection ou le suivi d'objets en mouvement. [17]

d) Drones en essaim :

Ces drones opèrent en groupe de manière coordonnée en communiquant entre eux pour accomplir des tâches collectives. Ils peuvent être semi-autonomes ou entièrement autonomes. [17]

1.2.4. Classification selon la portée

Les drones peuvent être classés selon leur portée en plusieurs catégories principales qui sont résumés dans le Tableau 1.1 et la Figure 1.9

Catégorie	Portée [Km]	Exemples
Courte portée	<5	DJI Mavic Mini Parrot Anafi
Moyenne portée	5-50	DJI Matrice 300, Elbit Skylark II
Longue portée	50-200	Boeing Insitu ScanEagle, Bayraktar TB2
MALE	200-1000	General Atomics MQ-9 Reaper, Bayraktar Akinci
HALE	>1000	Northrop Grumman RQ-4 Global Hawk, Airbus Zephyr

Tableau 1.1: Types des drones selon la portée

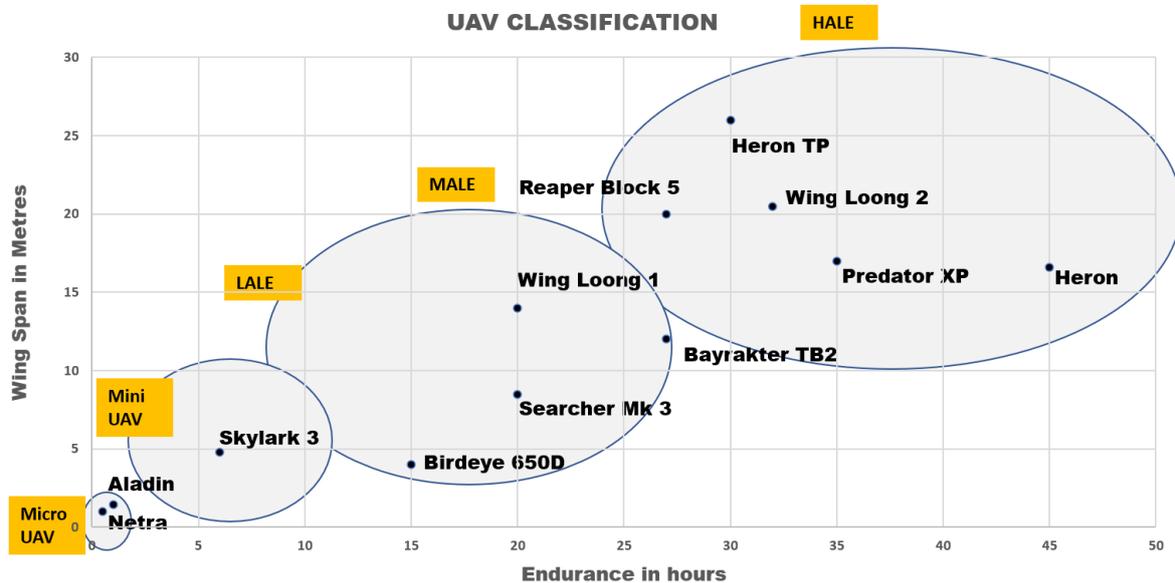


Figure 1.9: classification des drones selon l'endurance [18]

1.3. Domaines d'applications :

Les drones ont connu une évolution remarquable, passant d'outils militaires stratégiques à des solutions technologiques intégrées dans divers secteurs civils [1] grâce à leur polyvalence, leur efficacité et leur capacité à effectuer des tâches complexes avec précision.

1.3.1. Applications militaires

Historiquement, les drones ont été développés pour répondre aux besoins des forces armées, sont désormais des outils stratégiques en surveillance, reconnaissance et engagement tactique, optimisant les opérations.

- **Guerre électronique** : Intelligence électronique, brouillage et destruction des systèmes radar ennemis [19].
- **Communication et relais de signaux** : Transmission de données et extension des capacités de communication sur le champ de bataille. [20]
- **Surveillance et reconnaissance** : Observation des flottes ennemies, identification de cibles et collecte d'informations stratégiques. [21]
- **Opérations offensives et défensives** : Désignation et suivi des cibles, élimination de bombes non explosées, et leur rage de missiles par émission de signatures artificielles. [21]

1.3.2. Applications civiles

- **Topographie et cartographie** : Surveillance aérienne pour les recherches géographiques et la modélisation 3D des terrains [22]. La Figure 1.10 montre un exemple d'utilisation réelle.



Figure 1.10: cartographie par drone

- **Agriculture de précision** : Pulvérisation et surveillance agricole pour optimiser la gestion des cultures et améliorer les rendements. [23]
- **Recherche et secours** : Intervention rapide en cas de catastrophes naturelles, recherche de personnes disparues et opérations de sauvetage. [24]
- **Lutte contre les incendies** : Détection et suivi en temps réel des incendies de forêt pour améliorer les stratégies d'extinction. [25]

- **Sécurité et contrôle des frontières** : Surveillance des importations illégales et détection d'activités suspectes. [25]
- **Protection de l'environnement** : Études de pollution, surveillance des terres et suivi des changements climatiques. [25]
- **Inspection des infrastructures** : Évaluation de l'état des pipelines, lignes électriques et autres infrastructures critiques. [26]
- **Industrie pétrolière et énergétique** : Exploration et surveillance des sites d'extraction de pétrole et de gaz. [27]
- **Logistique et transport** : Livraison de colis dans des zones difficiles d'accès, notamment par des entreprises de commerce électronique. [28]

1.3.3. Les impacts négatifs des drones

Malgré leurs nombreux avantages, les drones peuvent également être utilisés à des fins malveillantes, représentant ainsi une menace pour la vie privée, la sécurité et l'ordre public.

- **Atteinte à la vie privée**

Les drones équipés de caméras haute résolution peuvent être utilisés pour surveiller ou espionner des individus sans leur consentement. Ils peuvent capturer des images ou des vidéos à leur insu, ce qui représente une menace pour la confidentialité des données personnelles [29]

- **Risques pour la sécurité aérienne**

- **Collisions aériennes** : Les drones mal pilotés ou non conformes aux réglementations peuvent entrer en collision avec des avions, des hélicoptères ou d'autres objets volants, mettant en danger la navigation aérienne.
- **Perturbation des opérations aéroportuaires** : La présence de drones à proximité des aéroports peut entraîner des retards et des annulations de vols, perturbant ainsi le transport aérien.

- **Utilisation malveillante et criminelle**

- **Espionnage et cybercriminalité** : Certains drones sont utilisés pour voler des données sensibles en interceptant des signaux Wi-Fi ou en accédant à des zones restreintes.
- **Trafic illégal** : Les criminels exploitent les drones pour transporter des marchandises illicites, comme de la drogue ou des armes, en échappant aux contrôles traditionnels. [30]
- **Attaques terroristes** : ils peuvent être armés ou utilisés pour transporter des explosifs, représentant ainsi un danger potentiel pour la sécurité nationale.

❖ Le Tableau 1.2 présente des exemples réels d'utilisations illégales des drones

Type d'utilisation illégale	Pays	Exemple réel
Espionnage et menaces à la sécurité nationale	France (2014)	Survol de 13 centrales nucléaires françaises par des drones non identifiés. Un rapport remis au gouvernement met en garde contre les risques sécuritaires liés à ces survols.
	Royaume-Uni (2018)	Des vols illégaux de drones au-dessus de l'aéroport de Gatwick ont provoqué l'annulation de centaines de vols et perturbé des milliers de passagers
Menace pour la sécurité aérienne	Europe (2016)	L'EASA recense 1400 incidents impliquant des drones, certains accidentels, d'autres malveillants ou terroristes.
	Colombie → Panama (2011)	Les narcotrafiquants utilisent des drones pour transporter jusqu'à 10 kg de cocaïne par voyage.
Trafic illégal	Mexique → États-Unis (2015)	Un drone transportant 3 kg de méthamphétamines s'écrase à la frontière. [31]
	France (2017)	Drones utilisés pour livrer des téléphones portables et des colis en prison (Valence, Villefranche-sur-Saône, Rennes-Vezin, Grasse).
	Irak, Syrie (2015-2020)	Des groupes terroristes ont utilisé des drones armés pour attaquer des positions militaires et des infrastructures civiles.
Attaques terroristes	Vénézuéla (2018)	Tentative d'assassinat du président Nicolás Maduro à l'aide de drones explosifs lors d'un rassemblement public. [32]
	Tableau 1.2: Exemples d'utilisations illégal des drones	

1.4. Les méthodes de détection

Ces dernières années, l'utilisation des drones a considérablement augmenté, faisant d'eux une menace potentielle entre les mains d'un ennemi. Cependant, leur détection fiable reste un défi complexe, nécessitant des efforts considérables.

Il existe diverses techniques de détection des drones, chacune présentant des avantages et des inconvénients. Leur efficacité dépend du contexte d'application, certaines étant mieux adaptées que d'autres selon les conditions d'utilisation. C'est pourquoi, dans la plupart des cas, plusieurs techniques sont combinées afin d'améliorer la précision et la fiabilité de la détection.

1.4.1. Détection RADAR

Les systèmes radar sont couramment utilisés aussi bien dans la vie quotidienne que dans les applications militaires. Cependant, les radars conventionnels sont principalement conçus pour détecter des objets de grande taille, ce qui les rend peu adaptés à l'identification de petits drones

(voir la Figure 1.11), en particulier lorsque ceux-ci se déplacent à faibles vitesses ou à basse altitude. [33]

Dans le cadre des systèmes de défense contre les drones (SDDD), la technologie radar constitue une méthode active permettant d'identifier et de localiser une menace potentielle posée par un UAV. Elle est utilisée pour déterminer des paramètres clés tels que la portée, l'angle ou la vitesse d'un UAV.



Figure 1.11: système de détection de drones par RADAR

1.4.2. Détection Radio Fréquence

La détection RF des UAV repose sur l'interception et l'analyse des signaux échangés entre le drone et sa station de contrôle au sol. Ces transmissions incluent généralement la liaison montante (par la station sol), ainsi que la liaison descendante (par le drone), qui véhicule des données telles que la position et le retour vidéo [33]. On peut voir l'exemple présenté dans la Figure 1.12



Figure 1.12: système de détection de drones Radio Fréquence [34]

L'application de techniques d'apprentissage automatique à ces données RF est encore récente. De plus, la littérature ne dispose pas encore d'un jeu de données public exhaustif permettant la validation et la comparaison des modèles. Par conséquent, les méthodes existantes présentent des performances limitées, notamment lorsque le rapport signal/bruit est faible

1.4.3. Détection optique

La détection optique repose sur l'utilisation de caméras pour capturer des images d'une zone spécifique en vue d'identifier la présence d'un drone cible. Cette approche exploite différents types de capteurs, notamment les caméras électro-optiques (EO) et infrarouges (IR), afin d'obtenir des informations visuelles détaillées.

a. Caméras électro-optiques (EO)

Certains systèmes de défense contre les drones (SDDD) intègrent des capteurs EO/IR, souvent couplés à d'autres technologies comme le radar ou la détection RF, pour améliorer la précision de l'identification. Ces capteurs permettent d'obtenir des images du drone et de ses caractéristiques principales, telles que sa charge utile. Ces images peuvent être enregistrées et analysées par des experts pour évaluer le niveau de menace qu'il représente. [35]

b. Caméras infrarouges / thermiques (IR)

Les caméras infrarouges thermiques détectent la chaleur émise par les composants du drone, notamment ses moteurs, batteries et processeurs. Cette technologie permet d'identifier un drone en fonction de sa signature thermique, ce qui peut être particulièrement utile dans des conditions où l'imagerie visible est moins efficace. [35]

1.4.4. Détection acoustique

Un drone en vol génère un bruit caractéristique par les rotors et les hélices pouvant être capté par des capteurs acoustiques, tels que des microphones. [33] Ce signal sonore peut ensuite être analysé à l'aide de diverses techniques afin d'identifier l'empreinte acoustique propre à chaque drone.

L'objectif idéal est de reconnaître le modèle du drone, voire d'identifier un appareil spécifique en fonction de son empreinte audio. De manière générale, la détection acoustique des drones repose soit sur des méthodes basées sur la corrélation et l'autocorrélation, soit sur des approches utilisant l'apprentissage automatique pour la classification des signaux. On simplifie avec le schéma de la Figure 1.13

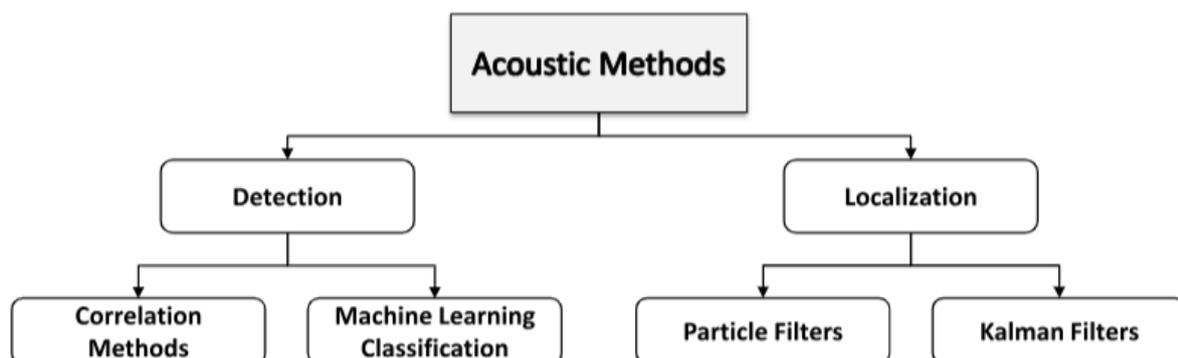


Figure 1.13: Schéma synoptique de la méthode de détection acoustique [33]

1.5. Limitations et performances des méthodes de détection

Bien que plusieurs techniques existent pour la détection des drones, chacune présente des avantages et des inconvénients en fonction du contexte d'utilisation. On résume ça dans le Tableau 1.3

Méthode de détection	Avantages	Inconvénients
RADAR	<ul style="list-style-type: none"> • Large couverture spectrale (3 MHz - 300 GHz). • Fonctionne quelles que soient les conditions météorologiques et de l'ambiance acoustique. • Peut identifier les objets en mouvement grâce à l'effet Doppler. 	<ul style="list-style-type: none"> • Besoin d'un radar de grande taille et d'une infrastructure coûteuse. • Moins performant pour différencier les drones des petits objets volants (oiseaux, débris). • Performances limitées à basse altitude et faible vitesse de vol.
Radio Fréquence	<ul style="list-style-type: none"> • Capte et analyse les communications entre le drone et sa station de contrôle. • Facile à mettre en œuvre avec une faible complexité. • Adaptable grâce à des algorithmes avancés de traitement du signal. 	<ul style="list-style-type: none"> • Vulnérable aux signaux RF cryptés ou modifiés, ce qui réduit son efficacité. • Moins performant dans les environnements urbains en raison des interférences électromagnétiques.
Optique	<ul style="list-style-type: none"> • Capable de détecter dans le spectre visible et infrarouge (3 MHz - 300 GHz). • Fonctionne efficacement dans des conditions météorologiques favorables. • Fournit des informations visuelles détaillées. 	<ul style="list-style-type: none"> • Ne fournit que des images 2D, ce qui peut limiter l'interprétation. • Sensibilité aux conditions météorologiques défavorables (brouillard, pluie, faible luminosité). • Dépend fortement de la qualité des capteurs et de l'angle de prise de vue.
Acoustique	<ul style="list-style-type: none"> • Couvre une large gamme de fréquences (20 Hz - 20 kHz). • Permet la création d'une bibliothèque de signatures acoustiques réutilisables. • Léger, simple à installer et compatible avec d'autres capteurs. 	<ul style="list-style-type: none"> • Portée de détection limitée. • Sensible aux bruits ambiants et aux interférences sonores. • Nécessite une base de données acoustiques bien fournie pour une identification précise.

Tableau 1.3: Les avantages et les inconvénients des différents systèmes de détection [33]

1.6. Détection Acoustique en Milieu Urbain

L'application de la détection acoustique des drones en environnement urbain soulève plusieurs défis en raison de la complexité du paysage sonore [36]. Contrairement aux milieux ouverts où le bruit de fond est relativement faible, les zones urbaines sont caractérisées par une multitude de sources sonores parasites qui compliquent l'identification des signatures acoustiques des drones, tel que :

- **Le trafic routier** : moteurs, klaxons.
- **Son de la nature** : sons produits naturellement, sans intervention humaine tels que : les oiseaux, souffle de vent, tonnerre.
- **Les infrastructures industrielles** : chantiers de construction, machines et générateurs.
- **Les activités humaines** : conversations, sirènes, musique et autres signaux sonores urbains.

➤ **Défis de l'Extraction du Signal Acoustique des Drones**

L'isolation d'un signal exploitable (son de drone) dans un environnement acoustiquement saturé constitue un défi considérable. Plusieurs éléments impactent ce processus, notamment :

- **La variabilité des signatures acoustiques** : L'intensité et la fréquence du son des drones varient en fonction du modèle, de la charge utile et du régime moteur.
- **L'atténuation et la dispersion du son** : en milieu urbain, la propagation des ondes sonores est altérée par la présence d'obstacles qui provoquent échos et diffractions.
- **Effet Doppler** : le mouvement du drone par rapport au récepteur provoque un décalage de fréquence ($f_r = f_0 + \Delta f$), ce qui complique l'analyse du spectre acoustique en modifiant les fréquences perçues.
- **Le faible volume sonore des drones** : au-delà d'une certaine distance, le bruit du drone devient difficile à distinguer des autres sons environnants.

Pour pallier ces difficultés, des techniques avancées de traitement du signal sont utilisées, afin d'améliorer la séparation du signal drone des bruits parasites, telles que :

- **L'analyse des caractéristiques spectrales**
- **Les modèles d'apprentissage automatique**
- **Les réseaux neuronaux profonds**

Cependant, la mise en œuvre de ces méthodes nécessite la constitution d'une base de données acoustique adaptée aux environnements urbains. La variabilité des conditions sonores et la diversité des types de drones rendent indispensable l'utilisation de modèles de classification robustes et adaptatifs.

1.7. Conclusion

Ce chapitre met en avant la variété des véhicules aériens sans pilote (UAV) en explorant leur classification selon divers critères tels que la taille, le poids, le type de structure aérodynamique ou d'ailes, ainsi que leur portée et degré d'autonomie. Cette analyse souligne la diversité des applications des UAV dans les domaines civil et militaire. Par la suite, l'accent est mis sur les enjeux de sécurité et les défis liés à cette technologie, mettant en évidence la nécessité d'y apporter des solutions pour favoriser leur acceptation et leur intégration dans différents secteurs. De plus, le chapitre examine les différentes méthodes de détection des UAV, en mettant en lumière leurs avantages et leurs limites. Une attention particulière est portée sur la détection acoustique en milieu urbain, en raison des défis spécifiques posés par cet environnement, notamment le bruit ambiant et les interférences.

