

وزارة التعليم العالي والبحث العلمي
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique



جامعة عبد الحميد ابن باديس مستغانم
Université Abdelhamid Ibn Badis de Mostaganem

كلية العلوم والتكنولوجيا
Faculté des Sciences et de la Technologie



N° d'ordre : M2...../GE/2026

MEMOIRE DE FIN D'ÉTUDES DE MASTER ACADEMIQUE

Filière : Télécommunication

Spécialité : Système des Télécommunications

Thème

**Conception et développement d'une architecture d'intelligence
artificielle pour la détection des feux de forêts à partir des images
satellitaires**

Présenté par :

M. REGUIEG Ahmed.

M. BERRACHE Mohamed El Amine.

Soutenu le 22/06/2026 à 10:00 devant le jury composé de :

Président : M. TARGUI Boubakar.

Université de Mostaganem

Examineur : M. ABED Mansour.

Université de Mostaganem

Encadreur : Mme MEHIDI Aïcha.

Université de Mostaganem

Co-Encadreur : Mme MIMI Malika.

Université de Mostaganem

Année Universitaire : 2025/2026

REMERCIEMENTS

Au nom d'Allah, le Tout-Puissant et le Très Miséricordieux, que nous louons pour avoir guidé nos pas dans l'accomplissement de ce modeste travail.

Alhamdoulillah (الحمد لله).

Nous exprimons notre profonde gratitude à notre encadrante Mme MEHIDI Aïcha ainsi qu'à notre Co-encadrante Mme MIMI Malika pour leur aide précieuse, leur disponibilité constante, leur encadrement rigoureux et leurs conseils avisés qui nous ont accompagnés tout au long de la réalisation de ce mémoire.

Nous tenons à remercier chaleureusement les membres du jury, à savoir Monsieur TARGUI Boubakar et Monsieur ABED Mansour, qui nous font l'honneur d'examiner ce travail et de l'enrichir par leurs remarques et leurs suggestions pertinentes.

Nous tenons également à remercier sincèrement tous nos enseignants pour la qualité de l'enseignement qu'ils nous ont dispensé tout au long de notre parcours universitaire, nous permettant ainsi d'acquérir une formation solide et efficace.

Nous tenons à exprimer notre sincère gratitude au Laboratoire de recherche Signaux et Systèmes (LSS) de l'Université de Mostaganem et à tous ses membres pour l'aide qu'ils nous ont apportée en termes d'équipement, d'espaces de travail, de commodités, de conseils, d'orientation et de suivi jusqu'à l'achèvement de nos projets de fin d'études master.

Enfin, nous adressons nos plus sincères remerciements à nos familles. Nous tenons tout particulièrement à remercier nos parents, nos frères et sœurs. Ils nous ont apporté un soutien, de la patience et des encouragements. Cela a été le cas tout au long de nos études. Mais c'est surtout durant cette dernière année que nous avons ressenti leur aide. Nous n'oublions pas non plus toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce mémoire. Qu'elles trouvent ici l'expression de notre profonde reconnaissance.

Dédicace

A

Mon cher père et ma chère mère

*Pour l'éducation et le grand amour dont ils m'ont entouré depuis ma
naissance.*

Pour leurs patiences et leurs sacrifices.

*Pour m'avoir poussé jusqu'au bout et pour avoir été toujours un confort
moral.*

A tous mes frères et toutes mes sœurs à mes neveux et à mes nièces

A toute ma famille proche soit-elle ou lointaine

A tous ceux qui m'ont aidé afin de réaliser ce travail

A tous ceux que j'aime et qui m'aiment

A tous ceux-ci je dédie ce travail.

Mr. REGUIEG Ahmed

Dédicace

Je dédie ce modeste travail à mes chers parents,

À mes chères sœurs,

À mes encadrants qui m'ont accompagné tout au long de ce travail

*À mes enseignants, ainsi qu'à mes collègues et à toutes les personnes
qui m'ont soutenu et accompagné tout au long de mon parcours.*

*Leurs encouragements, leurs conseils, leur confiance et leur présence ont
été une source de motivation précieuse qui m'a permis d'avancer et
d'atteindre ce niveau.*

*Qu'ils trouvent ici l'expression de ma profonde gratitude et de mon
sincère respect.*

Mr. BERRACHE Mohamed El Amine

Chapitre I :	page
Figure I.1 - Ingrédients pour déclencher un feu.	06
Figure I.2 - Les combustibles d'un feu de forêt.	07
Figure I.3 - Rôle de la topographie et du vent sur la propagation du feu.	08
Figure I.4 - Les différents types de feux.	11
Figure I.5 - Les différentes formes des feux de forêt.	12
 Chapitre II :	
Figure II.1 - Télédétection passive et active.	18
Figure II.2 - Le processus de télédétection.	20
Figure II.3 - L'onde électromagnétique.	21
Figure II.4 - Le spectre électromagnétique.	22
Figure II.5 - Deux images, dans le visible et dans l'infrarouge.	23
Figure II.6 - Les interactions rayonnement / matière.	25
Figure II.7 - Signature spectrale.	25
Figure II.8 - Résolution spatiale.	31
Figure II.9 - Résolution spectrale.	31
Figure II.10 - Résolution temporelle.	32
 Chapitre III :	
Figure III.1 - Intelligences Artificielles, Machine Learning, et l'apprentissage profond.	37
Figure III.2 - Les réseaux de neurones anticipation (Feedforward) –MLP.	43
Figure III.3 - Les réseaux de neurones convolutifs (CNN).	44
Figure III.4 - Les réseaux de neurones récurrents (RNN).	44

Figure III.5 - Architecture du transformeur.	44
Figure III.6 - Les autoencodeurs.	45
Figure III.7 - Architecture générale d'un CNN.	46
Figure III.8 - Application d'un filtre.	46
Figure III.9 - Caractéristique d'un filtre.	47
Figure III.10 - Taille d'un filtre.	47
Figure III.11 - Opérations de sous-échantillonnage : Max Pooling et Average Pooling.	47
Figure III.12 - Fonction ReLU (Rectified Linear Unit).	48
Figure III.13 - Couche fully-connected.	48
 Chapitre IV :	
Figure IV.1 - Schéma général de conception.	56
Figure IV.2 - Résultat de prétraitement des images satellitaires : (a) image originale, (b) image après le prétraitement.	60
Figure IV.3 - Architecture de modèle DenseNet201.	62
Figure IV.4 - Architecture de model MobileNet.	64
Figure IV.5 - Évolution de la perte Loss et de l'Accuracy de l'entraînement et de la validation du modèle DenseNet201.	74

LISTE DES TABLEAUX

Chapitre II :	page
Tableau II.1 - Résolutions spatiale et spectrale du satellite IKONOS.	27
Tableau II.2 - Résolutions spatiale et spectrale du satellite LANDSAT-7.	27
Tableau II.3 - Résolutions spatiale et spectrale du satellite SPOT-5.	28
Tableau II.4 - Résolutions spatiale et spectrale du satellite Sentinel-2.	29
 Chapitre IV :	
Tableau IV.1 - Résultats MSE et PSNR après le prétraitement de quelques images Satellites.	59
Tableau IV.2 - Comparaison des performances des modèles DenseNet et MobileNet utilisant les couches Flatten et Global Average Pooling (GAP).	72
Tableau IV.3 - Performances des modèles DenseNet201 et MobileNet (couche GAP) pour différentes tailles de l'ensemble de test.	73
Tableau IV.4 - performances des modèles DenseNet201 et MobileNet.	74

Adam	Adaptive Moment Estimation
AI / IA	Artificial Intelligence / Intelligence Artificielle
ANN	Artificial Neural Network
CNN	Convolutional Neural Network
CV	Computer Vision
DGF	Direction Générale des Forêts
DL	Deep Learning
DNN	Deep Neural Network
FN	False Negative
FP	False Positive
FPR	False Positive Rate
GAP	Global Average Pooling
GPU	Graphics Processing Unit
GRU	Gated Recurrent Unit
IEEE	Institute of Electrical and Electronics Engineers
LSTM	Long Short-Term Memory
MDP	processus de décision markoviens
ML	Machine Learning
MLP	Multi-Layer Perceptron
MODIS	Moderate Resolution Imaging Spectroradiometer
MSE	Mean Squared Error
NASA	National Aeronautics and Space Administration
NBR	Normalized Burn Ratio
NLP	Natural Language Processing
PSNR	Peak Signal to Noise Ratio
ReLU	Rectified Linear Unit
REM	Rayonnement électromagnétique
RGB	Red, Green, Blue
RNN	Recurrent Neural Network
SAR	Synthetic Aperture Radar
SGBD	Système de Gestion de Base de Données

SGD	Stochastic Gradient Descent
TALN	traitement automatique du langage naturel
TN	True Negative
TP	True Positive
TPU	Tensor Processing Unit
UAV	Unmanned Aerial Vehicle
VIIRS	Visible Infrared Imaging Radiometer Suite

Les avancées dans les technologies d'imagerie satellitaire issues de la télédétection ont un impact majeur sur la surveillance de l'environnement et la prévention des risques. Aujourd'hui, les séries temporelles d'images, qu'elles soient optiques ou radar, jouent un rôle crucial dans le suivi de la dynamique de la source terrestre. Elles sont particulièrement utiles pour repérer, caractériser et suivre l'évolution de phénomènes rapides, tels que les feux de forêts. Grâce à ces données, il est possible d'analyser des indicateurs environnementaux, d'identifier des zones à risque et d'observer l'évolution spatiotemporelle des feux depuis leur apparition jusqu'à leur propagation. Elles jouent un rôle essentiel dans l'amélioration des stratégies de gestion des alertes précoces et d'intervention contre les incendies.

L'objectif du sujet proposé est d'extraire des informations significatives à partir d'images satellites (Sentinel-2 API), aussi bien optiques que radar, afin de développer un outil d'analyse de texture destiné à améliorer la détection et le suivi des feux de forêts. Il est possible de concevoir cet outil de manière spécifique ou de l'améliorer et de l'élaborer en se basant sur les bibliothèques et les outils existants, en particulier en Python. L'enjeu principal est d'utiliser cet outil pour analyser et classifier différents types d'images d'occupation du sol, dans une perspective d'aide à la compréhension et à la gestion des phénomènes de feux dans ce cadre. Notre projet s'articule autour de deux axes. Le premier consiste à appliquer une étape de prétraitement visant à améliorer la qualité des images au moyen d'algorithmes spatialisés. La deuxième concerne la mise en place d'une procédure de détection et de classification utilisant des méthodes d'intelligence artificielle, en particulier les méthodes de Deep Learning, afin d'optimiser la reconnaissance et les caractéristiques des zones impactées.

Mots Clés : Télédétection, Images satellitaire, réseau de neurones convolutifs (CNN), prétraitement, classification binaire, détection.

ABSTRACT

Environmental monitoring and risk prevention are being greatly impacted by the advancements in satellite imaging technologies derived from remote sensing. Monitoring the Earth's surface dynamics relies heavily on time series of images, whether optical or radar. They are particularly useful for detecting, characterizing, and tracking the progression of rapid phenomena, such as forest fires. The use of this data allows for the analysis of environmental indicators, identification of areas at risk, and observation of fires' spatiotemporal evolution from their onset through their spread. Their role is crucial when it comes to improving early warning and fire response strategies.

The aim of this project is to extract meaningful information from satellite images (Sentinel-2 API), both optical and radar, in order to develop a texture analysis tool designed to improve the detection and monitoring of forest fires. The design and development of this tool can be done either from scratch or with the help of existing libraries and tools, particularly in Python. The main challenge is to use this tool to analyze and categorize different types of land-cover imagery, which would help in understanding and managing fire phenomena in this context. Our project is structured around two main areas. A pre-processing stage is applied in the first step to improve image quality using spatial algorithms. The second concern pertains to the implementation of a detection and classification procedure that utilizes Artificial Intelligence methods (AI), particularly deep learning methods, to enhance the recognition and classification of concerned areas.

Keywords: Remote sensing, satellite imagery, convolutional neural networks (CNN), pre-processing, binary classification, detection.

تُحدث التطورات في تقنيات التصوير الفضائي المستمدة من الاستشعار عن بُعد تأثيرًا كبيرًا على مراقبة البيئة والوقاية من المخاطر. واليوم تلعب سلاسل الصور الزمنية، سواء كانت بصرية أو رادارية، دورًا حاسمًا في رصد ديناميكيات الأرض وهي مفيدة بشكل خاص في تحديد وتوصيف ومتابعة تطور الظواهر السريعة، مثل حرائق الغابات و بفضل هذه البيانات، يمكن تحليل المؤشرات البيئية، وتحديد المناطق المعرضة للخطر، ومراقبة التطور المكاني والزمني للحرائق منذ ظهورها وحتى انتشارها. وهي تلعب دورًا أساسيًا في تحسين استراتيجيات إدارة الإنذارات المبكرة والتدخل لمكافحة الحرائق.

الهدف من الموضوع المقترح هو استخراج معلومات ذات دلالة من صور الأقمار الصناعية، سواء البصرية أو الرادارية، من أجل تطوير أداة لتحليل النسيج تهدف إلى تحسين الكشف عن حرائق الغابات ومتابعتها. من الممكن تصميم هذه الأداة ويتمثل بشكل خاص في تحسينها وتطويرها بالاعتماد على المكتبات والأدوات الموجودة في PYTHON ، لا سيما في لغة التحدي الرئيسي في استخدام هذه الأداة لتحليل وتصنيف أنواع مختلفة من صور استخدام الأراضي، بهدف المساعدة في فهم وإدارة ظاهرة الحرائق في هذا السياق. يدور مشروعنا حول محورين. الأول يتمثل في تطبيق مرحلة معالجة مسبقة تهدف إلى تحسين جودة الصور باستخدام خوارزميات مكانية. والثاني يتعلق بوضع إجراء للكشف والتصنيف باستخدام أساليب الذكاء الاصطناعي، ولا سيما أساليب التعلم العميق، من أجل تحسين التعرف على المناطق المتضررة وخصائصه.

كلمات مفتاحية : الاستشعار عن بعد، صور الأقمار الصناعية، المعالجة المسبقة، التصنيف الثنائي، الشبكات العصبية التلافيفية.

TABLE DES MATIÈRES

Liste des figures	A
Liste des tableaux	C
Abréviation	D
Résumé	F
Abstract	G
Résumé en arabe	H

INTRODUCTION GÉNÉRALE 01

CHAPITRE I : GÉNÉRALITES SUR LES FEUX DE FORETS

I.1.Introduction	05
I.2. Définition	06
I.3. Combustibles d'un feu de forêt	06
I.3.1. Les maquis	07
I.3.2. Les garrigues	07
I.3.3. Les landes	07
I.4. L'origine des feux de forêt	08
I.4.1. Facteurs de prédisposition	08
I.4.2. Facteurs d'éclosion	09
I.5. Les cause des feux de forêt	09
I.5.1. Causes naturelles	09
I.5.2. Causes humaines	09
I.5.2.1. Causes involontaires	09
I.5.2.2. Causes volontaires	10
I.6. Les différents types de feux	10
I.6.1. Les feux de sol	10
I.6.2. Les feux de surface	10
I.6.3. Les feux de cimes	10
I.6.4. Les feux avec braises	10
I.7. Les sauts et la vitesse de feu	11

I.8. Différentes formes des feux de forêt	12
I.8.1. Forme circulaire	12
I.8.2. Forme elliptique allongée	12
I.8.3. Forme irrégulière	12
I.9. Conséquences des incendies de forêt	13
I.9.1. Sur le milieu humain et leurs biens	13
I.9.2. La faune	13
I.9.3. La flore	13
I.9.4. Le sol	13
I.9.5. Le climat	14
I.9.6. L'atmosphère	14
I.10. Gestion du risque de feux de forêts	
I.10.1. Surveillance planétaire	14
I.10.2. La prévision	14
I.10.3. La prévention	14
I.10.3.1. La résorption des causes de feux de forêts	15
I.10.3.2. Surveiller les massifs forestiers	15
I.10.3.3. L'équipement des massifs forestiers	15
I.10.3.4. La prise en compte du risque dans l'aménagement du territoire	15
I.11. Conclusion	15