Cette revue approfondie permet d'illustrer la complexité et l'adaptabilité des systèmes de surveillance des drones. En définitive, bien que les UAV offrent des opportunités considérables dans de nombreux domaines, il est primordial d'aborder les préoccupations en matière de sécurité et d'optimiser les technologies de détection – en particulier la détection acoustique – afin d'améliorer leur efficacité et de garantir leur intégration sûre et maîtrisée.

Chapitre 2 : Les Arbres De Décision

2. Les arbres de décisions

Introduction

L'intelligence artificielle (IA) est un domaine interdisciplinaire, à la croisée de l'informatique et des mathématiques regroupant diverses méthodes algorithmiques et théories, se décompose en plusieurs sous-domaines comme représenté graphiquement dans la Figure 2.1 ; destinées à créer des machines capables d'imiter certaines formes d'intelligence humaine [37]. Son objectif principal est de reproduire des mécanismes de raisonnement, de décision ou d'apprentissage, afin de résoudre des problèmes complexes. Aujourd'hui en plein essor, l'intelligence artificielle trouve des applications variées dans des domaines aussi divers que la robotique, la santé ou encore les transports [38].

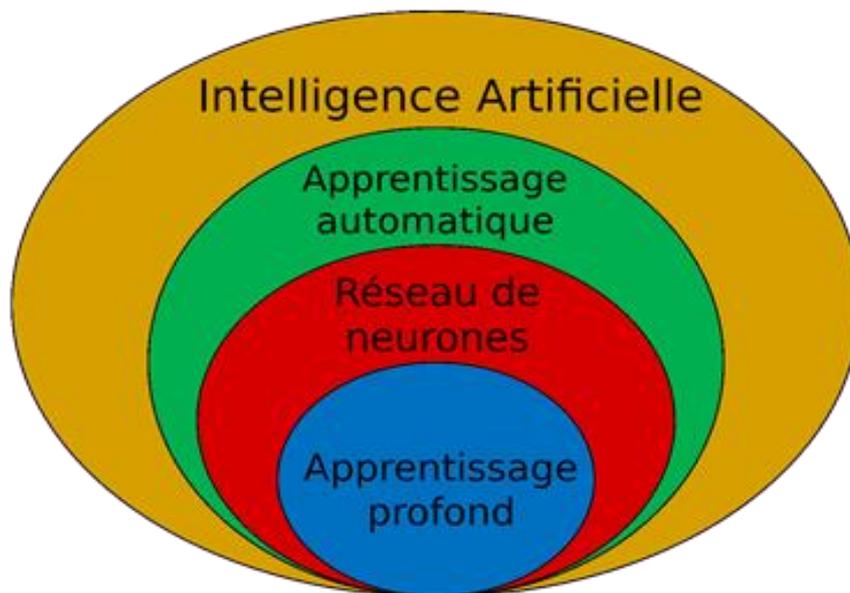


Figure 2.1: Schéma de décomposition du domaine de l'intelligence artificielle et de ces sous-domaines [37]

L'IA englobe, entre autres, les branches l'apprentissages automatique (Machine Learning) et l'apprentissage profond (Deep Learning) [39]. Ces techniques permettent aux machines d'apprendre à partir de données et de s'améliorer avec l'expérience, sans être explicitement programmées pour chaque tâche.

2.1. Apprentissage automatique

L'apprentissage automatique ou Machine Learning, peut être assimilé à l'apprentissage d'un jeune enfant dès la naissance pour reconnaître progressivement les objets et les sons en s'entraînant et en corrigeant ses informations et en répétant ce processus [40].

L'apprentissage automatique est considéré le sous-domaine le plus important de l'IA [40], il s'intéresse à la conception, à l'analyse, au développement et à l'implémentation de modèles permettant à une machine d'apprendre à partir de données, de manière systématique, dans le but d'accomplir une tâche précise.

Selon la nature des données disponibles et les objectifs de l'apprentissage, Il existe principalement quatre types d'apprentissage. La Figure 2.2 présente le schéma illustrant ces types.

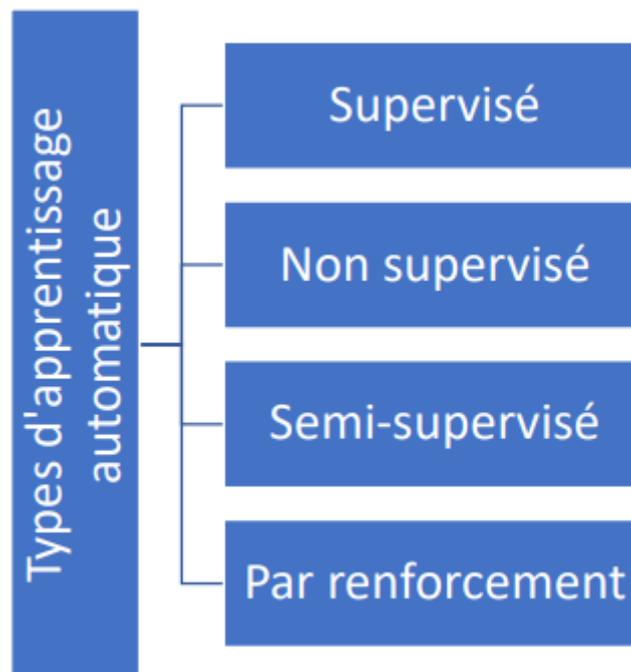


Figure 2.2: Types d'apprentissages en apprentissage automatique [41]

2.1.1. Apprentissage supervisé

Cette méthode consiste à utiliser des données d'entraînement étiquetées, c'est à dire dont on connaît la sortie voulue [37]. L'objectif est d'entraîner le modèle de manière à ce qu'il apprenne un mappage entre les entrées et les sorties en ajustant les paramètres pour minimiser l'erreur entre la sortie prédite et la sortie réelle. L'apprentissage supervisé est généralement utilisé pour la régression ou la classification.

2.1.2. Apprentissage non-supervisé

Dans ce cas la méthode consiste à utiliser des données ne sont pas étiquetées, L'algorithme peut utiliser des techniques comme le clustering ou la réduction de dimensionnalité pour identifier des relations sous-jacentes entre les données [37]. Cette méthode est donc destinée à révéler des motifs, des regroupements ou des structures intrinsèques.

2.1.3. Apprentissage par renforcement

L'apprentissage par renforcement est une méthode d'entraînement dans laquelle un système apprend à prendre des décisions en recevant des récompenses ou des punitions de son environnement, selon les actions qu'il effectue [37]. Il poursuit à maximiser les récompenses cumulées au fil du temps, en ajustant ses actions selon les retours reçus.

Plus que ces approches classiques, il existe également des méthodes semi-supervisé, qui combine à la fois les données étiquetées et non étiquetées, et les méthodes d'apprentissage en ligne, qui ajuste le modèle en temps réel avec de nouvelles données.

Ces systèmes de reconnaissance automatique reposent sur divers algorithmes capables d'analyser des données, de détecter des motifs et de prédire des résultats. Chaque algorithme

possède ses propres particularités, ce qui permet de les adapter selon le type de données ou la tâche à accomplir, Comme l'illustre la Figure 2.3 ci-dessous, exemple de ces algorithmes

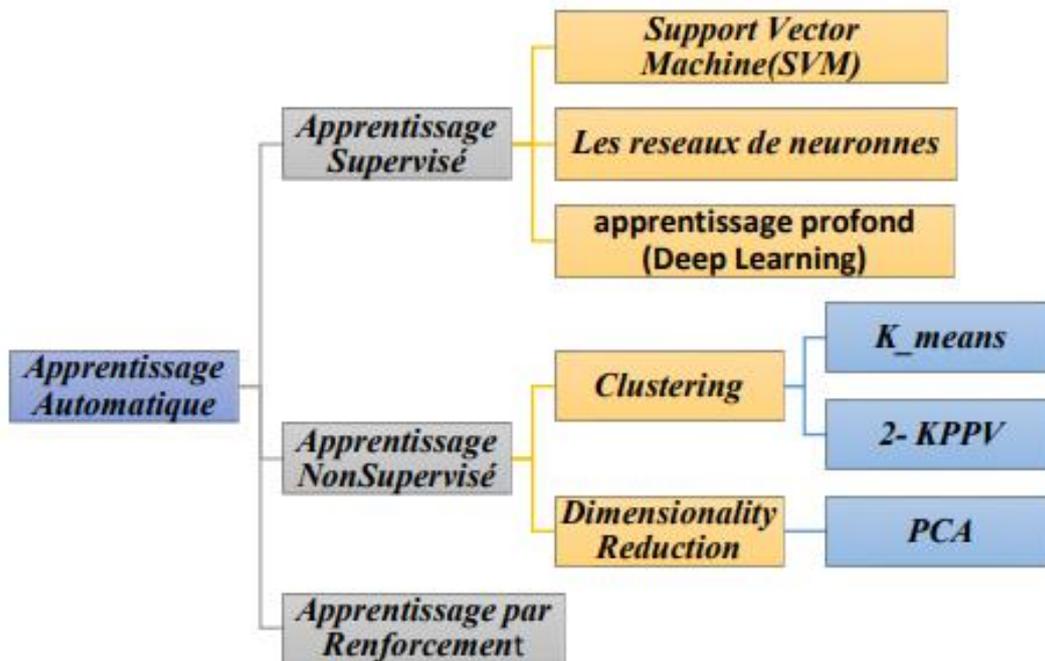


Figure 2.3:schéma représente quelques exemples d'algorithmes d'apprentissage automatique [41]

2.2 Apprentissage profond

Apprentissage profond (Deep Learning) est une sous-catégorie de ML, repose sur des architectures complexes de réseaux de neurones artificiels (voir la Figure 2.4). Contrairement au ML qui nécessite souvent une extraction manuelle des caractéristiques, le DP automatise cette étape grâce à des couches multiples capables d'extraire des représentations hiérarchiques des données.

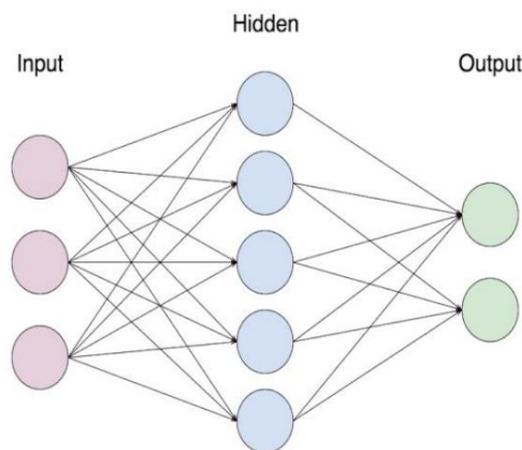


Figure 2.4: schéma générale d'un réseau de neurone [41]

Alors le Deep Learning englobe une variété des de réseaux de neurones, chacune conçue pour répondre à des types de données spécifiques et à des problématiques variées. Ces architectures exploitent la capacité des couches profondes à extraire automatiquement des représentations hiérarchiques. Parmi les architectures couramment utilisées, on distingue :

- **Réseaux de neurones convolutionnels (CNN)** : sont des modèles conçus pour traiter les images. Ils extraient automatiquement les éléments importants grâce à des couches de convolution et de pooling.
- **Réseaux de neurones récurrents (RNN)** : traitent des données séquentielles, telles que du texte ou des séries temporelles, en maintenant un état caché qui capture l'information précédente.
- **Réseaux à mémoire longue à court terme (LSTM)** : un type de RNN qui atténue le problème des gradients qui disparaissent, permettant une meilleure gestion des dépendances à long terme.
- **Réseaux antagonistes génératifs (GAN)** : composés d'un générateur et d'un discriminateur qui s'affrontent pour produire des données synthétiques réalistes, souvent utilisés pour la génération d'images et le transfert de style.

2.3. L'application de AI pour la détection acoustique

L'intelligence artificielle révolutionne aujourd'hui la gestion des environnements sonores grâce à des solutions innovantes capables de détecter, filtrer et identifier les sources acoustiques avec une grande précision [42]. En s'appuyant sur des techniques d'apprentissage automatique (Machine Learning) et d'apprentissage profond (Deep Learning), il devient désormais possible d'isoler les empreintes acoustiques pertinentes au sein d'un paysage sonore complexe, même en présence de bruit ou de distorsions [43].

Cette capacité de l'IA intervient à plusieurs niveaux du processus de filtrage et d'amélioration de la robustesse de ces empreintes, tel que :

- **Prétraitement et débruitage** : Les réseaux de neurones, entraînés sur des données bruitées et propres, suppriment efficacement le bruit tout en conservant les éléments essentiels du signal, améliorant ainsi la qualité des empreintes.
- **Extraction de caractéristiques** : L'IA optimise l'utilisation de techniques comme la FFT et les spectrogrammes pour extraire des caractéristiques robustes, renforçant la fiabilité des empreintes face aux perturbations.
- **Filtrage conditionnel** : Des systèmes de machine Learning, utilisent un échantillon de référence pour isoler un son spécifique dans un mélange complexe, même en environnement bruyant.

Cela offre des bénéfices considérables, en termes de robustesse et l'adaptabilité [43], notamment via le Deep Learning appliqué aux signaux acoustiques, est aujourd'hui une solution efficace et innovante pour la détection et la surveillance des drones.

2.4. Les Arbres de Discision

Les arbres de décision en Machine Learning sont des modèles supervisés prédictifs utilisés pour résoudre des problèmes de classification et de régression [44]. Cette technique de classification organise les données sous forme d'une structure arborescente (comme la montre la Figure 2.5), en divisant les données selon les critères spécifique. Pour illustrer de manière claire cette approche, il convient de s'intéresser à son architecture qui est structurée sous forme hiérarchique : nœuds, branches et feuilles.

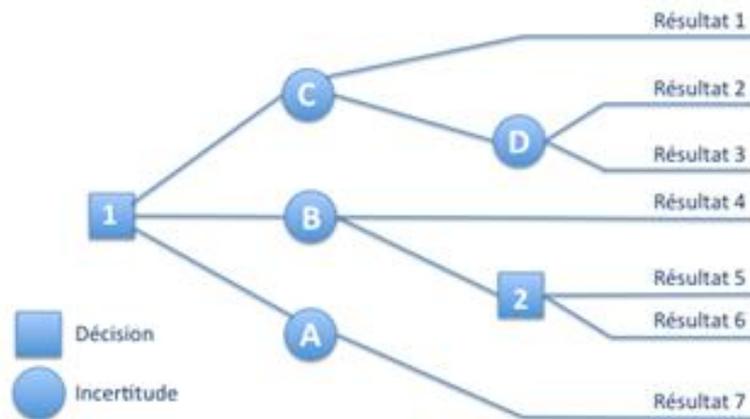


Figure 2.5: Exemple d'un Arbre de Décision

2.4.1. Architecture des arbres des décision

a. Nœuds racines (Root Node) :

Constituant les entrées de l'arbre, ils présentent le premier teste à effectuer sur une variable d'entrée.

b. Nœuds internes (Internal Node) :

Chaque nœuds interne correspond à un test ou condition sur un attribut [45], réalisant des opérations intermédiaires [46].

c. Branches (Edges) :

Relient les nœuds et représentent les résultats possibles des tests

d. Feuilles (Leaf Node) :

Les feuilles constituent les extrémités de l'arbre, désignent les prédictions ou les résultats finaux (classe ou valeur numérique)

La Figure 2.6 résume de manière graphique cette structure.

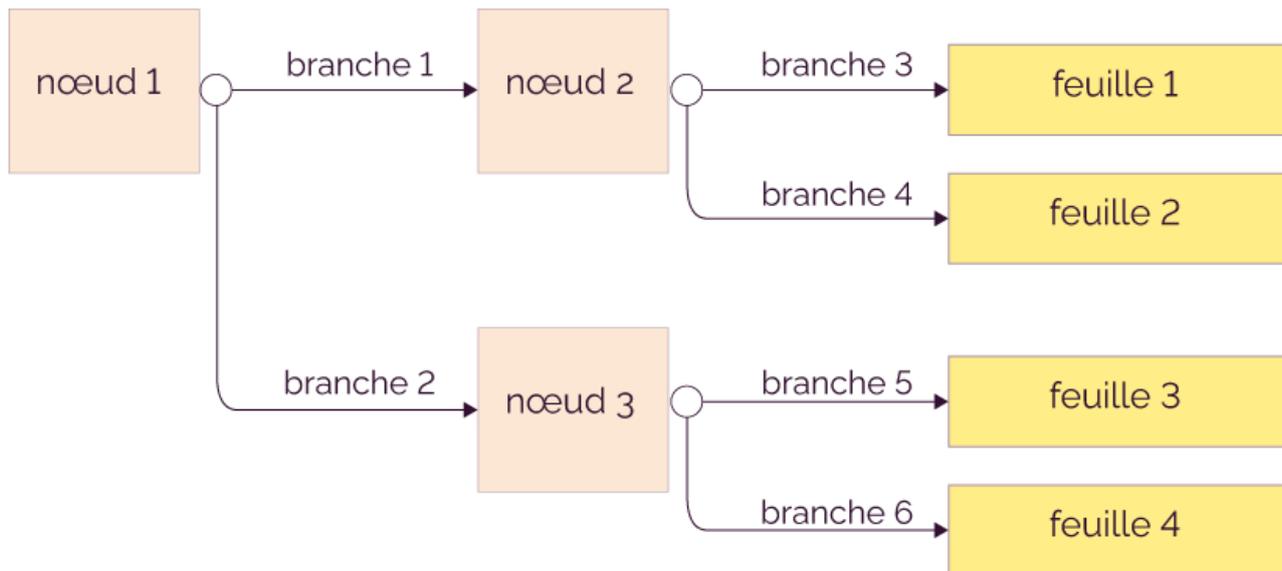


Figure 2.6: Exemple d'Architecture d'un Arbre de Décision [47]

2.4.4. Avantages et limites

Les arbres de décision présentent plusieurs avantages notables :

- **Facilité d'interprétation** : la structure hiérarchique et la logique booléenne des arbres de décision rendent leur compréhension plus facile, en permettant d'identifier rapidement les attributs clés.
- **Exécution rapide** : adaptée aux systèmes temps réel
- **Aucun paramétrage complexe requis** : ils s'adaptent automatiquement aux données sans nécessiter de connaissances spécifiques
- **Capacité à gérer des données mixtes** : ils manipulent à la fois les données catégorielles et numériques

Toutefois, cette méthode présente aussi certains inconvénients :

- **Sensibilité au bruit** : Une donnée erronée ou bruitée peut influencer de manière disproportionnée la structure de l'arbre.
- **Risque de surapprentissage (surajustement)** : Le surapprentissage survient lorsque l'arbre devient trop complexe, ce qui nuit à sa capacité à généraliser correctement sur de nouvelles données. [48]
- **Moins performants sur des tâches complexes** : Les arbres de décision peuvent être moins efficaces sur des tâches nécessitant des décisions plus nuancées ou complexes. [48].