CHAPITRE II : NOTIONS FONDAMENTALES DE TÉLÉDETECTION SPATIALE

II.1. Introduction	17
II.2. La Télédétection	17
II.2.1. Définition	17
II.2.2. Types de la télédétection	17
II.2.2.1. Télédétection passive A	18
II.2.2.2. Télédétection active B	18
II.3. Principes de base de la télédétection	18
II.4. Rayonnement électromagnétique et spectre	20
II.4.1. Rayonnement électromagnétique (REM)	20
II.4.2. Spectre électromagnétique	21
II.4.2.1. Domaine Visible	22
II.4.2.2. Domaine infrarouge	22
II.4.2.3. Domaine hyperfréquence ou micro-onde	23

II.5. Les interactions rayonnement / matière	23
II.5.1. Émission	23
II.5.2. Réflexion	24
II.5.3. Absorption	24
II.5.4. Transmission	24
II.5.5. Réfraction	24
II.5.6. Signature spectrale	25
II.6. Les différents systèmes de la télédétection	26
II.6.1. IKONOS	26
II.6.2. LANDSAT	26
II.6.3. SPOT	27
II.6.4. Sentinel-2	28
II.7. Caractéristiques d'un satellite de télédétection (orbite et sa fauchée)	29
II.7.1. Orbitographie	29
II.7.2. Fauchée du satellite	30
II.8. La résolution des images satellitaires	30
II.8.1. Résolution spatiale	30
II.8.2. Résolution spectrale	31
II.8.3. Résolution temporelle	32
II.9. Domaine d'applications de la télédétection	32
II.9.1. Applications de la télédétection pour la détection et la cartographie des incendies	
	de forêts
	32
II.10. Conclusion	33

CHAPITRE III : LES APPORTS MAJEURS DE L'INTELLIGENCE ARTIFICIELLE

III.1. Introduction	35
III.2. Intelligence artificielle	35
III.2.1. Définition d'intelligence artificielle	35
III.2.2. L'impact de l'Intelligence Artificielle	35
III.2.3. Les axe de l'intelligence artificielle	36
III.2.3.1. L'approche humaine	36
III.2.3.2. L'approche rationnelle	37
III.2.4. Distinction entre IA, apprentissage automatique et apprentissage profond	37
III.3. Apprentissage automatique (Machine Learning)	37

III.3.1. Définition	37
III.4. Fonctionnement de l'apprentissage automatique	38
III.5. Types d'apprentissage automatique	38
III.5.1. Apprentissage supervisée	38
III.5.2. Apprentissage non supervisé	39
III.5.3. Apprentissage semi-supervisé	39
III.5.4. Apprentissage par renforcement	40
III.6. Deep Learning	40
III.6.1. Définition	40
III.6.2. Historique de Deep Learning	40
III.6.3. Domaine d'application du Deep Learning	41
III.6.4. Forces et faiblesses du Deep Learning	42
III.6.4.1. Points forts de l'apprentissage profond	42
III.6.4.2. Limites de l'apprentissage profond	42
III.6.5. Principe de fonctionnement de Deep Learning	43
III.6.6. Architectures et algorithmes	43
III.7. Les réseaux de neurones convolutifs	45
III.7.1. Les différentes couches d'un CNN	46
III.7.1.1. La couche de convolution	46
III.7.1.2. La couche de Pooling	47
III.7.1.3. La couche de correction ReLU	47
III.7.1.4. La couche fully-connected	47
III.8. La fonction du cout	49
III.8.1. Définition	49
III.8.2. Réduction de la fonction du cout	49
III.9. Transfer Learning	49
III.9.1. Principe	50
III.9.2. Les avantage du Transfer Learning	50
III.9.3. Les principaux défis liés au Transfer Learning	50
III.10. Les travaux de recherche basés sur l'architecture CNN pour la détection des feux de forêts à partir des images satellitaires.	50
III.11. Conclusion	51

CHAPITRE IV : MISE EN ŒUVRE DE LA DÉTECTION

IV.1. Introduction	53
IV.2. Environnement de développement	53
IV.2.1. Outil de développement : PYTHON	54

IV.2.1.1. Définition	54
IV.2.2. Base de données	54
IV.3. Élaboration du système de détection	54
IV.3.1. Objectif	54
IV.3.2. Schéma général de conception	55
IV.3.2.1 Prétraitement des images	55
IV.3.2.1.1. Importance du prétraitement	55
IV.3.2.1.2. Correction des artefacts	57
IV.3.2.1.3. Normalisation des intensités	57
IV.3.2.1.4. Réduction du bruit	57
IV.3.2.1.5. Évaluation de l'efficacité du processus de prétraitement	57
IV.3.2.2. Détection et classification des images satellitaires	61
IV.3.2.2.1 Les architectures du DenseNet201& MobileNet : Modèles (CNN)	61
IV.3.2.2.1.1. Le modèle DenseNet201	61
IV.3.2.2.1.2. MobileNet	63
IV.3.2.2.1.3. Différence entre MobileNet et DenseNet	65
IV.3.2.2.2 Évaluation des métriques de détection	65
IV.4. Résultats expérimentaux	69
IV.4.1. Présentation des résultats	69
IV.4.2. Analyse et discussion	70
IV.7. Conclusion	75

CHAPITRE V : CONCLUSION GÉNÉRALE

V.1. Récapitulatif	76
V.2. Perspectives	78

BIBLIOGRAPHIE	79
----------------------	----

INTRODUCTION GENERALE

Depuis toujours, l'être humain s'efforce de se situer dans son environnement, de comprendre les phénomènes naturels et d'explorer l'espace qui l'entoure. Grâce aux avancées technologiques, notamment dans le domaine spatial, il est aujourd'hui possible d'observer la Terre de manière globale et continue à travers les images satellitaires. Ces dernières offrent une vision synoptique permettant d'analyser les transformations de la surface terrestre liées à des phénomènes naturels ou anthropiques tels que la déforestation, l'urbanisation ou encore les incendies de forêt.

L'évolution des technologies de télédétection, en particulier le développement des systèmes satellitaires et la diversification des capteurs à haute résolution spatiale, spectrale et temporelle, représente une opportunité majeure pour l'identification et l'analyse des objets géographiques. Les images satellitaires constituent ainsi une source d'information riche et variée, largement exploitée dans différents domaines tels que la classification, la détection d'objets et la reconnaissance de scènes.

Parmi les meilleurs usages de la télédétection se trouve la surveillance des feux de forêts, qui constituent un enjeu majeur tant sur le plan environnemental que socio-économique. Souvent rapides et difficiles à prévoir, ces phénomènes exigent des outils performants pour assurer une détection précoce et suivre leur propagation. L'exploitation des séries temporelles d'images satellitaires permet d'analyser les indicateurs environnementaux, d'identifier les zones à risque et de suivre l'évolution spatiotemporelle des feux depuis leur apparition jusqu'à leur extension.

Cependant, la complexité et la grande variabilité des images satellitaires rendent leur analyse difficile par des méthodes classiques. C'est dans ce contexte que les approches basées sur l'intelligence artificielle, et en particulier le Deep Learning, ont connu un essor considérable. Les réseaux de neurones convolutifs (CNN) offrent des performances remarquables pour l'extraction automatique de caractéristiques pertinentes et la classification des images, ce qui les rend particulièrement adaptés à la détection des feux de forêt.

L'objectif de ce travail est de concevoir et de développer une architecture d'intelligence artificielle dédiée à la détection des incendies de forêt à partir d'images satellitaires, qu'elles soient optiques. Cette approche vise à exploiter les techniques avancées de traitement d'images ainsi que les modèles d'apprentissage profond afin d'améliorer la précision et la rapidité de détection.

Dans cette optique, notre projet s'articule autour de deux axes principaux. Le premier consiste en une étape de prétraitement des images visant à améliorer leur qualité et à faciliter l'extraction des informations pertinentes à l'aide d'algorithmes spécialisés. Le second axe porte sur le développement d'une méthode de classification fondée sur des techniques d'intelligence artificielle, telles que DenseNet201 et MobileNet, afin de détecter automatiquement les zones touchées et de suivre l'évolution des incendies.