2.4.4. La justification de choix des arbres de décision

Dans le contexte de la détection acoustique des drones, les arbres de décision ont été choisis en raison de plusieurs avantages adaptés à cette tâche. Leur simplicité et leur structure explicite facilitent la compréhension du processus de classification, ce qui est essentiel pour analyser et justifier la détection de drones à partir de signaux sonores. De plus, ils permettent un traitement rapide, ce qui est favorable pour une utilisation en temps réel dans des systèmes de surveillance.

Les arbres de décision sont également capables de traiter des données à grande dimension, comme les multiples caractéristiques extraites des signaux audio (fréquence, intensité, durée, etc.). Cela en fait un outil pratique pour gérer la richesse acoustique produite par différents types de drones.

Cependant, l'environnement urbain présente des défis notables, sensibilités au bruit et un risque de surapprentissage, notamment lorsque les sons captés incluent de nombreuses perturbations et aussi une capacité parfois insuffisante à généraliser sur des données complexes. Pour pallier ces faiblesses, plusieurs méthodes d'ensemble ont été développées, notamment :

- **Forêts aléatoires (Random Forest) :** Combinaison de plusieurs arbres construits sur des sous-échantillons aléatoires, permettant de réduire la variance et d'améliorer la robustesse.
- **Boosting (Gradient Boosting, XGBoost) :** Construction séquentielle d'arbres corrigeant les erreurs des précédents, ce qui diminue le biais et accroît la précision [49].
- **Bagging :** Apprentissage sur plusieurs échantillons de données tirés avec remise, favorisant la diversité des arbres et la stabilité du modèle. [49]

2.5. Utilisation des arbres de décisions pour la détection acoustique des drones

La détection acoustique des drones peut être effectuée en utilisant les arbres de décision pour la classification des sons, et cette application repose sur les étapes classiques de l'apprentissage automatique adaptées aux particularités du traitement du signal. Ces étapes peuvent être synthétisées comme suit :

1. Collecte des données :

Il est nécessaire de rassembler des données d'entraînement provenant de différentes sources, en veillant à ce qu'elles soient bien représentatives du problème à traiter.

2. Prétraitement des données :

Les données doivent être prétraitées en nettoyant les signaux, en normalisant les amplitudes et en extrayant les segments pertinents tout en supprimant les bruits ou silences inutiles.

3. Extraction de caractéristiques :

En appliquant des techniques comme la FFT, les spectrogrammes ou les MFCC pour transformer les signaux bruts en vecteurs de caractéristiques utilisables par le modèle.

4. Séparation des données :

Généralement les données sont divisées en ensembles d'apprentissage (training) et de validation/test pour entraîner et évaluer le modèle.

5. L'entraînement de modèle (arbres de décision) :

Exploiter les vecteurs de caractéristiques pour entraîner le modèle pour être capable de classer les données à l'aide de règles décisionnelles.

6. Évaluation des performances :

Dans le cadre de l'utilisation d'AI ; dans notre cas l'utilisation des arbres de décision l'évaluation des performances est essentielle pour vérifier la fiabilité du modèle. Elle repose sur des mesures classiques de classification notamment :

- ❖ **Précision (Accuracy)** : indique le pourcentage de bonnes prédictions parmi l'ensemble des cas.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad \text{Equation (1)}$$

Avec :

- **TP (True Positives)** : Nombre de sons de drones correctement détectés comme drones.
- **TN (True Negatives)** : Sons non drones correctement identifiés comme tels.
- **FP (False Positives)** : Sons non drones incorrectement classés comme drones.
- **FN (False Negatives)** : Sons de drones non détectés.

- ❖ **Rappel (Recall)** : mesure la capacité du modèle à retrouver tous les cas positifs

$$Recall = \frac{TP}{TP + FN} \quad \text{Equation (2)}$$

- ❖ **Précision au sens strict (Precision)** : évalue la part des sons détectés comme drones qui le sont réellement.

$$Precision = \frac{TP}{TP + TF} \quad \text{Equation (3)}$$

- ❖ **F1-score** : combine précision et rappel pour donner une vision équilibrée de la performance.

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad \text{Equation(4)}$$

7. Utilisation de modèle :

Une fois validé, l'arbre de décision peut être appliqué pour détecter ou reconnaître des nouvelles données des enregistrements.

2.6. Conclusion :

Dans ce chapitre, nous avons présenté un panorama général de l'intelligence artificielle, en mettant l'accent sur l'apprentissage automatique (Machine Learning) et l'apprentissage profond (Deep Learning), tout en soulignant leur rôle clé dans le domaine de la détection acoustique et de la reconnaissance des empreintes acoustiques.

Nous avons ensuite recentré l'étude sur la méthode choisie dans notre projet : les arbres de décision, où on a détaillé leur fonctionnement, leur architecture, leurs avantages et limites, de même que les raisons pour lesquelles nous les avons choisies dans notre travail. Nous avons présenté aussi quelques techniques d'amélioration des arbres de décision et décrit leur mise en œuvre dans la détection acoustique. Cela justifie leur emploi comme solution raisonnablement adaptée à nos objectifs.

Chapitre 3 : Etude Acoustique des Drones

3. Etude acoustique des drones

Introduction

L'étude acoustique des drones s'appuie sur l'analyse détaillée des sons émis par ces appareils, sont effectivement lié à son fonctionnement mécanique, notamment au moteur et aux hélices, ce qui lui confère une signature acoustique spécifique. Cette signature sonore est composée de bruits aérodynamiques et mécaniques générés par la rotation des hélices et le fonctionnement des moteurs [50]. Chaque drone a donc une empreinte acoustique caractéristique, bien que cette signature puisse varier selon la conception des hélices et le type de moteur.

Cependant, cette signature acoustique n'est pas toujours unique de manière absolue, car certains drones peuvent avoir des sons similaires, ou elle peut néanmoins être atténuée ou masquée dans certaines conditions. En effet, des facteurs tels que le bruit, la distance, ou certains innovations – telles que les hélices toroïdales – peuvent réduire la clarté et la portée de cette empreinte sonore. [51]

3.1. Définition de l'empreinte acoustique

Dans le contexte des drones, l'empreinte acoustique correspond à l'ensemble des caractéristiques sonores propres au signal qu'il émet, notamment les composantes fréquentielles (fondamentales, harmoniques), les amplitudes, et la dynamique temporelle du bruit généré par ses moteurs et hélices. Grâce à des techniques avancées de traitement du signal, elle peut être extraite et distinguée du bruit ambiant, même dans des environnements bruyants ou complexes, souvent couplés à des algorithmes d'apprentissage automatique [52], permettent d'augmenter la robustesse et la fiabilité des systèmes de reconnaissance acoustique des drones.

L'analyse de cette empreinte acoustique permet la détection, l'identification et la classification des drones, en facilitant la différenciation entre différents modèles, états de fonctionnement, ou comportements en vol.

3.2. Caractéristique acoustique des drones

Les caractéristiques acoustiques des drones peuvent être décrites qualitativement selon plusieurs aspects :

➤ Fréquences typiques

a. Fréquences fondamentales

La fréquence fondamentale d'un drone correspond à la vibration sonore générée par la rotation régulière des hélices [53]. Elle est proportionnelle à la vitesse de rotation des moteurs et constitue le pic principal dans le spectre acoustique. Cette fréquence varie selon le modèle du drone, souvent autour de 128 Hz [54], elle joue un rôle clé dans l'identification acoustique.

b. Harmonique

Les harmoniques sont des fréquences multiples de la fréquence fondamentale, générées par les effets mécaniques [55] (déséquilibre des pales, vibration du châssis) et aérodynamiques (perturbations de l'écoulement d'air) lors du vol. On peut les visualiser ces fréquences dans le graphique dans la Figure 3.1:

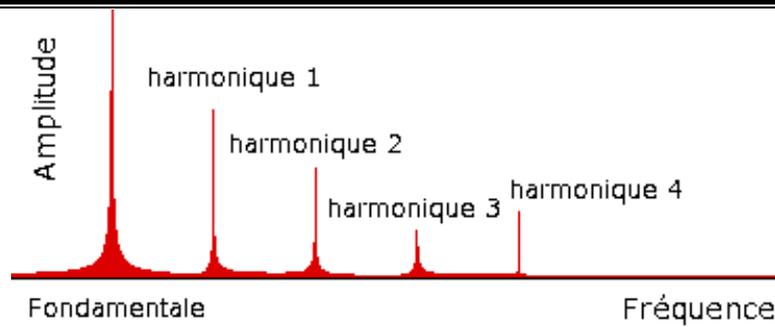


Figure 3.1: Exemple fréquence fondamentale et harmoniques d'une signature acoustique [56]

➤ Variabilité temporelle

Le son du drone varie dans le temps (non stationnaire) en fonction de la vitesse de rotation des hélices, des accélérations, des manœuvres et des changements de régime moteur, produisant des modulations de volume et de tonalité.

➤ Directivité

Le son émis par un drone ne se propage pas uniformément dans toutes les directions. Cette directivité acoustique dépend principalement de la géométrie du drone, notamment de la disposition des hélices, des moteurs et de la structure du châssis. Elle est également influencée par les interactions aérodynamiques complexes qui surviennent en vol. Par ailleurs, la directivité est étroitement liée à la fréquence des composantes, comme montré dans la Figure 3.2

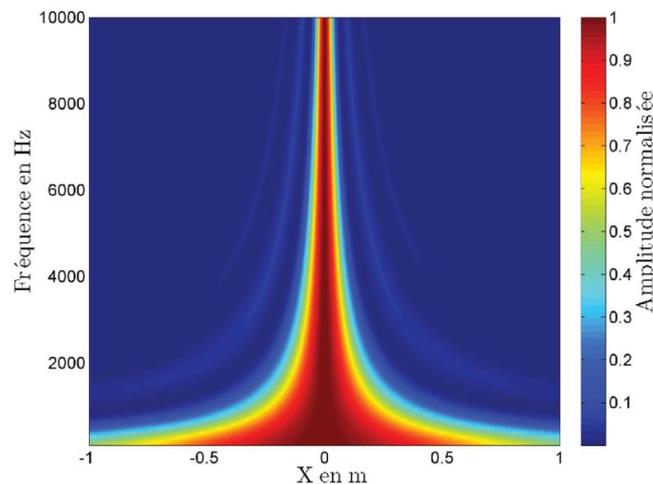


Figure 3.2: Directivité en fonction de la fréquence pour une source harmonique [57]

En plus des fréquences fondamentales et des harmoniques, le bruit émis par un drone peut contenir des fréquences parasites. Ces dernières proviennent de phénomènes secondaires tels que les frottements mécaniques, les vibrations de la structure ou les interférences internes. Bien qu'elles soient souvent de faible intensité, elles enrichissent le signal acoustique et peuvent offrir des indices précieux sur la condition mécanique ou l'environnement du drone.

3.3. Spectre acoustique des drones

Le spectre acoustique d'un drone correspond à la distribution des fréquences sonores qu'il émet pendant son fonctionnement. Il s'agit d'une représentation essentielle pour comprendre la nature des sons produits par le drone et pour les exploiter à des fins de détection, classification et surveillance dans des environnements complexes [58]. Contrairement à une simple analyse temporelle, le spectre acoustique permet de visualiser et quantifier l'énergie sonore sur différentes bandes de fréquence

Le spectre acoustique d'un drone se compose généralement de deux grandes plages de fréquences :

- **Basse fréquence (BF)** : entre environ 100 Hz et 500 Hz [50], cette plage est principalement liée au moteur. Elle contient la fréquence fondamentale de fonctionnement du drone. Ce bruit est continu, stable et se propage efficacement sur de longues distances.
- **Haute fréquence (HF)** : elle s'étend jusqu'à 8–10 kHz et est générée par les hélices. Ces composantes sont souvent riches en harmoniques [50], liées aux turbulences d'air, aux interactions aérodynamiques entre les pales et l'environnement, et aux variations de vitesse.

Et pour analyser le spectre acoustique des drones, il existe diverses méthodes de traitement du signal. Ces méthodes sont choisies en fonction des objectifs de l'analyse, et parmi les plus utilisées, on trouve :

3.3.1. Soustraction spectrale

Cette méthode repose sur l'isolation du signal du drone par rapport au bruit ambiant, au moyen d'une estimation du bruit de fond. L'isolation du signal est obtenue en utilisant des fenêtres de Hanning et des périodogrammes lissés.

3.3.2. La transformée de Fourier rapide (FFT)

Cet outil est couramment utilisé pour extraire les fréquences d'un signal, transformant une représentation temporelle en une représentation fréquentielle qui met en évidence les caractéristiques sonores du drone.

3.3.3. Spectrogrammes (STFT)

La transformée de Fourier à court terme (STFT) génère des représentations temps-fréquence du signal acoustique. Adaptée aux signaux non stationnaires comme ceux des drones, elle montre comment les fréquences évoluent. La Figure 3.3 montre clairement cette analyse

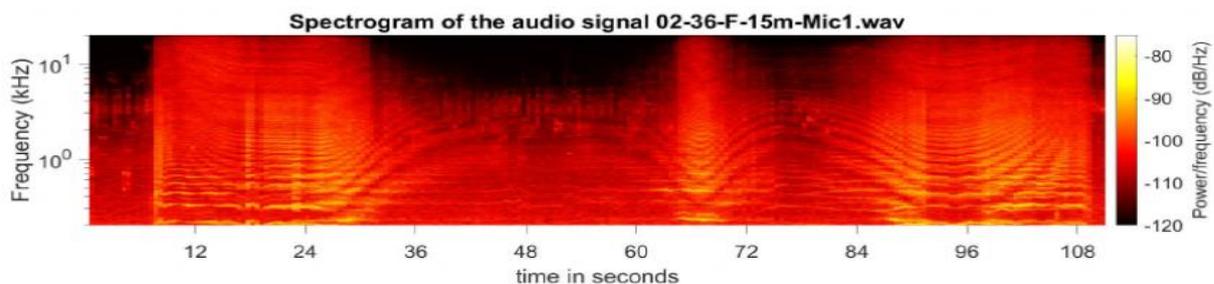


Figure 3.3: Spectrogramme du signal audio capturant la signature acoustique du drone lors de l'expérience en extérieur [59]

Parmi ces méthodes d'analyse du signal, la FFT est particulièrement prisée pour sa simplicité de mise en œuvre, et sa rapidité de calcul. Elle permet d'identifier directement dominantes au sein d'un signal temporel transformé en spectre fréquentiel comme la montre la Figure 3.4. Cette qualité la rend très adaptée à l'analyse des signaux stationnaires [60], où les caractéristiques ne changent pas significativement dans le temps. Cependant, la FFT repose sur cette hypothèse de stationnarité, ce qui constitue une limite majeure face aux signaux non stationnaires (son des drones), dans ce cas la FFT seule s'avère insuffisante, nécessitant des approches plus avancées comme la transformée de Fourier à court terme (STFT) qui permet de capturer l'évolution des fréquences au cours du temps en analysant de courtes sections du signal.

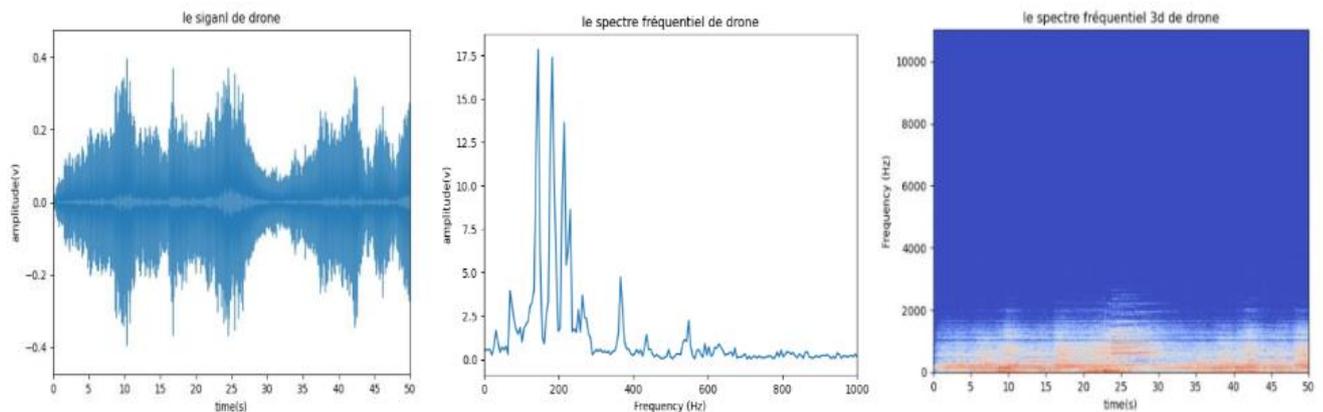


Figure 3.4: Exemple d'une représentation temporelle et fréquentielle (2D et 3D) du son de drone [60]

3.4. Influence de la vitesse sur le spectre acoustique des drones

La vitesse de rotation des hélices et la vitesse de déplacement du drone influencent de manière significative les caractéristiques du spectre acoustique enregistré, notamment en termes de fréquence, d'amplitude et de structure harmonique du bruit émis.

3.4.1. Influence de la vitesse de rotation des hélices

La vitesse de rotation des hélices conditionne directement la puissance et la structure du bruit produit par le drone. Son augmentation amplifie les effets plus les effets acoustiques deviennent marqués. :

- **Intensification du bruit global** : La rotation rapide des pales accentue les phénomènes aérodynamiques [61], ce qui se traduit par une élévation du niveau sonore capté.
- **Enrichissement fréquentiel** : La hausse de vitesse entraîne l'apparition de fréquences plus élevées, rendant le spectre plus complexe et étendu.
- **Des résonances spécifiques** : À certaines vitesses, les pales peuvent vibrer selon des modes particuliers (flexion, torsion...), ce qui génère des pics d'énergie à des fréquences précises dans le spectre.
- **Une évolution de la source dominante de bruit** : À bas régime, le bruit mécanique (du moteur et de la transmission) prédomine. En revanche, lorsque la vitesse augmente, le bruit aérodynamique lié aux hélices prend le dessus.

3.4.2. Influence de la vitesse de déplacement du drone

- Effet Doppler
- Variation de la directivité
- Accroissement de la non-stationnarité du signal

3.5. Logiciel de programmation

Le choix d’un langage de programmation généralement repose sur plusieurs critères essentiels. Il doit offrir une large gamme de bibliothèques adaptées au traitement acoustique, ainsi que la disponibilité de ressources pour la visualisation, l’analyse spectrale, et la manipulation des signaux est également un point important. De plus un langage soutenu par une large communauté permet également un développement plus fluide et évolutif.

Python est un langage de programmation open source, reconnu pour sa simplicité syntaxique, sa lisibilité et sa polyvalence. Il est couramment utilisé dans le domaine du big data.

Sa popularité repose sur plusieurs points forts :

- L’accès facile à une aide grâce à une communauté active.
- Une grande disponibilité de ressources et de bibliothèques.
- Une syntaxe claire qui favorise un code bien structuré et facile à lire.

3.6. La collecte et prétraitement des données

3.6.2. Description de datasets

Dans ce travail, nous avons utilisé deux bases de données audios disponibles publiquement sur Kaggle :

1. UrbanSound8K

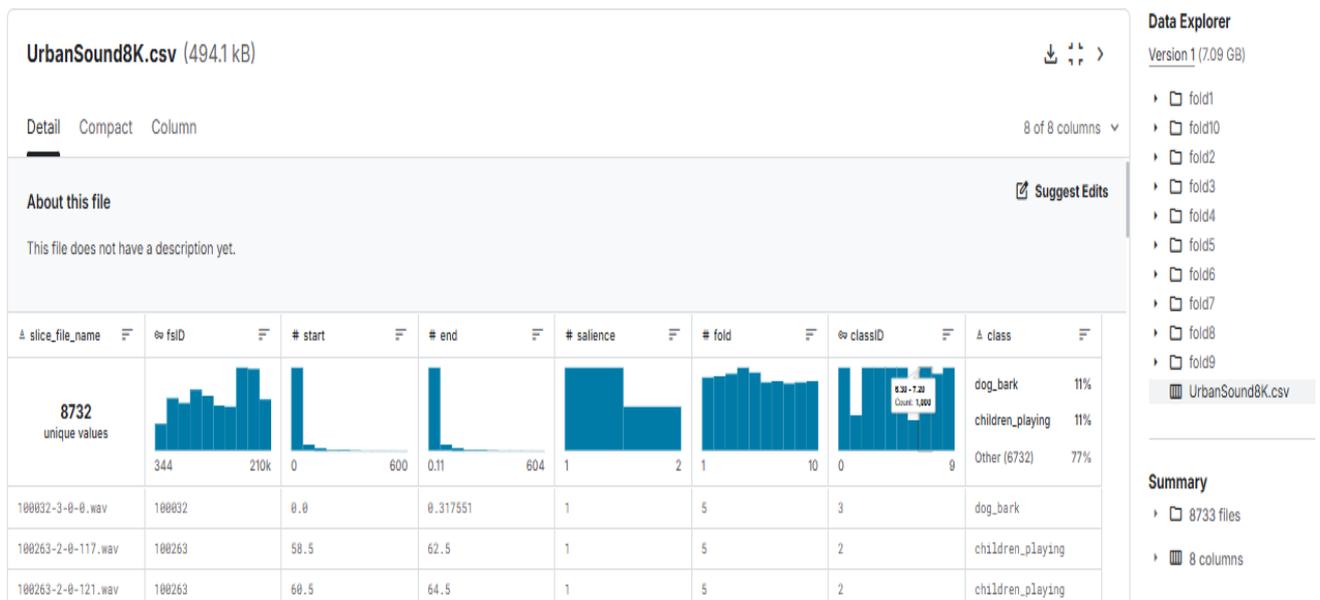


Figure 3.5: Aperçu du dataset UrbanSound8K tel qu’il apparaît sur la plateforme Kaggle [62].

Cet dataset illustré dans la Figure 3.5 contient 8732 extraits sonores labellisés d'une durée inférieure ou égale à 4 secondes, Ces extraits appartiennent à 10 classes d'une taxonomie des sons urbains :

air_conditioner, car_horn, children_playing, dog_bark, drilling, engine_idling, gun_shot, jackhammer, siren, street_music.

Les fichiers proviennent de freesound.org et sont répartis dans 10 sous-dossiers (de *fold1* à *fold10*) pour faciliter les étapes de classification et de validation croisée.

Chaque fichier audio est au format **WAV**, avec des caractéristiques (fréquence, bit depth, canaux) héritées du fichier source original.

Le dataset inclut également un fichier **CSV** (UrbanSound8K.csv) contenant les métadonnées suivantes pour chaque extrait :

- *slice_file_name* : nom du fichier audio
- *fsID* : identifiant Freesound de l'enregistrement d'origine
- *start,end* : temps de début et de fin de l'extrait dans l'enregistrement original
- *salience* : niveau de saillance du son (1 = premier plan, 2 = arrière-plan)
- *fold* : numéro du dossier (1 à 10)
- *classID* : identifiant numérique de la classe sonore (de 0 à 9)
- *class* : nom de la classe sonore (ex : *dog_bark, siren, etc.*)

2. Dataset-balanced-n-weighted-final

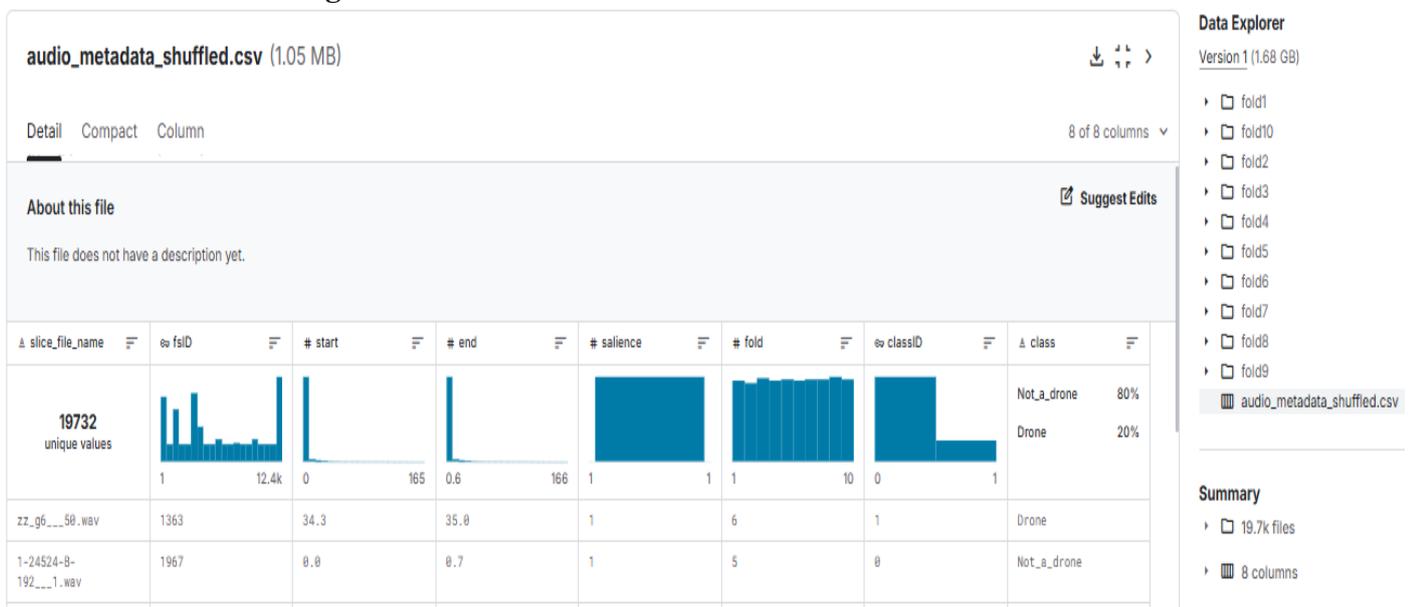


Figure 3.6: Aperçu du Dataset-balanced-n-weighted-final tel qu'il apparaît sur la plateforme Kaggle

Ce dataset est une version équilibrée et pondérée d'une base de données sonore orientée vers la détection de drones [63]. Il contient un total de 19 732 extraits audio, répartis en deux classes :

- *Drone* : 4017 échantillons
- *Not_a_drone* : 15 715 échantillons

Les extraits sonores sont accompagnés d'un fichier CSV décrivant les métadonnées associées à chaque fichier audio. Ce fichier contient les colonnes suivantes :

- *slice_file_name* : nom du fichier audio
- *fsID* : identifiant de la source d'origine
- *start et end* : points de début et de fin de l'extrait dans l'enregistrement initial
- *salience* : indication de la prééminence du son (1 = avant-plan, 2 = arrière-plan)
- *fold* : numéro de pli (utile pour le cross-validation)
- *classID* : identifiant numérique de la classe
- *class* : étiquette de la classe (Drone ou Not_a_drone)

Ce dataset est particulièrement adapté à la tâche de classification binaire visant à distinguer les sons de drones de ceux de l'environnement urbain ou naturel.

L'importation des datasets a été effectuée par le code suivant :

```
# Load the UrbanSound8K metadata
urban_df = pd.read_csv('/kaggle/input/urbansound8k/UrbanSound8K.csv')
print("Urban dataset - first 5 entries:")
display(urban_df.head())

# Load the drone detection metadata from the dataset 'dataset-balanced-n-weighted-final'
drone_df_full = pd.read_csv('/kaggle/input/dataset-balanced-n-weighted-final/audio_metadata_shuffled.csv')
```

3.6.2. Visualisation des données

Pour permettre de mieux comprendre la structure des signaux audio, il est important d'extraire certaines informations à travers leur visualisation, cela comprend : la représentation temporelle, a transformé de fourrier, spectrogramme.

1. La représentation temporelle

Cette représentation consiste à afficher le signal dans le domaine temporel, c'est-à-dire observer l'évolution de signal en fonction de temps. Illustré dans la Figure 3.7 et **Error! Reference source not found.** Cette étape a été générée à l'aide de la fonction *waveshow* de la bibliothèque **Librosa**, permettant de visualiser l'évolution de l'amplitude du son en fonction du temps, l'affichage a été effectué avec la bibliothèque **Matplotlib**, par le code suivant :

```
librosa.display.waveshow(y, sr=sr, alpha=0.8) # Génération de la représentation temporelle
plt.show() # Affichage avec Matplotlib
```

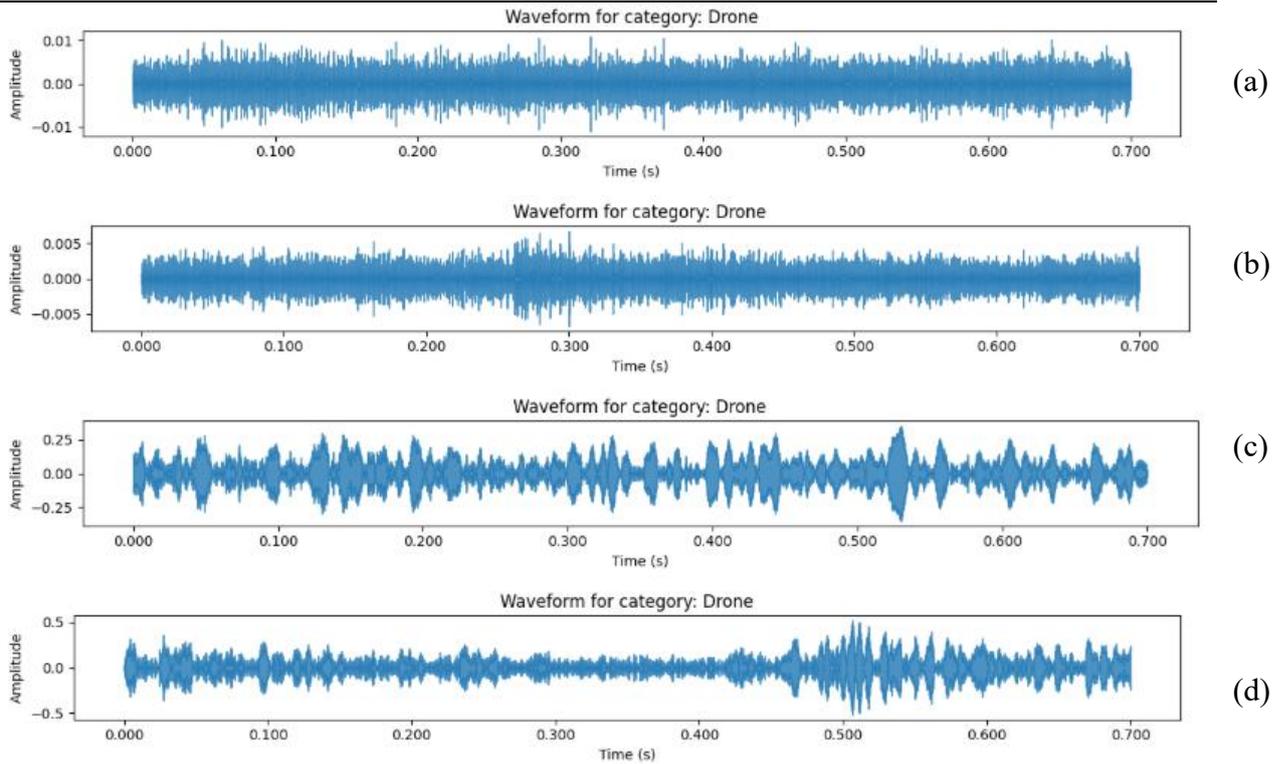


Figure 3.7: représentation de quelques sons des drones dans le domaine temporel

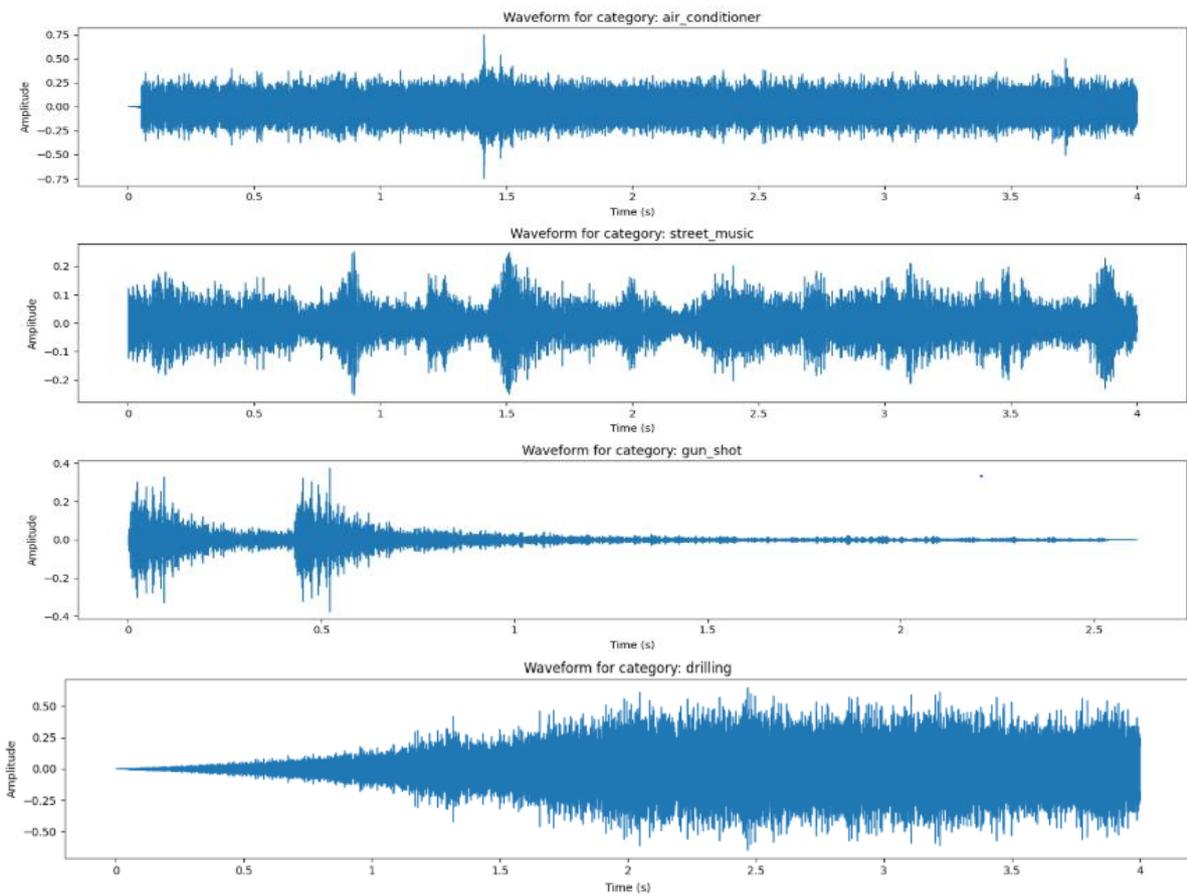


Figure 3.8: représentation temporelle de quelques exemples des sons urbains

Error! Reference source not found.

❖ Analyse et discussion :

A partir des exemples des formes d'ondes des figures Figure 3.7 et Figure 3.8), on peut tirer quelques observations générales sur leurs caractéristiques temporelles.

En premier lieu, on remarque que la représentation temporelle ne permet pas à elle seule de distinguer précisément la nature du son. Elle donne une vue globale sur l'amplitude, la continuité ou la variation du signal, mais n'indique pas les détails fréquentiels.

La majorité des signaux affichés sont monophoniques et présentent une structure assez régulière, ce qui les rend visuellement similaires dans plusieurs cas. En particulier, la plupart des sons apparaissent comme monotones et continus, notamment les sons de drones, *air_conditioner*, *drilling*. Ces signaux sont denses, sans silences ni coupures nettes. En observant de plus près les signaux attribués aux drones (Figure 3.7), on constate qu'ils sont courts (environ 0,7 s), continus et variés en amplitude :

- **Le drone (a)** : présente une amplitude faible (± 0.01), avec un signal stable et sans pics distincts.
- **Le drone (b)** : encore plus discret (± 0.005), conserve une densité similaire, ce qui pourrait traduire un drone éloigné.
- **Le drone (c)** : affiche une amplitude plus élevée (± 0.25) avec des micro-variations visibles, suggérant un signal plus énergétique mais toujours régulier.
- **Le drone (d)** : avec une amplitude atteignant ± 0.5 , présente un signal très dense accompagné de fluctuations internes, typique d'un drone proche ou plus puissant.

Certains signaux(Figure 3.8) présentent toutefois des caractéristiques distinctives :

- Par exemple, la forme d'onde *drilling* commence par une amplitude faible qui augmente progressivement, ce qu'on peut interpréter comme une phase de démarrage.
- D'autres, comme *gun_shot*, montrent au contraire une impulsion très brève suivie d'une chute rapide du signal, marquant une attaque immédiate suivie d'un silence.
- Des sons comme *street_music* montrent des variations dynamiques, avec des alternances entre zones actives et plus calmes, reflétant la structure rythmique.

En conclusion, la représentation temporelle permet d'observer des éléments comme l'amplitude et la directivité mais elle reste insuffisante pour distinguer avec fiabilité les sons de drones des autres sons urbains. Une analyse fréquentielle est donc nécessaire pour extraire leurs signatures spécifiques.