Ce manuscrit est constitué de quatre chapitres organisés comme suit :

- Dans le premier chapitre de ce travail, nous proposons une présentation générale des feux de forêt, en mettant en lumière leurs principales causes, leurs types ainsi que leurs impacts environnementaux et socio-économiques sur différents milieux, ainsi que les solutions visant à réduire les risques d'incendie.
- Le deuxième chapitre, à caractère introductif, propose une série de définitions visant à faciliter la compréhension des images satellitaires, notamment à travers leurs processus ainsi que les concepts de rayonnement électromagnétique et de spectre. Il aborde également le fonctionnement de la télédétection ainsi que quelques notions de base du traitement des images satellitaires, telles que les différents types d'images et leurs caractéristiques.
- Les principaux concepts de l'intelligence artificielle appliqués à l'analyse des images satellitaires constituent l'objectif du troisième chapitre. Il introduit d'abord l'intelligence artificielle, son impact et ses différents axes, puis distingue ses formes de mise en œuvre. Il aborde ensuite l'apprentissage automatique, ses principes et ses différents types. Il détaille ensuite les réseaux de neurones convolutifs (CNN), leur architecture et leurs principales couches, ainsi que la fonction de coût utilisée pour optimiser les modèles. Enfin, il introduit le Transfer Learning, ses avantages et ses défis, et présente quelques travaux de recherche utilisant les CNN pour la détection des feux de forêt à partir d'images satellitaires.

- Au sein du quatrième chapitre, nous présentons la mise en œuvre des approches proposées, à savoir DenseNet201 et MobileNet, ainsi que les expérimentations réalisées et l'évaluation des résultats obtenus. Pour évaluer les résultats du prétraitement, nous utilisons des critères d'évaluation tels que le rapport signal sur bruit de crête (PSNR) et l'erreur quadratique moyenne (MSE). Dans le cadre de la classification, plusieurs métriques d'évaluation permettent de mesurer les performances.

Ce manuscrit se conclut par une synthèse des résultats obtenus, ainsi que par des perspectives futures visant à améliorer les performances du système proposé et à étendre son application dans le domaine de la surveillance environnementale.

CHAPITRE I

GENERALITES SUR LES FEUX DE FORETS

Les feux de forêt représentent un risque naturel majeur en raison de leur propagation rapide et de leurs impacts significatifs sur l'environnement et les populations. La surveillance et la détection de ces incendies reposent aujourd'hui sur des technologies avancées, notamment la télédétection spatiale, qui permet d'exploiter les images satellitaires pour observer et analyser la surface terrestre.

Ce chapitre présente une vue générale des feux de forêt, en mettant en évidence leurs principales causes, leurs conséquences sur les différents milieux ainsi que les solutions et stratégies permettant de réduire les risques associés.

I.1. Introduction

Les feux de forêt sont des incendies qui se déclarent et se propagent dans des zones boisées, des forêts, des broussailles ou des prairies. Ils peuvent être d'origine naturelle, comme ceux provoqués par la foudre, ou d'origine humaine, par négligence (cigarettes, feux de camp mal éteints) ou actes volontaires. Ces incendies constituent un phénomène naturel dans certains écosystèmes, mais ils peuvent devenir extrêmement destructeurs lorsqu'ils échappent à tout contrôle. Avec le réchauffement climatique, les périodes de sécheresse et les fortes chaleurs augmentent la fréquence et l'intensité des feux de forêt, notamment dans la région de la méditerranée.

En Europe, le feu est la principale menace naturelle qui pèse sur les forêts et les zones boisées du bassin méditerranéen. Il a causé des dommages plus importants aux forêts. On note que la situation empire nettement en Grèce (de 12000 à 39000 ha), en Italie (de 43000 à 118000 ha), en Espagne (de 50000 à 208000 ha) et dans l'ex-Yougoslavie (de 5000 à 13000 ha). Par contre, au Portugal, la situation s'est également dégradée. Les forêts ravagées couvrent environ un tiers de la surface de l'ensemble des pays européens (185 millions d'hectares) [1], [2].

En Afrique, les feux de forêt sont catastrophiques, on appelle souvent l'Afrique « le continent du feu » en raison de la fréquence et de l'étendue des incendies. La majorité des feux incontrôlés en Afrique concerne des écosystèmes adaptés aux feux. Des recherches récentes effectuées par l'administration nationale de l'aéronautique et de l'espace des États-Unis (NASA), environ 130 millions d'hectares de savanes et de formations herbeuses brûlent chaque année en Afrique. Les incendies les plus intensifs sont concentrés dans la zone subtropicale humide qui comprend l'Angola, le sud de la République démocratique du Congo, la Zambie, le nord du Mozambique et le sud de la République-Unie de Tanzanie. Il est estimé que, pendant la saison des incendies de l'année 2000, la superficie brûlée au sud de l'équateur a dépassé les 200 millions d'hectares.

En Algérie, les feux de forêt sont un problème important, surtout pendant l'été lorsque les températures sont très élevées et que la sécheresse est intense. Les régions du nord du pays, où se trouvent la majorité des forêts, sont les plus touchées.

Certaines zones comme la Kabylie, notamment la wilaya de Tizi Ouzou, ou encore Bejaïa et Jijel, connaissent régulièrement de graves incendies. Ces feux sont souvent causés par la forte chaleur, le vent, mais aussi par des activités humaines (imprudence, brûlage de déchets, parfois actes volontaires). Selon la Direction Générale des Forêts (DGF), 811 incendies se

sont déclarés dans 32 wilayas de l'Algérie en 2025. Ces feux ont détruit 40 001 hectares de forêts, de maquis et de broussailles. Les régions les plus touchées sont le nord et le centre du pays, pour cause de leur exposition à des conditions climatiques extrêmes comme la sécheresse, les vents violents et les fortes températures. Ces catastrophes ont engendré d'importants dégâts matériels et écologiques principalement dans les zones dotées d'un accès difficile pour une intervention rapide [3].

I.2. Définition

Un feu de forêt est un incendie incontrôlé qui se propage dans des milieux naturels comme les forêts, les broussailles ou les prairies. On parle d'incendie de forêt lorsqu'il affecte au moins un hectare de végétation composée d'arbres ou d'arbustes, mais ce terme peut aussi inclure des formations plus petites comme le maquis, la garrigue ou les landes [4].

Ces incendies peuvent être causés naturellement (par exemple par la foudre) ou par des activités humaines, telles qu'une négligence avec une cigarette ou un feu mal maîtrisé. Leur déclenchement repose sur la présence simultanée de trois éléments : la chaleur, l'oxygène et un combustible.

Lorsque ces conditions sont réunies, le feu peut se propager rapidement et causer des dégâts importants sur l'environnement, les biens et les populations [5].




Figure I.1 - Ingrédients pour déclencher un feu.

I.3. Combustibles d'un feu de forêt

Les combustibles d'un feu de forêt sont les matières végétales qui peuvent brûler et alimenter le feu. Ce sont généralement des plantes sèches, des herbes, des feuilles, des arbustes ou des arbres. Plus la végétation est sèche, plus elle est inflammable.

Parmi les principaux combustibles, on trouve : Le maquis, la garrigue et les landes sèches (ainsi que présenté à la figure I.2) sont des combustibles naturels qui favorisent le développement des feux de forêt, surtout en été lorsque la végétation est sèche [6].

I.3.1. Les maquis

Le maquis est une végétation dense composée d'arbustes et de petits arbres toujours verts. On le trouve surtout dans les régions méditerranéennes, comme en Algérie.

Il est formé de plantes comme le lentisque, le chêne-liège ou l'arbousier. Le maquis brûle facilement car il est épais, riche en huiles végétales et souvent exposé à la sécheresse.

I.3.2. Les garrigues

La garrigue est une végétation plus basse et moins dense que le maquis. Elle est composée de petits arbustes, de plantes aromatiques (thym, romarin) et d'herbes sèches. Elle pousse sur des sols pauvres et secs. En période de forte chaleur, la garrigue devient très inflammable et favorise la propagation rapide du feu.

I.3.3. Les landes

Les landes sont des terrains couverts de végétation basse comme les bruyères et les ajoncs. Elles se trouvent dans certaines régions au climat humide ou tempéré. En période sèche, les landes deviennent aussi un combustible important, car leurs plantes fines et sèches s'enflamment rapidement



Les maquis



Les garrigues



Les landes

Figure I.2 - Les combustibles d'un feu de forêt.

I.4. L'origine des feux de forêt

L'origine d'un incendie est souvent difficile à identifier en raison de l'absence de preuves matérielles concrètes. Un feu de forêt est une combustion qui se développe sans contrôle, dans le temps et dans l'espace. De nombreux facteurs de prédisposition, d'éclosion et de propagation contribuent à la manifestation de ce phénomène.

I.4.1. Facteurs de prédisposition

Les facteurs de prédisposition regroupent l'ensemble des conditions qui rendent un milieu propice à l'apparition et à la propagation des incendies. Parmi eux, les conditions climatiques jouent un rôle majeur : des températures élevées, une sécheresse persistante, une faible humidité de l'air et des vents forts favorisent à la fois l'ignition et la rapide extension des flammes [7].

La nature de la végétation constitue également un élément déterminant, notamment la présence de végétaux secs, l'accumulation de feuilles mortes et de bois desséché, ainsi que des formations telles que les maquis, garrigues et landes, particulièrement inflammables.

Enfin, les caractéristiques topographiques influencent fortement le comportement du feu : les terrains montagneux et les pentes accentuées facilitent sa progression, notamment vers les zones en altitude (ainsi que la montre la figure I.3). Dans les régions méditerranéennes, ces différents facteurs sont fréquemment réunis durant la saison estivale, ce qui accroît considérablement le risque d'incendie.




Figure I.3 - Rôle de la topographie et du vent sur la propagation du feu.

I.4.2. Facteurs d'éclosion

Les facteurs d'éclosion sont les causes directes qui déclenchent le feu. Les incendies peuvent être causés par des facteurs naturels comme la foudre et la chaleur extrême, mais ils sont le plus souvent dus à des causes humaines telles que les cigarettes mal éteintes, les feux de camp, le brûlage de déchets ou de champs, les étincelles provenant d'outils ou de lignes électriques, ainsi que les actes volontaires (incendies criminels) [6].

I.5. Les cause des feux de forêt

Les feux de forêt peuvent être provoqués par des causes naturelles ou humaines. Dans la plupart des pays, les causes humaines sont les plus fréquentes [5].

I.5.1. Causes naturelles

Les causes naturelles des incendies sont principalement associées à des phénomènes climatiques ou environnementaux.

La foudre constitue la cause naturelle la plus fréquente : lorsqu'un éclair frappe un arbre ou une zone particulièrement sèche, il peut déclencher un départ de feu. Par ailleurs, des conditions de chaleur extrême, combinées à une sécheresse prolongée, favorisent également l'apparition d'incendies, notamment lorsque la végétation est fortement desséchée.

Enfin, bien que plus rares, certains phénomènes naturels, comme les éruptions volcaniques, peuvent également être à l'origine d'incendies dans certaines régions du monde.

I.5.2. Causes humaines

Les causes humaines représentent la majorité des feux de forêt. Elles peuvent être involontaires ou volontaires.

I.5.2.1. Causes involontaires

Les causes involontaires regroupent les incendies provoqués par négligence ou imprudence. Parmi les plus fréquentes figurent les cigarettes mal éteintes, les feux de camp laissés allumés, le brûlage de déchets, les étincelles produites par des outils ou des machines agricoles, ainsi que les défauts de lignes électriques. Ces types d'incendies sont particulièrement fréquents pendant la période estivale.

I.5.2.2. Causes volontaires

Les causes volontaires désignent les incendies déclenchés intentionnellement. Ils peuvent résulter d'actes criminels, de feux allumés pour nettoyer des terrains agricoles, ou encore de conflits et actes de sabotage. Ces incendies volontaires peuvent entraîner des dommages très graves, tant sur le plan humain qu'environnemental.

I.6. Les différents types de feux

Les feux de forêt ne se propagent pas tous de la même manière. Selon la partie de la végétation qui brûle, on distingue plusieurs types de feux.

I.6.1. Les feux de sol

Les feux de sol brûlent la matière organique située sous la surface du sol, comme les racines, l'humus ou la tourbe. Ils progressent lentement et sont parfois difficiles à détecter. De plus, ils peuvent durer longtemps. Même s'ils sont peu visibles, ces feux peuvent reprendre et alimenter d'autres types d'incendies.

I.6.2. Les feux de surface

Les feux de surface sont les plus fréquents. Ils affectent les herbes sèches, les broussailles, les feuilles mortes et les petits arbustes. Leur propagation est rapide, ils sont sensibles au vent et peuvent parfois se transformer en feux de cimes. Ce type de feu est courant dans les régions méditerranéennes, comme en Algérie.

I.6.3. Les feux de cimes

Les feux de cimes, ou feux de couronne, atteignent la partie supérieure des arbres. Ils brûlent les branches et les feuilles en hauteur, sont très rapides et violents, et difficiles à maîtriser. Ces incendies sont les plus dangereux, car ils se propagent rapidement d'un arbre à l'autre.

I.6.4. Les feux avec braises

Les feux avec braises produisent des morceaux incandescents transportés par le vent. Ces braises peuvent parcourir de longues distances, provoquer de nouveaux départs de feu et rendre l'incendie plus difficile à contrôler.

Les feux de forêt peuvent brûler le sol, la surface ou les cimes des arbres comme indiqué dans la figure I.4. Plus le feu atteint les hauteurs et produit des braises, plus il devient dangereux et difficile à éteindre [8].



Figure I.4 - Les différents types de feux.

I.7. Les sauts et la vitesse de feu

Lors d'un incendie de forêt, le feu peut se propager de différentes manières. Deux phénomènes importants sont les sauts de feu et la vitesse de propagation.

- Les sauts de feu se produisent lorsque des braises ou des débris enflammés sont transportés par le vent et tombent plus loin, provoquant un nouveau départ de feu. Les principales causes des sauts de feu sont les vents forts, des feux de cimes très intenses et un terrain en pente. Les braises peuvent parcourir plusieurs centaines de mètres, parfois plus d'un kilomètre. Ce phénomène rend l'incendie plus difficile à contrôler, car il peut franchir des routes, des rivières ou même des pare-feux.

- La vitesse de propagation d'un incendie dépend de plusieurs facteurs. Les conditions climatiques jouent un rôle important : température élevée, sécheresse et vent fort, ce dernier étant le principal facteur d'accélération. Le type de végétation influence également la rapidité du feu : les herbes sèches provoquent une propagation rapide, le maquis dense entraîne une propagation intense, et les forêts hautes présentent un risque de feux de cimes. Le relief intervient aussi : en montée, le feu progresse plus vite, tandis que sur terrain plat, il avance plus lentement. En été, dans des pays méditerranéens comme l'Algérie, la vitesse du feu peut devenir très élevée à cause de la chaleur et du vent.

Les sauts de feu et la vitesse de propagation rendent les incendies de forêt imprévisibles et dangereux. C'est pourquoi une surveillance rapide et une intervention précoce sont essentielles pour limiter les dégâts.

I.8. Différentes formes des feux de forêt

La forme d'un feu de forêt est essentiellement déterminée par le vent, le relief, la nature de la végétation ainsi que par l'intensité de l'incendie. On identifie généralement trois formes principales [8]:

I.8.1. Forme circulaire

La forme circulaire apparaît lorsque le vent est faible ou absent, le terrain est plat et la végétation homogène, ainsi que le montre la figure I.5(1). Dans ce cas, le feu se propage presque de manière égale dans toutes les directions autour du point de départ. Cette forme est généralement plus stable et plus facile à maîtriser.

I.8.2. Forme elliptique allongée

La forme elliptique allongée est la plus fréquente. Elle se produit lorsque le vent souffle dans une direction précise et que le terrain présente une pente. Le feu avance alors plus rapidement dans le sens du vent ou en montée, formant une sorte d'ovale étiré. La partie la plus active s'appelle la tête du feu, où la propagation est la plus rapide et la plus dangereuse, voir figure I.5(2).