2. La représentation spectrale

Le spectrogramme représente visuellement comment les fréquences d'un signal audio évoluent dans le temps, en montrant l'intensité (en dB) de chaque fréquence à chaque instant.

Pour réaliser cette étape on a utilisé une combinaison de bibliothèques spécialisées, sont :

- *Pandas* pour lire le CSV,
- *Librosa* pour charger l'audio et calculer le spectrogramme,
- *NumPy* pour le traitement numérique,

- *Matplotlib* pour afficher le graphe.

On a obtenu les spectrogrammes exposés dans la

Figure 3.9 et Figure 3.10

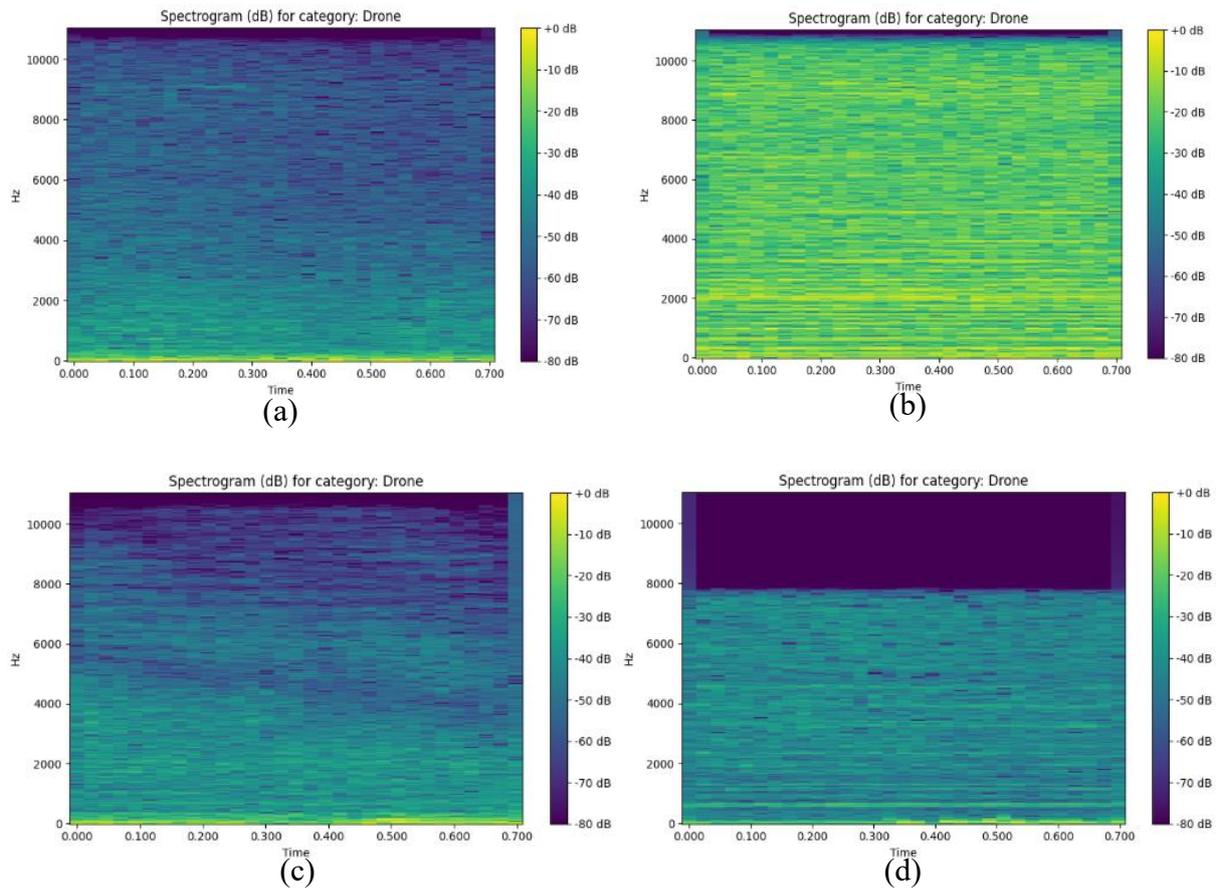


Figure 3.9 : spectrogrammes de différents sons de drones

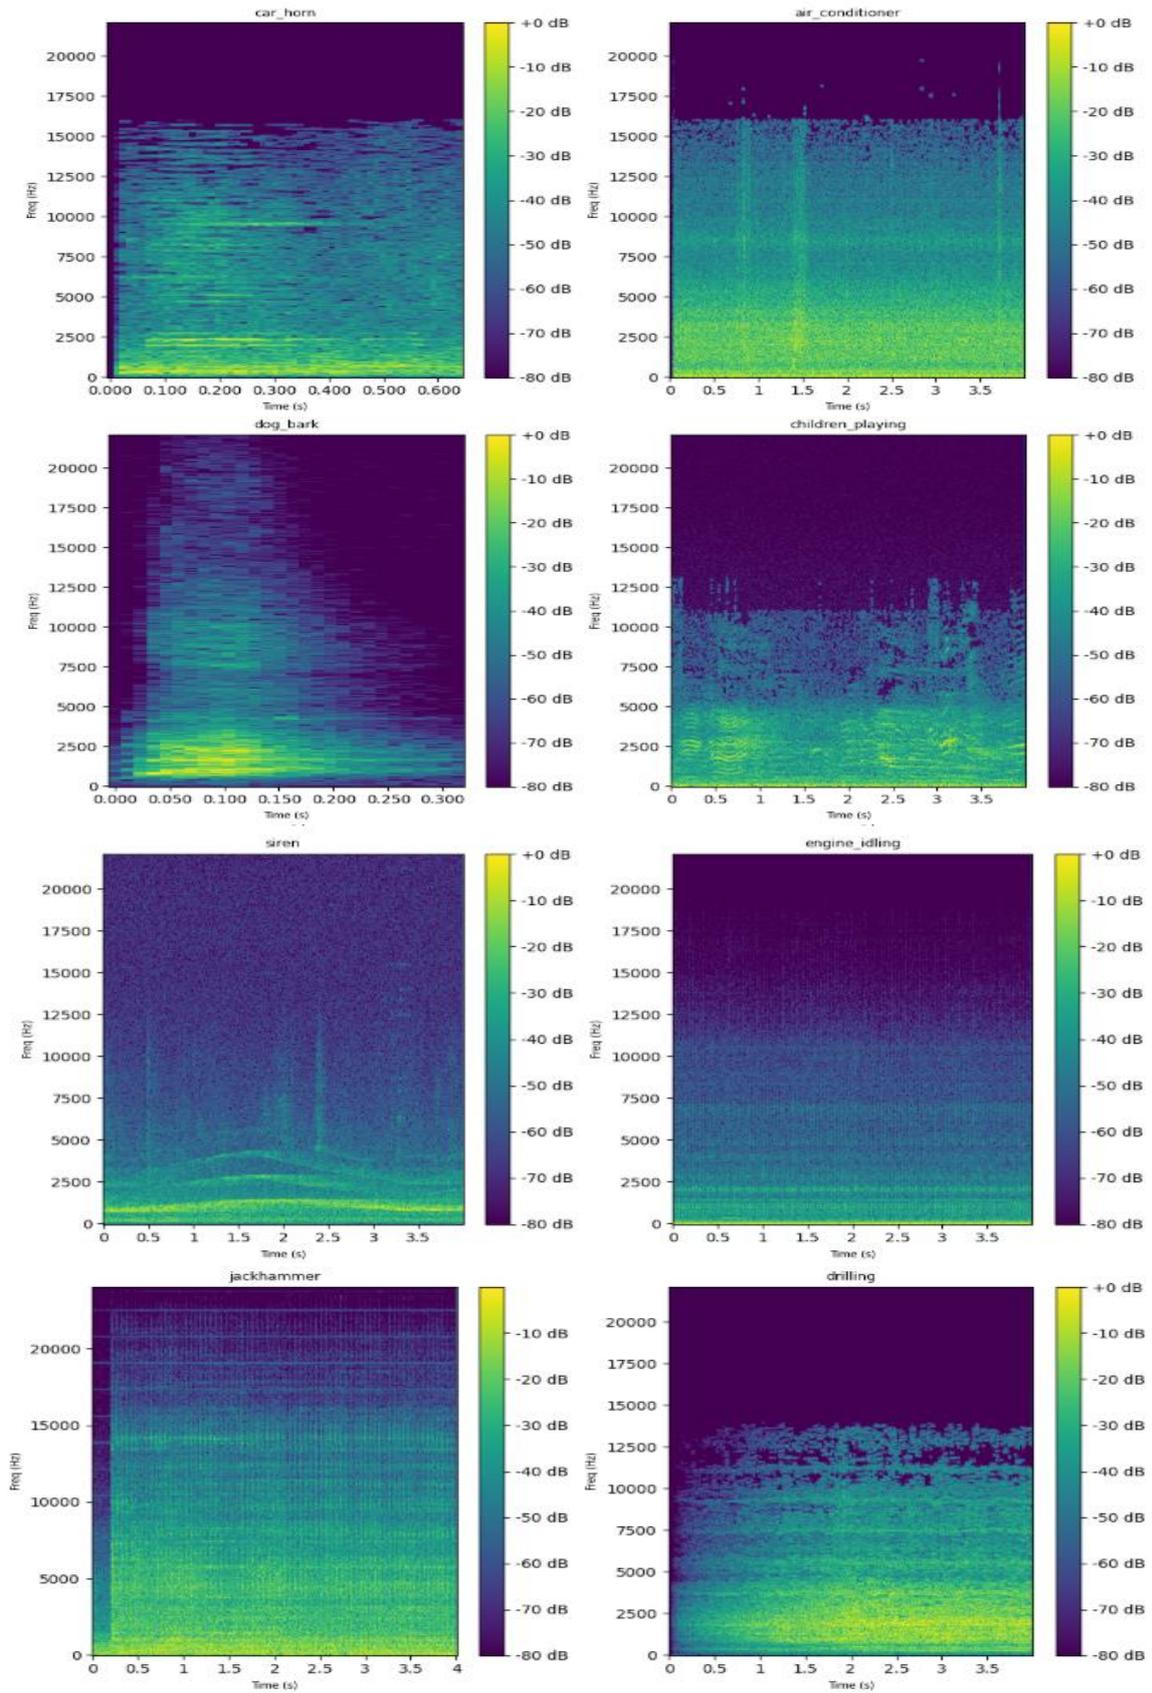


Figure 3.10: spectrogrammes de différents sons urbains

Tous ces graphes montrent l'évolution de l'énergie sonore en fonction de la fréquence (axe des y) et du temps (axe des x) avec l'intensité (amplitude en dB) codée par la couleur :

- Les couleurs sombres (violet, bleu) indiquent une faible intensité,
- Les couleurs claires (jaune, vert clair) indiquent une forte intensité.

❖ Analyse et discussion

Les quatre spectrogrammes de la Figure 3.9 représentant des sons de drones révèlent une signature acoustique globalement stable et continue, dominée par des composantes basses à moyennes fréquences, ce qui traduit la régularité mécanique des hélices en vol.

- **Le drone (a) :** Ce spectrogramme montre une énergie concentrée principalement entre 0 et 4000 Hz, ce qui indique un son plutôt grave. La texture visuelle est lisse et homogène, sans rupture temporelle, avec des tons bleu-vert-jaune montrant une intensité moyenne à forte. Ce signal est riche en amplitude dans les basses fréquences, suggérant un vol stable et lointainement perceptible. Ce son est un son régulier qui traduit des caractéristiques d'un drone en déplacement linéaire ou stationnaire.
- **Le drone (b) :** Le spectre de ce signal est plus étendu, atteignant les 10 000 Hz, ce qui montre la présence de composantes aiguës, en plus des graves. L'image est plus chargée en pixels lumineux (jaune vif), indiquant une forte amplitude énergétique, notamment dans les moyennes et hautes fréquences. Visuellement, on remarque une structure plus irrégulière, traduisant un spectre riche et actif d'un drone plus proche ou plus puissant.
- **Le drone (c) :** Ici, l'énergie s'étend jusqu'à 10 000 Hz, mais elle devient plus faible après 4000 Hz, ce qui montre que le son contient peu de fréquences aiguës. Les couleurs dominantes sont le bleu et le vert clair, ce qui indique un son de force moyenne. Le spectre est assez flou, sans motifs précis, mais reste stable dans le temps. Ce drone semble éloigné ou faiblement capté.
- **Le drone (d) :** Ce spectrogramme est visuellement plus vide au-dessus de 8000 Hz, ce qui signifie une absence totale de sons aigus. L'énergie est concentrée dans les fréquences graves à moyennes, avec une intensité visible (pixels verts et jaunes), surtout en dessous de 6000 Hz. L'image montre une bande bien délimitée en bas, stable dans le temps. Il s'agit probablement d'un drone dont le son est profond et grave.

La Figure 3.10 représente des sons urbains analysés, permettent d'observer, pour chaque source sonore, la répartition des fréquences au cours du temps ainsi que l'intensité acoustique exprimée par les couleurs.

- **Car_horn :** Le spectrogramme de ce son se distingue par une durée très courte, inférieure à 0,5 seconde, et une concentration de l'énergie entre 500 et 3000 Hz. Avec un spectre net et intense, typique d'un événement impulsif facilement reconnaissable.
- **Air conditionner :** ce son stable et grave, essentiellement concentrée dans les basses fréquences (jusqu'à 6000 Hz) avec une intensité faible à modérée. Il s'agit d'un bruit de fond constant, peu dynamique, difficile à distinguer visuellement.
- **Dog_bark :** Spectre marqué par des impulsions rapides et irrégulières, dans une plage de 500 à 8000 Hz, avec une intensité variable.

- **Children_playing** : Spectre très étalé jusqu'à 15 000 Hz, avec une grande variabilité temporelle et une intensité modérée. La figure est chaotique, sans structure harmonique.
- **Siren** : Le spectrogramme est facilement reconnaissable par sa forme ondulatoire, résultant d'une modulation de fréquence entre environ 500 et 3000 Hz. Avec intensité moyenne à forte.
- **Engine_idling** : on voit que ce signal est stable dans le temps, avec une concentration dans les basses fréquences (principalement < 3000 Hz). Le spectre est régulier, peu dynamique, et montre une intensité modérée, sans apparition de composantes aiguës. Les couleurs restent sombres (bleu/vert), traduisant un niveau sonore constant mais non négligeable.
- **Jackamer** : Ce spectrogramme présente une très grande densité spectrale, avec une bande de fréquences allant de 500 Hz à plus de 15 000 Hz. L'intensité est très forte, bien visible par des zones jaunes intenses. Le motif est irrégulier mais présente un certain rythme, avec une forte activité dans les hautes fréquences.
- **Driling** : Le spectre de ce son est également riche, avec une plage de fréquences s'étendant de 500 à environ 13 000 Hz. L'intensité est modérée à forte, les couleurs oscillent entre vert et jaune, et la texture est légèrement floue. La structure temporelle est relativement régulière, sans interruption.

En conclusion, l'analyse spectrogrammique offre une visualisation claire des empreintes acoustiques propres à chaque catégorie sonore. Par exemple, la signature des drones se distingue par une périodicité marquée et une concentration d'énergie dans les basses et moyennes fréquences, accompagnée d'harmoniques bien définies. En revanche, les sons urbains présentent une grande variabilité temporelle et fréquentielle. Toutefois, malgré sa richesse informative, le spectrogramme demeure une représentation trop complexe et redondante pour être exploitable directement dans un système de classification.

3. L'extraction MFCCs

La MFCCs décrivent aussi l'évolution temporelle de l'énergie du signal, mais dans un espace de coefficients cepstraux dérivé de l'échelle de Mel, plus proche de l'audition humaine.

On choisit les MFCCs car elles transforment un son complexe en une empreinte numérique facile à analyser par un modèle d'intelligence artificielle, tout en respectant les caractéristiques auditives humaines. La Figure 3.11 et Figure 3.12 les résultats obtenus de cette étape, à partir de différentes sources sonores.

Revenant à notre code python, nous avons utilisé un ensemble de bibliothèques tel que :

- **Librosa**: pour charger les sons (*librosa.load*) et extraire les MFCCs (*librosa.feature.mfcc*).
- **Matplotlib** et **librosa.display** : pour visualiser les MFCCs avec *specshow*, sous forme de carte colorée.
- **Pandas** : pour lire le fichier CSV contenant les métadonnées audios.
- **NumPy** : pour manipuler les données numériques et créer des tableaux.