I.8.3. Forme irrégulière

La forme irrégulière apparaît lorsque le vent change de direction, que le relief est accidenté, que la végétation est variée ou qu'il existe des obstacles naturels ou artificiels, comme le met en évidence la figure I.5(3). Cette forme est la plus difficile à prévoir et à contrôler. Elle est fréquente dans les régions montagneuses du nord de l'Algérie.

La forme d'un feu de forêt dépend donc des conditions naturelles et climatiques. Plus le vent est fort et le terrain accidenté, plus la forme devient allongée ou irrégulière, rendant l'incendie plus dangereux.




Figure I.5 - Les différentes formes des feux de forêt.

I.9. Conséquences des incendies de forêt

Les incendies de forêt entraînent des impacts importants sur l'environnement, la société et le climat. Voici les principaux effets selon les différentes composantes de l'écosystème [9], [10].

I.9.1. Sur le milieu humain et leurs biens

Les incendies de forêt menacent directement les habitations et les infrastructures. Les villages et les villes proches des forêts peuvent être détruits, entraînant des pertes économiques importantes et obligeant parfois les habitants à fuir leurs maisons. Ces incendies peuvent provoquer la destruction d'habitations et d'infrastructures, mettre en danger la vie des habitants et des pompiers, causer des pertes économiques considérables dans l'agriculture, le tourisme et l'exploitation forestière, et déplacer les populations dans les zones touchées.

I.9.2. La faune

Les incendies touchent fréquemment les animaux, dont beaucoup ne parviennent pas à échapper aux flammes. La destruction de leurs habitats entraîne une baisse de certaines populations et perturbe l'équilibre écologique local. En outre, ces feux provoquent la mort d'animaux incapables de fuir, réduisent la biodiversité et contribuent à la disparition d'habitats naturels essentiels à la survie de plusieurs espèces.

I.9.3. La flore

Les feux détruisent les arbres, les arbustes et la végétation basse. Certaines plantes mettent plusieurs années à repousser, et les forêts peuvent perdre leur diversité si les incendies sont répétés ou très intenses. Cela entraîne la destruction de la végétation, la réduction de la régénération naturelle, surtout après des feux intenses, et augmente le risque d'invasion par des espèces non indigènes.

I.9.4. Le sol

Le sol devient vulnérable après un incendie. La matière organique est détruite, ce qui diminue sa fertilité. De plus, le risque d'érosion et de glissements de terrain augmente, surtout dans les zones montagneuses. Les sols s'appauvrissent, l'érosion et les glissements deviennent plus probables, et la perte de fertilité complique la régénération de la végétation.

I.9.5. Le climat

Les feux de forêt contribuent au réchauffement local et global. La combustion des arbres libère du dioxyde de carbone (CO₂), modifiant l'humidité et la température de la région affectée. Cela entraîne une augmentation locale des températures, une diminution temporaire de l'humidité et contribue au changement climatique par l'émission de CO₂.

I.9.6. L'atmosphère

Les incendies de forêt perturbent fortement l'atmosphère en émettant de grandes quantités de gaz à effet de serre, comme le CO₂, le méthane et le protoxyde d'azote. Leurs fumées contiennent aussi des particules fines et du carbone noir, qui retiennent la chaleur et accélèrent la fonte des glaciers.

Ils libèrent également des oxydes d'azote et des composés organiques volatils, favorisant la formation d'ozone, un polluant nocif. De plus, les aérosols issus des incendies modifient le cycle de l'eau en influençant les nuages et les précipitations [11]. Chaque année, ces feux rejettent entre 1,5 et 2 milliards de tonnes de CO₂ dans le monde. En 2023, un record a été atteint au Canada avec près d'un milliard de tonnes émises. Enfin, cette pollution est responsable de plus de 330 000 décès prématurés par année.

I.10. Gestion du risque de feux de forêts

I.10.1. Surveillance planétaire

La surveillance planétaire utilise des satellites et des technologies modernes pour détecter les départs de feu rapidement, même dans des zones éloignées. Cela permet d'alerter les autorités et d'intervenir avant que l'incendie ne devienne incontrôlable.

I.10.2. La prévision

La prévision consiste à estimer le risque d'incendie en fonction des conditions climatiques, de la sécheresse, du vent et de la végétation. Elle permet de planifier les interventions et de déclencher des alertes précoces pour protéger les populations et les forêts.

I.10.3. La prévention

La prévention a pour objectif de diminuer les risques d'incendie et d'en limiter la propagation. Elle repose sur la mise en œuvre de plusieurs mesures, notamment :

I.10.3.1. La résorption des causes de feux de forêts

Il s'agit de réduire les actions humaines dangereuses, comme le brûlage incontrôlé de déchets, les feux de camp mal éteints ou les cigarettes jetées dans la forêt. La sensibilisation de la population est essentielle.

I.10.3.2. Surveiller les massifs forestiers

Les massifs forestiers sont surveillés par des patrouilles, des tours de guet et des caméras pour détecter rapidement les départs de feu et intervenir immédiatement.

I.10.3.3. L'équipement des massifs forestiers

Les forêts sont équipées de pare-feu, citernes, points d'eau et routes d'accès pour les pompiers afin de faciliter la lutte contre les incendies et protéger les zones à risque.

I.10.3.4. La prise en compte du risque dans l'aménagement du territoire

Lors de la planification urbaine ou agricole, le risque de feux de forêt doit être intégré dans l'aménagement. Cela signifie éloigner les habitations des zones très inflammables, créer des zones tampons et protéger les espaces naturels.

La gestion du risque de feux de forêt combine technologie, organisation et sensibilisation. La surveillance, la prévision et la prévention permettent de limiter les pertes humaines, matérielles et environnementales, surtout dans des pays exposés aux incendies comme les pays de la méditerranée.

I.11. Conclusion

Dans ce chapitre, nous avons présenté des généralités sur les feux de forêt, en mettant en évidence des chiffres significatifs concernant les forêts détruites par les incendies à travers le monde. Cela montre que les incendies ont joué un rôle déterminant dans l'état actuel des écosystèmes forestiers, contribuant à façonner leurs paysages.

Nous avons également identifié les principales causes d'éclosion du feu, ainsi que leurs conséquences sur différents milieux. En outre, nous avons étudié les combustibles des incendies, ainsi que les différents types et formes que peut prendre le feu en milieu forestier. Ainsi, la surveillance à l'échelle mondiale, la prévision et la prévention demeurent essentielles pour réduire les risques liés aux feux de forêt.

CHAPITRE II

NOTIONS FONDAMENTALES DE TELEDETECTION SPATIALE

La télédétection, basée sur l'imagerie satellitaire, est un outil essentiel pour observer la Terre et suivre l'évolution de ses surfaces dans le temps. Elle joue un rôle important dans la détection et le suivi des feux, en fournissant des informations précieuses pour analyser les phénomènes environnementaux tels que le changement climatique, les catastrophes naturelles et les problèmes écologiques.

Elle contribue également à la gestion des ressources naturelles et à la lutte contre la déforestation.

Dans ce chapitre, nous aborderons les principes de la télédétection, ses composants, ses capteurs, les types d'images et leurs résolutions, ainsi que les différentes étapes et corrections du processus de télédétection.

II.1. Introduction

La télédétection est une technique d'observation à distance qui permet de collecter et d'analyser des informations sur la surface terrestre et l'atmosphère à partir du rayonnement électromagnétique réfléchi, émis ou transmis par les objets. Elle repose sur des capteurs embarqués sur des satellites ou des plateformes aériennes et exploite différents domaines du spectre électromagnétique (visible, infrarouge, micro-ondes). Les interactions entre le rayonnement, la matière et l'atmosphère, ainsi que les caractéristiques des satellites (orbite, fauchée) et des images (résolutions spatiale, spectrale, radiométrique et temporelle), déterminent la qualité et la précision des données obtenues.

Grâce à ces informations, la télédétection offre de nombreuses applications, telles que la cartographie des forêts, le suivi des ressources naturelles, l'agriculture de précision, l'urbanisme, la surveillance climatique et la gestion des catastrophes naturelles. Elle permet également une observation continue et à grande échelle, facilitant l'analyse des dynamiques environnementales dans le temps et l'espace. Ainsi, la télédétection constitue un outil essentiel pour la surveillance, la planification et la gestion durable de l'environnement, notamment dans la prévention et le suivi des feux de forêt.

II.2. La télédétection

II.2.1. Définition

Télé signifie « à distance » et détection veut dire « découvrir ». La télédétection est une discipline scientifique et technique qui permet d'acquérir, à distance et sans contact direct, des informations quantitatives et qualitatives sur des objets, des surfaces ou des phénomènes. Elle repose sur la mesure et l'analyse du rayonnement électromagnétique émis, réfléchi ou diffusé par la surface terrestre ou l'atmosphère, à l'aide de capteurs embarqués sur des plateformes aériennes ou satellitaires. Les données collectées sont ensuite traitées et interprétées afin d'extraire des informations utiles à l'observation et à la gestion des systèmes environnementaux [2].

II.2.2. Types de la télédétection

La télédétection peut être classée en deux grandes catégories selon l'origine de la source d'énergie utilisée pour l'observation : la télédétection passive et la télédétection active (cf. figure II.1) [2].

II.2.2.1. Télédétection passive A

La télédétection passive utilise une source d'énergie naturelle, principalement le rayonnement solaire. Les capteurs enregistrent soit l'énergie réfléchiée par la surface terrestre, notamment dans le domaine du visible et de l'infrarouge proche, soit le rayonnement thermique émis par les objets. Ce type de télédétection dépend donc des conditions d'éclairement (alternance jour/nuit) et peut être influencé par les conditions atmosphériques, en particulier la présence de nuages. Elle est largement exploitée par de nombreux satellites optiques multispectraux, notamment ceux développés par la NASA et l'European Space Agency, pour l'étude de la végétation, des sols, des eaux et de la température de surface.

II.2.2.2. Télédétection active B

La télédétection active, quant à elle, repose sur l'émission d'un signal électromagnétique par le capteur lui-même, puis sur l'analyse de l'énergie renvoyée par la surface. Elle fonctionne indépendamment de l'éclairage solaire et peut être utilisée de jour comme de nuit. De plus, elle est peu affectée par les conditions météorologiques, notamment dans le domaine des micro-ondes. Ce type de télédétection, comme les systèmes radar (SAR), permet d'étudier la structure, la rugosité et l'humidité des surfaces [10].




Figure II.1- Télédétection passive et active.

II.3. Principes de base de la télédétection

La télédétection désigne l'ensemble des techniques permettant d'observer et d'analyser la surface terrestre à distance, sans contact direct, en exploitant les interactions entre le rayonnement électromagnétique et les objets observés. Elle s'appuie principalement

sur des capteurs embarqués sur des satellites, des avions ou des drones, capables de collecter des données précises sur l'état et l'évolution de l'environnement. Cette approche offre ainsi un moyen efficace de surveiller, cartographier et comprendre les phénomènes naturels et les transformations des territoires. Voici les principes fondamentaux, comme représenté sur la figure II.2 [12], [13] :

1. Source d'énergie/illumination : Une source d'énergie est requise pour éclairer l'objet d'intérêt ou pour lui fournir un rayonnement électromagnétique.

Le premier principe est la source d'énergie. Pour observer une cible (forêt, sol agricole, océan, zone urbaine...), il faut qu'elle soit illuminée. Dans la plupart des cas, cette source est naturelle, comme le Soleil, ce qui correspond à la télédétection passive. Dans d'autres situations, notamment avec les radars, l'énergie est émise par le capteur lui-même, ce qui relève de la télédétection active.

2. Rayonnement/énergie et atmosphère : Tout au long de son trajet, du point de départ à la destination, le rayonnement interagit avec les particules atmosphériques avant d'atteindre la surface terrestre. Au cours de ce trajet, il peut être absorbé, diffusé ou transmis, ce qui modifie l'énergie initiale et influence la qualité des données recueillies. Une fois que l'énergie parvient de l'objet au capteur, une deuxième interaction peut se produire.

3. Objet d'étude : Lorsque le rayonnement atteint la surface terrestre, il interagit avec différents objets et phénomènes physiques tels que la végétation, l'eau, le sol ou les bâtiments. Il peut alors être réfléchi, absorbé ou transmis. Chaque type d'objet possède une signature spectrale spécifique, permettant de les différencier lors de l'analyse.

4. Capteur enregistreur de rayonnement : Un capteur placé à distance de l'objet d'étude doit capturer le rayonnement électromagnétique émis ou réfléchi par la cible.

5. Système de traitement des données : Les données enregistrées par le capteur doivent être acheminées (habituellement de manière électronique) vers un centre de réception et de traitement, où l'énergie mesurée est convertie en une image utilisable.

6. Analyse et interprétation : À la suite du traitement des données en télédétection, l'image est soumise à une analyse et une interprétation visuelle et/ou numériques en vue d'obtenir des informations sur l'objet étudié.

7. Applicaton pratique : En fin de compte, le processus vise à exploiter les informations tirées des images pour approfondir la compréhension de la cible, découvrir des éléments jusqu'alors méconnus ou contribuer à la résolution de problèmes [13].




Figure II.2 - Le processus de télédétection.

II.4. Rayonnement électromagnétique et spectre

Le rayonnement électromagnétique regroupe l'ensemble des ondes utilisées en télédétection, caractérisées par leur longueur d'onde et leur fréquence. Ces ondes constituent le spectre électromagnétique, qui s'étend des ondes radio aux rayons gamma. L'analyse de ce spectre permet d'extraire des informations sur la nature et les propriétés des surfaces observées.

II.4.1. Rayonnement électromagnétique (REM)

Le Soleil est la principale source de rayonnement électromagnétique, généré par des réactions de fusion nucléaire en son cœur. Cette énergie se propage dans l'espace sous forme d'ondes électromagnétiques, sans support matériel, et se manifeste notamment sous forme de lumière visible.

Le rayonnement électromagnétique peut être décrit selon deux approches complémentaires : la théorie corpusculaire, qui le considère comme un flux de photons, et la théorie ondulatoire, qui le représente comme une onde constituée de champs électrique et

magnétique perpendiculaires (comme indiqué à la figure II.3) se propageant à la vitesse de la lumière ($c \approx 3 \times 10^8$ m/s dans le vide). Il est principalement caractérisé par sa longueur d'onde (λ), correspondant à la distance entre deux points identiques successifs, et sa fréquence (ν), qui représente le nombre d'oscillations par seconde, exprimé en Hertz (Hz).

En télédétection, le rayonnement électromagnétique constitue la base de l'observation, car les capteurs mesurent l'énergie réfléchie ou émise par les objets terrestres [14].




Figure II.3 - L'onde électromagnétique.

II.4.2. Spectre électromagnétique

Le spectre électromagnétique correspond à l'ensemble des rayonnements classés selon leur longueur d'onde ou leur fréquence (cf. figure II.4). Le soleil émet un spectre composé de différents types de rayonnements qui atteignent la terre. Toutefois, l'atmosphère agit comme un filtre naturel : elle laisse principalement passer la lumière visible, une partie de l'infrarouge et certaines ondes radio, tandis qu'elle absorbe la majorité des rayons ultraviolets ainsi que presque tous les rayons X et gamma, notamment grâce à la couche d'ozone. Cette filtration protège les êtres vivants des rayonnements nocifs. En télédétection, on exploite principalement trois grandes régions du spectre électromagnétique [14].




Figure II.4- Le spectre électromagnétique.

II.4.2.1. Domaine Visible

La lumière visible émise par le soleil est une lumière blanche composée de plusieurs couleurs correspondant au spectre visible, allant du violet au rouge. Elle peut être décomposée en différentes couleurs (rouge, orange, jaune, vert, bleu, indigo et violet) lorsqu'elle traverse un prisme ou lors de la formation d'un arc-en-ciel. Ce domaine du spectre correspond aux longueurs d'onde comprises entre environ $0,4\ \mu\text{m}$ et $0,7\ \mu\text{m}$, c'est-à-dire les rayonnements perceptibles par l'œil humain. Il s'étend du violet ($\approx 0,4\ \mu\text{m}$) jusqu'au rouge ($\approx 0,7\ \mu\text{m}$), en passant par le bleu et le vert.