Le code est résumé comme suit :

```
# --- Extract MFCC features for UrbanSound8K dataset ---
X_urbansound = []
for data, sr in audio_files_urbansound:
    # Extract MFCC features and take the mean across time frames
    mfccs = librosa.feature.mfcc(y=data, sr=sr, n_mfcc=40)
    mfccs_scaled = np.mean(mfccs.T, axis=0)
    X_urbansound.append(mfccs_scaled)

# --- Extract MFCC features for Drone dataset ---
X_drone = []
for data, sr in audio_files_drone:
    # Extract MFCC features and take the mean across time frames
    mfccs = librosa.feature.mfcc(y=data, sr=sr, n_mfcc=40)
    mfccs_scaled = np.mean(mfccs.T, axis=0)
    X_drone.append(mfccs_scaled)
```

Après avoir ploter les résultats on a obtenu les graphes suivants :

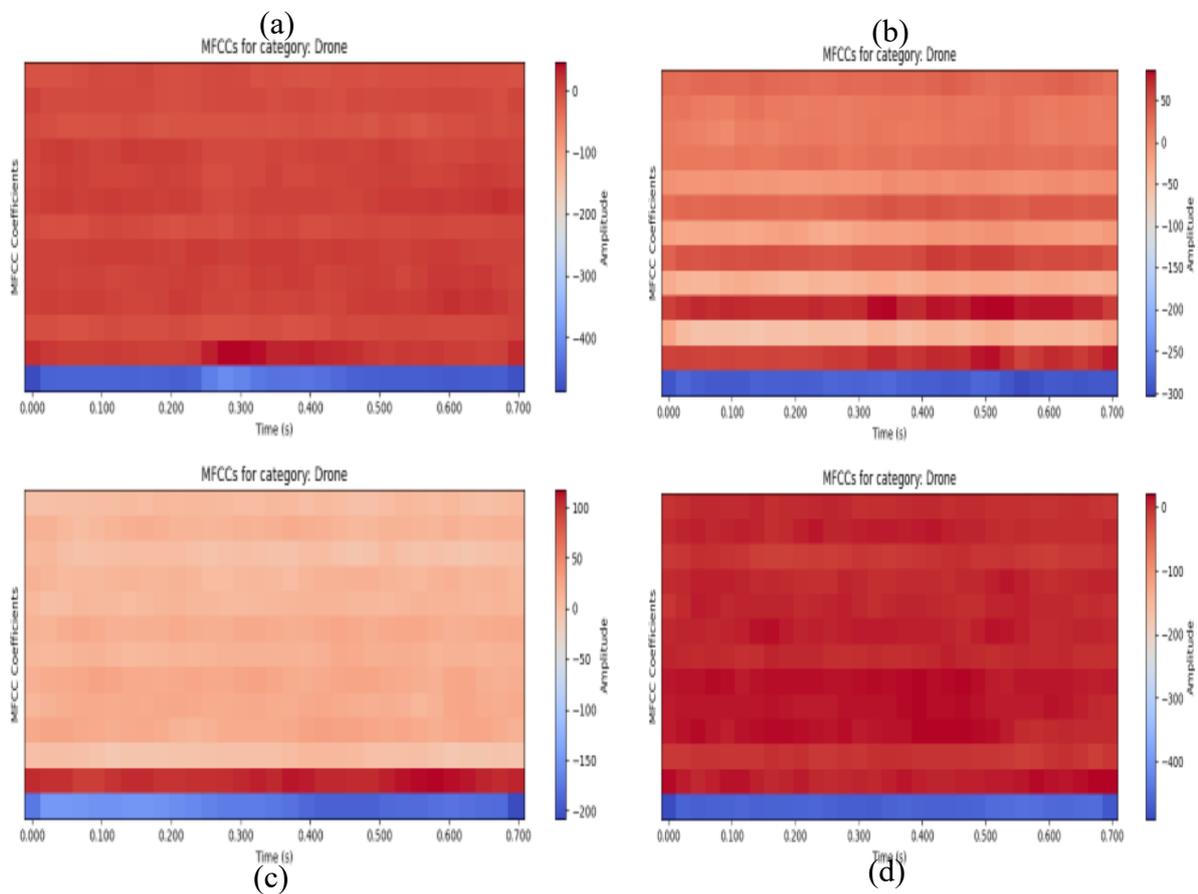


Figure 3.11: Extraits MFCCs de divers sons de drones

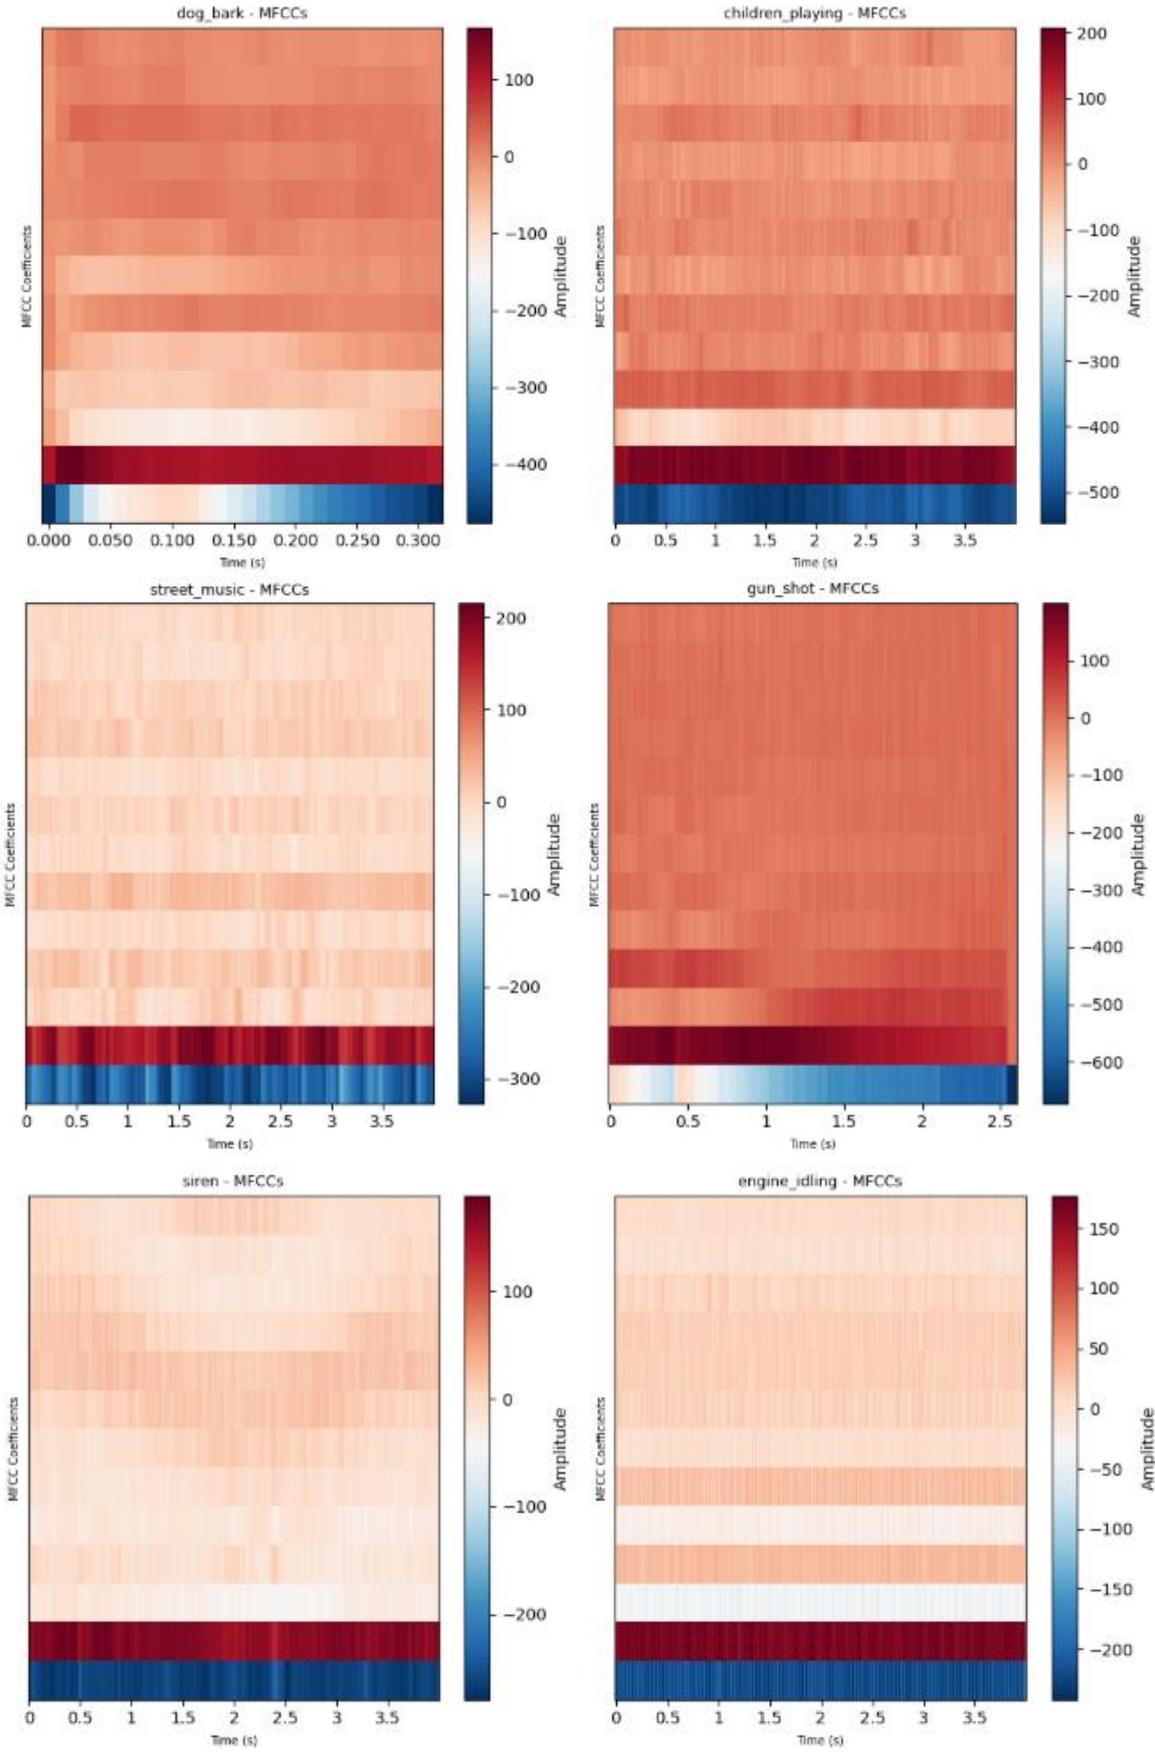


Figure 3.12: Illustration de l'extraction des MFCCs sur des enregistrements variés

Les couleurs traduisent l'intensité des coefficients MFCC (axe des Y), le temps en seconde (axe des X), exprimée sous forme d'amplitude indiqué par les couleurs :

- Les couleurs bleu, violet indiquent une faible intensité des coefficients.
- Les couleurs rouge, orange clair signalent une forte intensité.

Cette représentation permet d'analyser visuellement la signature sonore d'un signal, utile notamment pour distinguer différents types de sons comme les voix, moteurs, ou drones.

❖ Analyse et discussion

La Figure 3.11 regroupe les MFCCs de quatre exemples des signaux émis par des drones avec une durée de 0.7 secondes :

- **Le drone (a)** : on voit que ce graphe présente une forte régularité temporelle dans les premiers coefficients, Les coefficients inférieurs montrent une bande bleu foncé persistante (amplitude entre -400 et -500), suggérant une très faible énergie dans les fréquences graves. Les coefficients moyens et supérieurs montrent des amplitudes modérées (entre -200 et 0). L'ensemble indique un son stationnaire et stable, caractéristique d'un drone en vol constant.
- **Le drone (b)** : Le MFCC de ce drone est similaire au précédent, montre également une structure régulière. Les amplitudes dans les composantes inférieures descendent légèrement plus bas (jusqu'à -500), tandis que les coefficients supérieurs présentent une énergie un peu plus marquée (jusqu'à 0). Cela reflète un signal globalement régulier
- **Le drone (c)** : on voit dans ce graphe une structure régulière, avec des amplitudes faibles dans les coefficients inférieurs (-400 à -500) et une énergie modérée dans les coefficients moyens et supérieurs (-200 à 0). De légères variations sont visibles, mais le signal reste globalement stable et typique.
- **Le drone (d)** : on remarque que ce son conserve la même organisation générale que les autres, mais se distingue par des amplitudes plus proches de zéro (-200 à 0) dans les coefficients moyens à supérieurs, ce qui reflète une énergie plus élevée dans ces zones. Le son reste néanmoins stationnaire et régulier.

Passons à la Figure 3.12 qui correspond à quelques exemples des sons urbains ou on a obtenu les notes suivantes :

- ***Dog_bark*** : ce son est bref (environ 3.0 secondes), avec une forte impulsion initiale visible dans les coefficients supérieurs. On remarque une chute rapide d'amplitude dans les coefficients inférieurs (-400 à -500), indiquant une décomposition rapide du signal. Ce son est typique d'un événement percussif et transitoire.
- ***Children_playing*** : ce son est plus long (~ 3.9), montre une structure très variable dans le temps. On observe une alternance rapide de zones actives, traduisant des événements acoustiques diversifiés, on note également On note une instabilité des coefficients, signe d'un signal non stationnaire et varié.
- ***Sreet_music*** : sa durée est en 3.5s, on remarque une organisation plus régulière des MFCCs, combinant bandes horizontales et transitoires verticales. Présente une distribution d'énergie plus structurée que celui de *childre_playing*, ce qui reflète la présence de rythme et de mélodie, est donc un motif répétitif

- **Gun_shot** : Son bref mais intense (~ 2.5), avec une impulsion verticale marquée en début de graphe. On observe des amplitudes proches de 0 au moment de l'impulsion, suivies d'une chute rapide jusqu'à -400 dans les coefficients inférieurs.
- **Siren** : D'une durée d'environ 3,5 s, se caractérise par des motifs ondulatoires ou diagonaux dans les coefficients MFCC. On remarque une variation régulière de l'énergie liée aux montées et descentes de fréquence. Cela indique une modulation cyclique, propre aux sons d'alerte.
- **Engine_edling** : Sur une durée équivalente ($\sim 3,5$ s), on observe une structure spectrale relativement stable, avec des bandes horizontales nettes. On note des amplitudes faibles dans les coefficients inférieurs (-400 à -500), suggérant une énergie concentrée dans les basses fréquences. Est un signal stationnaire, proche à celle de drone mais avec des variations plus subtiles.

Enfin, chaque son urbain montre une forme MFCC unique, qu'ils soient impulsifs, stationnaires, modulés ou complexes. Ce qui aide à bien les différencier et les reconnaître automatiquement, et constitue une base pertinente pour leur classification automatique.

3.7. Conclusion

Ce chapitre a posé les bases de la détection acoustique des drones, en s'appuyant sur des éléments essentiels à la compréhension et à la préparation des données sonores.

Nous avons introduit l'empreinte acoustique des drones et présenté leurs caractéristiques acoustiques et spectrales, en mettant l'accent sur les fréquences typiques et l'analyse fréquentielle

Nous avons également présenté l'environnement de travail utilisé, à savoir le langage Python, où on a introduit les datasets utilisés, en décrivant le nombre d'échantillons, leurs types, leur durée, et en représentant quelques exemples par des visualisations temporelles, spectrales et MFCCs, afin de mieux comprendre les données en entrée de notre système.

Chapitre 4 :
Développement du Modèle
d'Intelligence Artificielle

4. Développement du modèle d'intelligence artificielle

Introduction

Après avoir mis à l'échelle les coefficients MFCC, deux étapes préalables sont indispensables avant d'entamer l'entraînement du modèle : encodage des étiquettes ; ensuite, la séparation des données :

1. Encodages des étiquettes

Cette phase sert à préparer les données pour entraîner le modèle d'apprentissage plus précisément :

- Combine les caractéristiques MFCC issues des deux jeux de données dans une seule matrice.
- Crée une liste unique d'étiquettes correspondant aux données audios combinées.
- Standardise les données pour améliorer la performance et la convergence du modèle.
- Transforme les étiquettes textuelles en entiers pour les rendre compatibles avec l'algorithme d'apprentissage.

On résume ça dans le code suivant :

```
# Concatenate the feature lists from both datasets
X = np.concatenate((X_urbansound, X_drone), axis=0)

# Concatenate the corresponding labels from both datasets
labels_combined = labels_urbansound + labels_drone

# Scale the features
X = scaler.fit_transform(X)

# Encode the labels into integers
y = le.fit_transform(labels_combined)
```

2. La séparation des données

Pour évaluer correctement la performance du modèle, on divise l'ensemble de données à l'aide de la fonction `train_test_split` de la bibliothèque `scikit-learn` en :

- 80% des données sont utilisées pour l'entraînement (X_{train} , y_{train}).
- 20 % sont réservées pour tester le modèle (X_{test} , y_{test}).

Et nous avons basé sur `random_state=42` pour garantir que la répartition est reproductible si on relance le code.

Le code ci-après reflète cette étape :

```
# Split the combined dataset into training and test sets
from sklearn.model_selection import train_test_split

X_train, X_test, y_train, y_test = train_test_split(
    X,          # Combined features from both datasets
    y,          # Combined encoded labels
    test_size=0.2, # 20% for testing
    random_state=42 # For reproducibility
)
```

4.1. Modèles et comparaison

Nous avons comparé deux modèles d'apprentissage : l'arbre de décision (Decision Tree) et la forêt aléatoire (Random Forest), afin de déterminer quel algorithme fournit les meilleurs résultats pour la classification des sons, cette phase s'est déroulée en plusieurs étapes :

1. L'importation des bibliothèques et classifieurs :

Avant la manipulation il est nécessaire d'importer les bibliothèques appropriées et définir les classifieurs à comparer

```
from sklearn.tree import DecisionTreeClassifier
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import accuracy_score, precision_score, recall_score
import pandas as pd

# Define classifiers to compare
classifiers = [
    DecisionTreeClassifier(),
    RandomForestClassifier()
]
```

2. Création d'un tableau pour les résultats :

Il s'agit d'initialiser un DataFrame vide pour stocker les performances

```
# Create empty DataFrame to store results
results = pd.DataFrame(columns=['Classifier', 'Accuracy', 'Precision', 'Recall'])
```

3. Entraînement et prédiction :

Pour chaque modèle il est essentiel d'entraîner et prédire les classes des données de test.

```
# Train and evaluate each classifier
for clf in classifiers:
    clf.fit(X_train, y_train) # Train classifier on training data

    y_pred = clf.predict(X_test) # Predict on test data
```

4. Evaluation des performances :

Évalué les performances du modèle à l'aide de trois métriques (Accuracy, Recall, Precision), Leur calcul repose sur les équations (Equation (1), Equation (2), Equation (3), Equation(4) définies dans le chapitre 2.

```
# Calculate evaluation metrics
accuracy = accuracy_score(y_test, y_pred)
precision = precision_score(y_test, y_pred, average="macro")
recall = recall_score(y_test, y_pred, average="macro")

# Prepare results row
row = pd.DataFrame([
    'Classifier': clf.__class__.__name__,
    'Accuracy': accuracy,
    'Precision': precision,
    'Recall': recall
])

results = pd.concat([results, row], ignore_index=True) # Append results row
```

5. Classement et affichage des résultats :

```
# Sort results by accuracy descending
results.sort_values(by='Accuracy', ascending=False, inplace=True)

# Display results table
print(results)
```

4.2. Résultats et discussion

4.2.1. Résultats comparatifs des classifieurs

Dans le but d'évaluer la pertinence des modèles d'apprentissage automatique appliqués à la détection acoustique de drones, deux algorithmes de classification ont été implémentés : arbre de décision (Decision Tree Classifier) et forêt aléatoire (Random Forest Classifier). Ces performances sont évaluées à l'aide de métriques standards : Précision (Accuracy), Rappel (Recall), Précision au sens strict (Precision), où on a obtenu la Tableau 4.1 **Error! Reference source not found.**

	Classifieur	Accuracy	Precision	Recall
1	RandomForestClassifier	0.870718	0.950831	0.674432
0	DecisionTreeClassifier	0.753206	0.605433	0.615093

Tableau 4.1: résultats comparatifs des classifieurs

Par cette analyse, on constate que le randomforest surpasse clairement l'arbre de décision en termes de précision globale (87% contre 75%), ce que signifie que le randomforest plus performant pour prédire les classes. De plus il marque une précision de 95 % et un rappel moyen de 67 % contre respectivement 60 % et 61 % pour le modèle DecisionTree. Cela confirme son meilleur pouvoir de généralisation.

3.6.2. Évaluation des performances et interprétation des résultats de l'arbre de décision

Le modèle d'arbre de décision présente des performances globalement inférieure. À partir du rapport de classification dans le Tableau 4.2 **Error! Reference source not found.** et la matrice de confusion dans la Figure 4.1, nous procédons à l'analyse de ce modèle

```

=== Rapport de classification pour DecisionTreeClassifier ===
              precision    recall  f1-score   support

   Drone           0.88        0.88        0.88         835
  Not_a_drone       0.83        0.81        0.82        3123
  air_conditioner   0.70        0.71        0.71         221
   car_horn         0.56        0.47        0.51          99
  children_playing  0.45        0.49        0.47         200
   dog_bark         0.41        0.37        0.39         203
   drilling         0.49        0.62        0.55         169
  engine_idling     0.76        0.78        0.77         201
   gun_shot         0.46        0.45        0.46          73
  jackhammer        0.66        0.71        0.68         207
   siren            0.68        0.68        0.68         173
  street_music      0.38        0.41        0.39         189

 accuracy          0.75                    0.75        5693
  macro avg         0.61        0.62        0.61        5693
  weighted avg      0.76        0.75        0.75        5693

```

Tableau 4.2: rapport de classification de classifieur arbre de décision

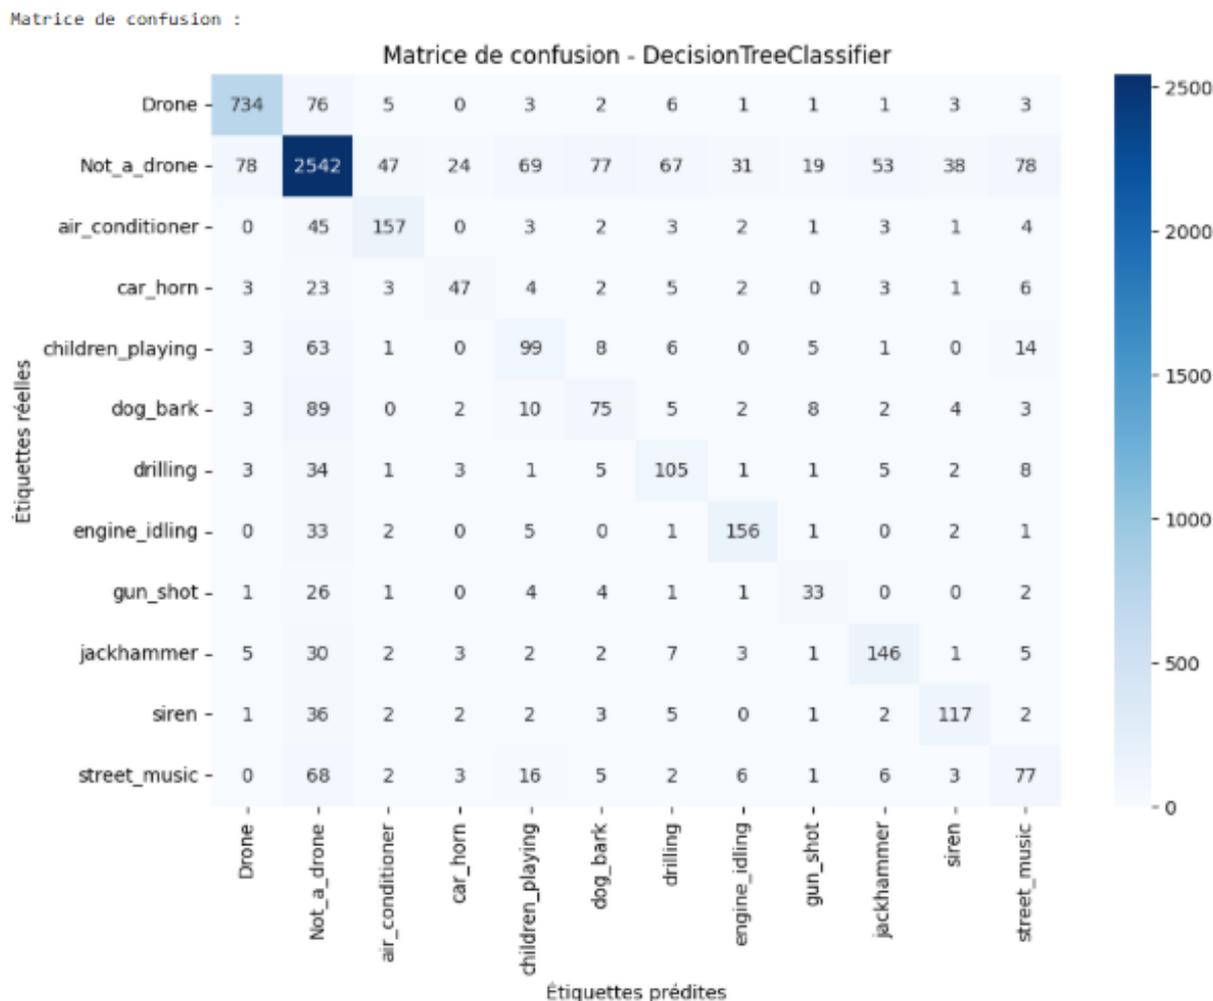


Figure 4.1: matrice de confusion de modèle d'arbre de décision

1. Classes à bonne performance

Ces classes se distinguent par des valeurs élevées et équilibrées des trois métriques

- **Drone** : Précision, Rappel et F1-score de 88% environ. Ces métriques sont excellentes et suggèrent que le modèle identifie très bien les drones. Ce qui est essentiel puisque cette classe constitue souvent la cible principale de l'application.
- **Not_a_Drone** : F1_score de 0.82 (précision de 0,83), donc il classe correctement une grande majorité des instances, mais certaines confusions apparaissent avec des sons tels que : *air_conditioner* et *engine_idling*

Certaines classes secondaires sont bien détecté avec un bon équilibre entre précision et rappel tel que :

- **engine_idling** (F1 = 0.77), **jackhammer** (F1 = 0.68), **siren** (F1 = 0.68)

Cela démontrant que le modèle n'oublie pas souvent ces types de son et se montre relativement précis lorsqu'il en détecte un, même que quelques sons souvent confondus avec d'autres bruits urbains.

2. Classes à performances moyennes

Les deux classes ci-dessous présentent des valeurs modérées et parfois déséquilibrées entre les différentes métriques ce qui reflète l'efficacité de modèle

- **Air_conditioner** : un bon équilibre entre précision (0.70) et rappel (0.71) montre une reconnaissance fiable malgré quelques confusions avec des bruits ambiants similaires.
- **Drilling** : affiche un rappel satisfaisant (0.62) mais une précision plus faible (0.49), révélant une tendance à surclasser des sons voisins.

Leurs F1-scores respectifs (0.71 et 0.55) confirment des performances exploitables, bien qu'imparfaites dans des environnements complexes.

3. Classes à faibles performances

- **Children_playing, dog_bark, street_music, car_horn** : Ces classes sont souvent confondues entre elles ou avec *not_a_drone* avec rappel < 0.50 ce qui montre que l'arbre de décision a du mal à capturer leurs subtilités acoustiques et elle rate plusieurs classes.
- **Gun_shot** : un taux de rappel de rappel de 0.45 seulement, ce qui indique que ce type de bruit est mal classé et confondu avec d'autres bruits (*children_playing, dog_bark, street_music*)

Leur score F1 (À 0.76), est tiré vers le bas par ces faibles valeurs de rappel, ce qui indique que les performances du modèle ne sont pas uniformes dans toutes les classes.

Ces observations sont également confirmées par la matrice de confusion de la Figure 4.1, qui montre une prédominance des prédictions correctes sur la diagonale, en particulier pour les classes *Drone* et *Not_a_drone*, tandis que d'autres présentent plus de confusions, On a relevé ces remarques :

❖ Prédictions correctes (diagonale)

Les éléments situés sur la diagonale de la matrice de confusion correspondent aux vrais positifs (TP), où le modèle a correctement identifié une classe. On note une concentration raisonnable de ces valeurs, ce qui témoigne d'une certaine capacité à identifier correctement les classes, notamment :

- *Drone* : 734 TP sur 835 échantillons réels ($\approx 88\%$ de bonnes prédictions).
- *Not_drone* : 2542 TP sur 3123.

❖ Erreurs de classification (hors diagonale)

Les éléments situés hors diagonales sont soit des faux négatifs (FN) ou bien des faux positifs (FP) on peut prendre les exemples suivants :

- *Drone* : 734 TP sur 835 ($\approx 88\%$), avec 26 FN confondus avec *Not_a_drone*.
- *Not_a_drone* : 2542 TP sur 3123 ($\approx 81\%$), dont 69 FP vers *car_horn* et 24 FP vers *air_conditioner*.
- *Siren* : 117 TP sur 136 ($\approx 86\%$), avec 15 FN confondus avec *street_music*.
- *Dog_bark* : 75 TP sur 203, donc 128 FN ($\approx 37\%$ de rappel).
- *Car_horn* : 47 TP sur 99, soit 52 FN, et plusieurs FP venant de *Not_a_drone*.
- *Jackhammer* : 168 TP sur 207 ($\approx 81\%$), avec quelques FN vers *drilling* ou *engine_idling*.

Remarque : Le modèle *DecisionTree* montre une tendance marquée aux faux négatifs, surtout pour les classes minoritaires, ce qui signifie qu'il rate de nombreux sons à détecter.

Il souffre aussi d'une confusion importante entre certaines classes, notamment entre les sons urbains proches. Enfin, il présente un risque de surapprentissage, limitant sa capacité à généraliser. Quant aux vrais négatifs (TN), ils existent mais sont difficiles à quantifier précisément dans un contexte multi classes.

4.2.3 Évaluation des performances et interprétation des résultats de Randomforest

Pour analyser performances de cet algorithme, on se base sur le rapport de classification du Tableau 4.3 et la matrice de confusion de la Figure 4.2 résultants :

```

=== Rapport de classification pour RandomForestClassifier ===
      precision    recall  f1-score   support

   Drone           0.99      0.92      0.95         835
  Not_a_drone       0.82      0.99      0.90        3123
air_conditioner     1.00      0.80      0.89         221
   car_horn         1.00      0.52      0.68          99
children_playing    0.95      0.47      0.62         200
   dog_bark         0.88      0.31      0.46         203
   drilling         0.89      0.64      0.74         169
engine_idling       1.00      0.83      0.91         201
   gun_shot         0.98      0.55      0.70          73
  jackhammer        0.97      0.81      0.88         207
   siren            0.97      0.83      0.89         173
street_music        0.97      0.44      0.60         189

 accuracy              0.87         5693
  macro avg           0.95      0.67      0.77         5693
  weighted avg        0.89      0.87      0.86         5693

```

Tableau 4.3: rapport de classification de classifieur Random forest

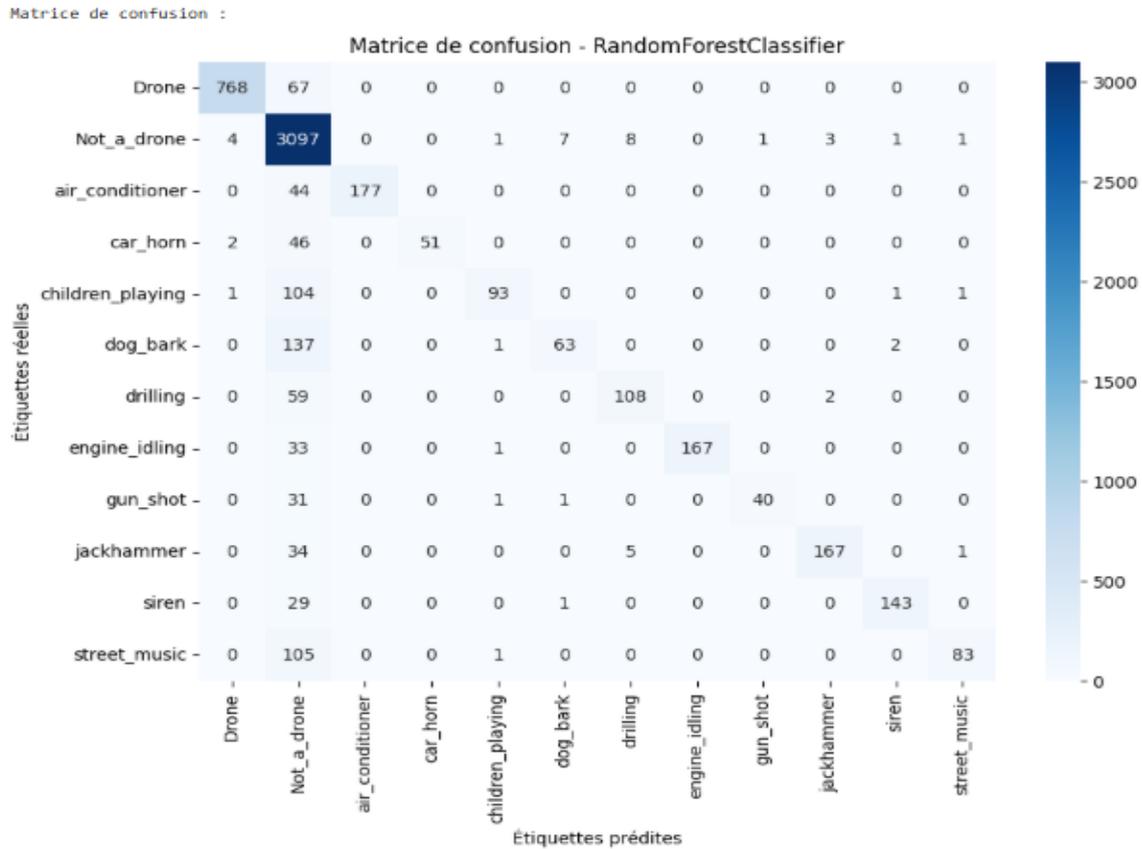


Figure 4.2: matrice de confusion de modèle Random forest

1. Classes à bonnes performances

Certaines classes sont bien détectées, avec un équilibre entre précision et rappel, ce qui traduit un F1score élevé

- **Drones** : Précision de 0.99, Rappel de 0.92, score F1 de 0.95, ce que signifie une très bonne détection de la cible principale, malgré quelque confusion avec d'autre son de la classe *Not_a_Drone*
- **Not_a_Drone** : Précision de 0.81, Rappel de 0.99, score F1 de 0.89. Le rappel exceptionnel pour cette classe majoritaire, signifie qu'elle rate rarement un son (*Not_a_Drone*)
- **Engine_idling (F1-score=0.91), jackhammer (F1-score= 0.88), siren (F1score=0.89) et air_conditioner (F1-score : 0.89)** : ces classes montrant un F1-score élevé, avec une précision parfaite (1.00) ou très élevée. Alors Le modèle est très fiable lorsqu'il prédit ces sons et en détecte une grande proportion.

La performance exceptionnelle sur ces classes suggère que le modèle a pu apprendre des caractéristiques distinctives très claires et robustes pour ces catégories.

2. Classes à performances moyennes

D'autres classes montrent des résultats corrects, mais avec des déséquilibres entre précision et rappel, traduisant une compétence partielle du modèle à les reconnaître :

- **Drilling** (forage) : avec une précision de 0.89 mais un rappel de 0.64, le modèle identifie correctement les cas détectés, mais en manque encore une proportion importante. Le F1-score (0.74) indique une performance moyenne exploitable.
- **Gun_shot** : malgré une excellente précision (0.98), le rappel n'est que de 0.55, ce qui indique que presque la moitié des tirs ne sont pas détectés. Le F1-score (0.70) reflète cette faiblesse.
- **Car_horn** : très bonne précision (1.00), mais rappel de 0.52, donc des confusions fréquentes ou des omissions. Le F1-score de 0.68 reste acceptable mais montre une marge d'amélioration.

3. Classes à faibles performances

Certaines classes sont difficilement reconnues par le modèle, malgré un entraînement sur des datasets équilibré. Elles présentent un faible rappel, ce qui signifie que la majorité des occurrences de ces sons ne sont pas détectées :

- **Dog_bark** : avec un rappel de seulement 0.31, le modèle rate presque 70 % des cas, même si sa précision est correcte (0.88). Le F1-score de 0.46 souligne cette faiblesse.
- **Children_playing** : bien que la précision soit de 0.95, le rappel est de seulement 0.47. Cela reflète une incapacité à capturer de nombreuses occurrences de cette classe. Le F1-score est limité à 0.62.
- **Street_music** : ce cas est similaire avec un rappel de 0.44 pour une précision très élevée (0.97). Le F1-score chute à 0.60, révélant une détection lacunaire.

En se basant sur la matrice de confusion de la Figure 4.2, ces remarques peuvent être confirmées par les points suivants :

❖ **Diagonale renforcée :**

La majorité des classes montrent une nette augmentation du nombre des vrais positifs (TP) spécifiquement :

- *Drone* : 768 TP sur 835 — soit $\approx 92\%$.
 - *Not_drone* : 3097 TP sur 3123 ($\approx 99\%$).
- **Réduction des erreurs hors diagonale :**
On voit que les valeurs en dehors de la diagonale sont très faibles, souvent nulles ou proches de 1 ; on prendre les exemples suivants :
 - *Dog_bark* : passe de 75 à 137 bonnes classifications ($\approx 68\%$).
 - *Engine_idling* : de 156 à 167 ($\approx 83\%$).
 - *Siren* : de 117 à 143 ($\approx 83\%$).
 - *Jackhammer* : 168 \rightarrow 180 ($\approx 87\% \rightarrow 91\%$).
 - *Car_horn* : 47 \rightarrow 52 (mais précision passe de 56 % à 100 %, suggérant moins de fausses détections).

Remarque : Le modèle Random Forest se distingue par sa fiabilité et sa capacité de généralisation, avec une forte concentration de bonnes prédictions (TP) et peu d'erreurs (FP, FN), confirmant sa robustesse face au surapprentissage. Toutefois, ses faibles performances en rappel révèlent une limite importante : certaines classes restent mal détectées, probablement à

cause d'une sous-représentation, d'une grande variabilité ou de similarités acoustiques entre classes.

4.2.4. Analyse comparative entre Random Forest et Arbre de Décision

Après avoir analysé les résultats obtenus, nous avons identifié plusieurs points de comparaison entre l'Arbre de Décision et l'algorithme Random Forest. Cette comparaison met en évidence les avantages des méthodes ensemblistes. Les principaux éléments relevés sont les suivants :

- Le modèle Random Forest affiche une précision globale supérieure (87 %) par rapport au Decision Tree (75 %), confirmant ainsi une meilleure capacité de généralisation.
- Les scores F1 moyens (macro et pondéré) sont également en faveur de Random Forest, ce qui indique des performances plus équilibrées entre les différentes classes, même celles qui sont minoritaires.
- Pour les classes principales comme *Drone* et *Not_a_drone*, Random Forest offre une détection plus fiable, avec des F1-scores de 0.95 et 0.90 respectivement, contre 0.88 et 0.82 pour le Decision Tree.
- Sur les classes difficiles telles que *dog_bark*, *street_music* ou *children_playing*, Random Forest reste plus performant, bien que des améliorations restent nécessaires.

Ces points principaux sont résumés dans la ci-dessous

Critères	Arbres de Décision	Random Forest
Précision globale (accuracy)	75%	87%
F1-score macro	0.61	0.77
F1-score pondéré	0.75	0.86

Tableau 4.4: comparaison des performances des deux modèles

En résumé, Random Forest s'impose comme le modèle le plus performant dans ce contexte, offrant un bon compromis entre précision, et rappel l'ensemble des catégories. Se distingue par sa fiabilité et sa capacité de généralisation, avec une forte concentration de bonnes prédictions (TP) et peu d'erreurs (FP, FN), ce qui confirme sa robustesse face au surapprentissage. Comparée à la matrice de l'Arbre de Décision, celle du Random Forest présente une distribution plus nette sur la diagonale, signe de meilleures prédictions cohérentes par classe.

4.3. Conclusion

Ce chapitre a permis de mettre en œuvre, d'entraîner et d'évaluer deux algorithmes d'apprentissage supervisé – l'arbre de décision et la forêt aléatoire (Random Forest) – dans le cadre de la classification de sons environnementaux, avec un intérêt particulier pour la détection des sons de drones.

Les résultats obtenus de l'analyse comparative des modèles Decision Tree et Random Forest pour la classification sonore, démontre clairement la supériorité du Random Forest. Ce dernier offre une performance globale significativement meilleure, une robustesse accrue face au surapprentissage, et une fiabilité de prédiction supérieure pour la majorité des catégories sonores.

Ces résultats soulignent l'importance du choix du modèle et de la qualité des données. Pour améliorer les performances, des pistes comme l'augmentation de données, le rééquilibrage des classes ou l'utilisation de modèles plus avancés peuvent être envisagées.

Conclusion Générale

Conclusion générale

Dans ce travail, nous avons étudié une approche basée sur l'intelligence artificielle pour la détection acoustique des drones, en nous appuyant sur les arbres de décision comme méthode de classification. L'objectif principal de ce travail était de reconnaître les sons caractéristiques des drones et de les extraire efficacement du bruit ambiant urbain. Pour cela, nous avons adopté une démarche structurée allant de l'analyse théorique des drones et des méthodes d'apprentissage automatique, jusqu'au développement pratique et à l'évaluation de modèles sur des jeux de données.

Dans le premier chapitre, nous avons présenté les différentes catégories de drones, leurs caractéristiques techniques, ainsi que les enjeux de sécurité associés à leur utilisation croissante. La détection acoustique a été retenue comme approche intéressante, notamment en contexte urbain, malgré la complexité du bruit ambiant.

Le second chapitre a permis d'introduire les concepts fondamentaux de l'intelligence artificielle, avec un focus sur l'apprentissage automatique. Nous avons détaillé le fonctionnement des arbres de décision, leurs avantages, et les raisons qui justifient leur choix pour ce type de tâche.

Le troisième chapitre a posé les bases de l'analyse acoustique, en décrivant les caractéristiques des signaux sonores des drones et les outils utilisés pour les visualiser. Les deux bases de données exploitées ont été présentées, avec une analyse descriptive des échantillons et quelques représentations graphiques permettant de mieux comprendre la nature des sons.

Le dernier chapitre, a été consacré au développement et à l'évaluation comparative des modèles entre deux modèles d'apprentissage automatique appliqués à la classification sonore, à savoir le Decision Tree et le Random Forest, nous avons analysé leurs performances respectives, ce qui a permis de mettre en évidence des différences notables en termes d'efficacité.

Le Decision Tree, bien que simple et interprétable, présente une précision limitée (75 %) et des confusions marquées entre les classes, en particulier pour la détection des sons de drones. Ces limites sont typiques des modèles peu complexes confrontés à la richesse des données acoustiques, et s'expliquent notamment par le surapprentissage, la sensibilité au bruit.

À l'inverse, le Random Forest se distingue par sa robustesse et son efficacité. Il a atteint une précision globale de 87 % avec des scores F1 nettement plus élevés., il parvient à mieux généraliser et à limiter les erreurs de classification. En particulier, la détection des drones est nettement améliorée, avec une réduction significative des faux positifs et des faux négatifs. Ces résultats s'expliquent par sa structure en ensemble de plusieurs arbres, qui permet de combiner les prédictions de manière intelligente et d'augmenter la fiabilité du système. D'après notre observations le modèle constitue ainsi une solution pertinente pour des tâches complexes telles que la reconnaissance acoustique et la détection spécifique de signatures sonores de drones.

Ainsi, bien que notre modèle présente certaines limites de précision, notamment dans des contextes complexes ou en présence de classes déséquilibrées, il demeure pertinent dans le domaine de la détection acoustique. Cette méthode de détection conserve aujourd'hui une place centrale, notamment dans les systèmes hybrides, où elle complète efficacement d'autres technologies comme la vision ou le radar. Les recherches récentes confirment d'ailleurs que

Conclusion Générale

l'acoustique joue un rôle crucial, en particulier dans les situations où les autres capteurs montrent leurs limites.

Notre modèle, bien qu'imparfait, constitue une base solide pouvant être améliorée. L'intégration future de techniques d'apprentissage profond, telles que les réseaux de neurones convolutifs (CNN) ou les architectures LSTM, permettrait de renforcer sa robustesse et sa capacité de généralisation. Ces perspectives ouvrent la voie à un détecteur acoustique plus performant, apte à répondre aux exigences croissantes des systèmes de surveillance modernes.

Bibliographie

Bibliographie

- [1] «Ametra Groupe, "L'essor des drones armés",13 mars 2024.<https://blog.ametrargroup.com/lessor-des-drones-armes/> . Consulté le 14/02/2025».
- [2] «Damaisin d'Arès, Jean-Christophe. « *Tout savoir sur les drones – L'arme 3.0* », Chapitre : L'évolution des drones militaires. p224. Éditions Jean-Pierre Otelli. 2017.».
- [3] «Shani Weinstein: "Utilisation abusive des drones : Attaques et incidents liés aux drones", le 06 juin 2023.<https://sentrycs.com/fr/the-counter-drone-blog/misuse-of-drones-drone-attacks-and-incidents/> , consulté le 15/02/2025».
- [4] «By Nicolas, "Drone XTR : systèmes de détection de drones",24 mars 2024, <https://www.drone-actu.fr/actualite/drone-xtr-systemes-de-detection-de-drones>. consulté le 15/02/2025».
- [5] «Engr. Dr. S.Alhaji Musa,R. raja abdullah,I.Alyani,S.Aduwati, S.Asem:"A REVIEW OF COPTER DRONE DETECTION USING RADAR SYSTEM",Researchgate,pp 20-24, mars 2019».
- [6] «Direction : AID. « DEEPLOMATICS : identifier et localiser des drones par l'analyse des sons émis ». 3 mars 2022. <https://www.defense.gouv.fr/aid/actualites/deeplomatics-identifier-localiser-drones-lanalyse-sons-emis> . consulté le 15/02/2025.».
- [7] «« L'UTLN développe un détecteur acoustique pour la lutte anti-drones ». Projet de recherche, Université de Toulon, 3 février 2022.».
- [8] «« Apprentissage automatique : comprendre les bases et les applications ». le 12 octobre 2023. <https://merciia.com/apprentissage-automatique-comprendre-les-bases-et-les-applications/>.Consulté le 15/02/2025.».
- [9] «Klusowski J. M,Tian P. M:" *Large Scale Prediction with Decision Trees*". Journal of the American Statistical Association,pp.525-537,2023».
- [10] «Wikipédia,« Drone » ,<https://fr.wikipedia.org/wiki/Drone>. Consulté le 20/10/2025,» [En ligne].
- [11] «« Mieux connaître les drones Avant-propos », Conférence ONERA, pp 3-34, [vers 2004],» [En ligne].
- [12] ««EASA Class 6 – Guidelines for Drone Pilots ». ENAC guide, avril 2024, <https://www.enac.gov.it/app/uploads/2024/04/EASA-Classe-6-EN.pdf>, consulté le 20/02/2025».
- [13] «MOHAMMEDI et IRBAH, « Conception d'un auto pilote pour un drone léger type quadri-rotor ». Mémoire de Master aéronautique, option Avionique, Université de Blida, 2019».

Bibliographie

- [14] «Mario Esposito. « RoboBees : Harvard's Micro-Robots Revolutionizing Farming Practices ». The bLife Movement, 24 novembre 2023, <https://www.theblifemovement.com/robobees-harvards-micro-robo>, consulté le 20/02/2025».
- [15] «A,BELKADI: "COMMANDE D'UN UAV DE TYPE BIROTOR COAXIAL",Mémoire de Master aéronautique, option Avionique, Université de Blida, 2019».
- [16] «Samraj, S. « Types of Drones you didn't know existed! ». Skyrider Aerosolutions, 14 juin 2020,<https://www.skyrideraerosolutions.com/post/types-of-drones>, consulter le 21/02/2025,» 2020.
- [17] «F.Z. SAADAOUI "DESIGN OF INTELLIGENT MULTI-SENSOR DRONE DETECTION SYSTEM" ,Thèse doctorat en aéronautique, université de BLIDA,2024».
- [18] «Zen Technologies. « Classification of Drones Based on Endurance ». LinkedIn, article en ligne, 24 avril 2023,<https://www.linkedin.com/pulse/classification-drones-based-endurance-zen-technologies>, consulté le 22/02/2025».
- [19] «D.M. Patiuk,R.Oberle, "Ukraine-Russie : la guerre des drones",Magazine Diplomatie, pp(1-3),30 septembre 2024».
- [20] «Oledcomm,« Explore The Future Military Drone Technology », 11 décembre 2024, <https://www.oledcomm.net/blog/future-military-drone-technology/>, consulté le 22/02/2025».
- [21] «OTAN. « Renseignement, surveillance et reconnaissance interarmées (JISR) »,7 mars 2024. Disponible sur : https://www.nato.int/cps/fr/natohq/topics_111830.htm, consulté le 22/02/2025».
- [22] «TopGéo. « Topographie par drone », <https://www.topgeo.net/service/topographie-par-drone>, consulté le 22/02/2025».
- [23] M. B. Pouya, R. Diebre, G. Rambaldi, G. Zomboudry, F. Barry, M. Sedogo et F. Lompo, «Analyse comparative de l'agriculture de précision incluant l'utilisation de la technologie drone et de l'agriculture classique en matière de production de riz et de revenu des agriculteurs au Burkina Faso.Rapport de recherche, CTA, 11 juin 2020».
- [24] «MORITZ, Laurène BAUDOUIN et Marcel, "L'usage des drones par les sapeurspompiers : opportunités opérationnelles et risques juridiques', Projet juridique de COOPOL, Université de Lille, CNRS, France. [vers2018]».
- [25] «Rami, Cheraitia ,"Conception et réalisation d'un système de protection contre les incendies des forets à base d'un drone quadrirotor",Mémoire de Master Electronique option Instrumentation, Universite de Guelma, 2024».
- [26] «Ferguson, Laird D: "Guidelines for Drone Use: Infrastructure Inspections", Mémoire de Master en génie civil, Université de New Brunswick, septembre 2016».

Bibliographie

- [27] M. J. H. M. I. G. N. e. P. R. AL-BATTBOOTTI, «Surveillance des pipelines de pétrole et de gaz pendant la pandémie de COVID-19 à l'aide de véhicules aériens sans pilote. Université Politehnica de Bucarest, Faculté d'ingénierie en langues étrangères,15/11/2021,» 15 novembre 2021.
- [28] «Dhote, Jérémy, et Limbourg, Sabine, " Conception d'un réseau de drones destiné au transport de produits biomédicaux", conférence Transport Research Days 2019, Belgique, 23–24 mai 2019. Université de Liège – HEC Liège».
- [29] «Cyberjustice." Les drones entre menace à l'ordre public et respect de la vie privée : quelle réglementation ?", 23 août 2019».
- [30] «20 Minutes,"Belgique : Une livraison de drogue par drone en prison vire au fiasco',15 mai 2020, : <https://www.20minutes.fr/insolite/2779739-20200515-belgique-livraison-droque-drone-prison-vire-fiasco> consulté le 29/02/2025».
- [31] N. V. a. M. Martinez, «Drone carrying drugs crashes south of U.S. border,,» 23 janvier 2015.
- [32] «Dedrone News,"Tentative d'assassinat du président vénézuélien par des drones porteurs d'explosifs",5 août 2018,<https://fr.dedrone.com/press/response-to-venezuelan-drone-assassination-attempt>, consulté le 01/03/2025».
- [33] «Yousaf, J., Zia, H., Alhalabi, M., Yaghi, M., Basmaji, T., Al Shehhi, E., Gad, A., Alkhedher, M. et Ghazal, M. "Drone and Controller Detection and Localization" , Trends and Challenges in Robotic Applications, 12(24), 2022».
- [34] «"Detection of small drones with millimeter wave radar. Fraunhofer Institute for High Frequency Physics and Radar Techniques FHR",avril 2024».
- [35] W. M.-P. R. M. B. A.-V. W. G. A. a. J. A. P. Anibal Jara-Olmedo, «"Interface of Optimal Electro-Optical/Infrared for Unmanned Aerial Vehicles." In Developments and Advances in Defense and Security, edited by Smart Innovation, 372-380. April 2018».
- [36] «R. Bhatia, « Noise Pollution: Managing the Challenge of Urban Sounds », Earth Journalism Network, 20 mai 2014. <https://earthjournalism.net/resources/tipsheet/noise-pollution-managing-the-challenge-of-urban-sounds>, consulté 02/03/2025».
- [37] «Steeven JANNY, Solal NATHAN ,Wenqi SHU-QUARTIER "Introduction à l'apprentissage",culture Science de l'Ingénieur , école normale supérieure de Paris - Saclay,24/05/2022».
- [38] «Matuszak, J. . 7 applications robotiques et d'IA qui transforment le secteur de la santé.19 Janvier 2024. Consulté le 12/05//2025».
- [39] «Chollet, F. . Deep Learning with Python. Chapitre 1. 504 pages. Manning Publications. 2021».

Bibliographie

- [40] «Billard, A. G., Calinon, S., & Dillmann, R. "*Springer Handbook of Robotics. Chapitre 74 Learning from humans*". . Pages 1995–2014. Springer. 2016.».
- [41] «MAKHLOUF, Lazhar. L'apprentissage profond appliqué à la reconnaissance des anomalies mammaires. option Systèmes Informatiques. Université de Guelma, 2022.».
- [42] «Amos, Z. . Comment l'IA transforme la surveillance acoustique. Article en ligne, 3 min de lecture. 23 décembre 2024. Datafloq , Disponible sur – <https://datafloq.com/read/how-ai-transforming-acoustic-monitoring/> consulter le 12/05/2025».
- [43] «Amorós i Cortiella, M. Robust solutions for audio fingerprinting. Mémoire de Master, spécialité Technologies Avancées de Télécommunication, Universitat Politècnica de Catalunya – Escola Tècnica d'Enginyeria de Telecomunicació de Barcelona, 2023».
- [44] «<https://datasciencetoday.net/index.php/fr/machine-learning/109-ml-sup/178-les-arbres-de-decision-introduction>».
- [45] «M BELARBI Boucif,M TEMMOUN Alaa Eddine:' Etude comparative des algorithmes dédiés à la classification",option Réseaux et Ingénierie des Données , Université de Ain Temouchent,2022».
- [46] S. N. ., S.-Q. Steeven JANNY, «"Introduction à l'apprentissage",culture Science de l'Ingénieur , école normale supérieure de Paris -Saclay,24/05/2022».
- [47] «<https://www.maxicours.com/se/media/img/5/8/8/6/588611.png> Cnsulté le 05/05/2025».
- [48] «"Arbres de décision dans l'apprentissage automatique à l'aide de R", 15 min de lecture, 14 nov. 2024, consulté le07/05/2025».
- [49] «IBM. "Qu'est-ce qu'un arbre de décision ?" . <https://www.ibm.com/fr-fr/think/topics/decision-trees>. consulté le 05/05/2025».
- [50] «Blanchard, Torea." Caractérisation de drones en vue de leur localisation et de leur suivi à partir d'une antenne de microphones". Thèse de doctorat en acoustique, Le Mans Université, École doctorale Sciences pour l'Ingénieur (SPI), le 13 décembre 2019».
- [51] «C-UAS Hub, "La conception de l'hélice réduit la signature acoustique du drone", 28 janvier 2023. Disponible sur : <https://cuashub.com/fr/contenu/la-conception-de-lhelice-reduit-la-signature-acoustique-du-drone/>, consulte le 03/03/2025».
- [52] «Mrabet. M, M.Sliti, and L. Ben Ammar. "Machine learning algorithms applied for drone detection and classification: benefits and challenges." *Frontiers in Communications and Networks*, vol. 5, 17 October 2024».
- [53] «Baron.V, " Méthodes d'identification de sources acoustiques paramétriques par traitement du signal",Thèse de doctorat, INSA Lyon,2020.».

Bibliographie

- [54] «Blanchard, Torea, Thomas, Jean-Hugh, et Raoof, Kosai." *Caractérisation et Localisation de Drone à Partir d'un Réseau de Capteurs*". 14^e Congrès Français d'Acoustique (CFA 2018), Le Havre, France, pp. 1103–1109,23–27 avril 2018.».
- [55] «Herold, G. *In-flight directivity and sound power measurement of small-scale unmanned aerial systems*. Acta Acustica, vol. 6, n° 1, pp. 1–12, 2022.».
- [56] «« Rappels sur le son ». EasyZic, Disponible sur : <https://www.easyzic.com/dossiers/rappels-sur-le-son,h390.html> ; consulter le 24/04/2025».
- [57] «Padois Thomas." Sound source localisation in an anechoic wind-tunnel by two microphone array techniques: Beamforming and numerical time reversal". École de Technologie Supérieure, janvier 2011, Researchgate».
- [58] «Teglund, Jonas. Isolating Drone Frequencies in a Real-Time Drone Detection System. Mémoire de Master en Ingénierie Informatique, Université d'Uppsala, Suède, juin 2024».
- [59] S. Kümmitz, «"Sound of Surveillance: Enhancing Machine Learning-Driven Drone Detection with Advanced Acoustic Augmentation", January 2024 researchgate, consulté le 27/04/2025».
- [60] F. S. BESSAHRA Manal Maria, «"Détecteur de drones non conventionnels",Mémoire Master en aéronautique , option avionique, Université de BLIDA ,2020».
- [61] «Shelkovenko, Nikolai. Réduire les vibrations des drones :" Comprendre l'importance des hélices à équilibrage dynamique". Vibromera, 18 septembre 2023, <https://vibromera.eu/fr/exemple/reduire-les-vibrations-des-drones-comprendre-li>,consulter le 28/04/2025».
- [62] «<https://www.kaggle.com/datasets/chrisfilo/urbansound8k>».
- [63] «<https://www.kaggle.com/datasets/yehiellevi/dataset-balanced-n-weighted-final>».