En télédétection, ce domaine du spectre est particulièrement important pour l'observation des paysages, la cartographie de l'occupation du sol et l'analyse visuelle des images satellitaires (comme le montre la figure II.5). Il permet d'identifier directement les caractéristiques naturelles et artificielles visibles à l'œil nu, facilitant ainsi l'interprétation des scènes observées.

II.4.2.2. Domaine infrarouge

Le domaine infrarouge est une partie du spectre électromagnétique située entre la lumière visible et les micro-ondes. Ce rayonnement est invisible pour l'œil humain, mais il est principalement associé à la chaleur émise par les objets, y compris le soleil et la terre. La longueur d'onde du rayonnement infrarouge est généralement comprise entre environ $0,7$ micromètre et 1 millimètre (tel que présenté à la figure II.5 [15]). Le domaine infrarouge est subdivisé en plusieurs sous-domaines selon les longueurs d'onde et les applications [16]:

- Infrarouge proche ($0,7 - 1,3\ \mu\text{m}$) : L'infrarouge proche correspond à des longueurs d'onde d'environ $0,7$ à $1,4$ micromètre. Il est très proche de la lumière visible et une partie du rayonnement émis par le soleil dans cette zone atteint la terre. Ce domaine est utilisé en télédétection, en imagerie satellitaire et pour l'étude de la végétation.
- Infrarouge moyen ($1,3 - 3\ \mu\text{m}$) : L'infrarouge moyen couvre environ $1,4$ à $3\ \mu\text{m}$ (parfois jusqu'à $8\ \mu\text{m}$ selon la classification). Ce rayonnement est fortement lié à la chaleur émise par les objets. Il est utilisé dans les capteurs thermiques, l'analyse chimique et certaines applications de spectroscopie pour identifier les molécules.
- Infrarouge thermique ($3 - 14\ \mu\text{m}$) : L'infrarouge lointain s'étend d'environ $3\ \mu\text{m}$ jusqu'à 1 millimètre. Il est principalement associé au rayonnement thermique des objets froids comme

la surface de la terre ou les nuages. Ce domaine est utilisé en astronomie, en météorologie et dans certaines technologies d'imagerie thermique.




Figure II.5 - Deux images, dans le visible et dans l'infrarouge.

II.4.2.3. Domaine hyperfréquence ou micro-onde

Le domaine hyperfréquence ou micro-onde couvre les longueurs d'onde comprises entre 1 mm et 1 m et est principalement exploité par les systèmes radar. Ce domaine présente plusieurs caractéristiques importantes : il fonctionne de jour comme de nuit, est peu sensible aux nuages, et permet d'analyser la rugosité et l'humidité des surfaces. Un exemple typique de ce type de télédétection est fourni par les satellites radar développés par l'Agence spatiale européenne, qui permettent d'obtenir des informations précises même dans des conditions météorologiques difficiles.

II.5. Les interactions rayonnement / matière

Lorsque le rayonnement électromagnétique atteint un objet (sol, végétation, eau, bâtiment...), plusieurs phénomènes physiques peuvent se produire. Ces interactions sont fondamentales en télédétection car elles permettent d'identifier et de caractériser les objets observés (selon la figure II.6) [17].

II.5.1. Émission

L'émission est le processus par lequel un objet libère de l'énergie sous forme de rayonnement électromagnétique. Tous les corps dont la température est supérieure au zéro absolu émettent un rayonnement, dont l'intensité dépend à la fois de la température et de la nature du matériau. En télédétection, ce phénomène est principalement exploité dans le domaine infrarouge thermique, permettant d'estimer la température de surface du sol, de l'eau ou des zones urbaines.

II.5.2. Réflexion

La réflexion correspond au renvoi d'une partie du rayonnement incident par la surface d'un objet. On distingue deux types principaux : la réflexion spéculaire, qui se produit sur des surfaces lisses comme l'eau calme et renvoie le rayonnement de manière directionnelle, et la réflexion diffuse, qui se produit sur des surfaces rugueuses comme le sol ou la végétation et disperse le rayonnement dans plusieurs directions. En télédétection, la quantité et le spectre de l'énergie réfléchie varient selon la nature de l'objet, ce qui permet de l'identifier et de caractériser les surfaces observées.

II.5.3. Absorption

L'absorption se produit lorsque l'énergie incidente est captée par la matière et transformée en une autre forme d'énergie, le plus souvent en chaleur. Par exemple, la végétation absorbe fortement la lumière rouge pour la photosynthèse, tandis que l'eau absorbe principalement l'infrarouge proche. Ce phénomène est essentiel en télédétection, car il influence la signature spectrale des objets et permet de différencier les types de surfaces.

II.5.4. Transmission

La transmission correspond à la partie du rayonnement qui traverse un matériau sans n'être absorbée ni réfléchie. Par exemple, l'eau claire laisse passer partiellement certaines longueurs d'onde, et les matériaux transparents comme le verre permet au rayonnement visible de les traverser. Ce phénomène est important en télédétection pour comprendre quelles longueurs d'onde peuvent atteindre ou traverser certains objets et surfaces.

II.5.5. Réfraction

La réfraction est le changement de direction d'un rayonnement lorsqu'il passe d'un milieu à un autre, comme de l'air à l'eau. Ce phénomène dépend de l'angle d'incidence et de l'indice de réfraction du milieu traversé. Par exemple, un objet immergé dans l'eau semble visuellement décalé par rapport à sa position réelle en raison de la réfraction. En télédétection, la réfraction peut influencer la précision de la localisation et la restitution des images, notamment pour les surfaces aquatiques.




Figure II.6 - Les interactions rayonnement / matière.

II.5.6. Signature spectrale

La signature spectrale correspond à la réponse spécifique d'un objet aux différentes longueurs d'onde du spectre électromagnétique. Elle décrit comment l'absorption, la réflexion ou l'émission de l'objet varie en fonction de la longueur d'onde. Par exemple, la végétation absorbe fortement le rouge et réfléchit beaucoup dans l'infrarouge proche, l'eau présente une faible réflexion sur presque tout le spectre, et le sol reflète progressivement selon sa composition (comme illustré à la figure II.7). Chaque objet possède donc une signature spectrale propre, ce qui permet de l'identifier et de le classer en télédétection.




Figure II.7 - Signature spectrale.

La signature spectrale des feux correspond au profil de rayonnement électromagnétique émis par les flammes à différentes longueurs d'onde, ce qui la distingue des autres surfaces comme la végétation ou l'eau. Le feu émet principalement dans le proche et moyen infrarouge (0,7 – 3 μm), zones où l'énergie thermique est maximale et facilement détectable par les satellites. Il émet également dans la lumière visible (0,4 – 0,7 μm), donnant l'apparence rouge-orange de la flamme, et dans l'infrarouge thermique ou lointain (3 – 15 μm), qui permet de détecter la chaleur résiduelle même après que la flamme n'est plus visible.

Cette signature unique est utilisée pour la détection d'incendies à distance, la surveillance forestière, l'analyse de la propagation des feux et la prévention des risques. Grâce à la signature spectrale, les satellites comme MODIS ou VIIRS peuvent identifier et suivre les incendies, même à travers la fumée ou la nuit [17].

II.6. Les différents systèmes de la télédétection

II.6.1. IKONOS

Le satellite commercial IKONOS est exploité par la société GeoEye, basée en Virginie, aux États-Unis, et a été mis en service en 1999. Par la suite, le satellite OrbView-3 a été lancé en 2003. Toutefois, en raison d'une défaillance de son système de caméras, il a cessé d'acquérir de nouvelles images en 2007, selon SpaceToday.net (2007). Le satellite GeoEye-1, initialement connu sous le nom d'OrbView-5, a ensuite été placé en orbite en septembre 2008.

Le satellite IKONOS offre une résolution spatiale de 1 mètre en mode panchromatique et de 4 mètres en mode multispectral. Les bandes multispectrales enregistrées couvrent le bleu, le vert, le rouge et le proche infrarouge. Son temps de revisite varie entre trois et cinq jours [2] et [18].

Tableau II.1- Résolutions spatiale et spectrale du satellite IKONOS.

Mode	Canal	Bande spectrale	Résolution Spatiale
Panchromatique	PAN	0,45 - 0,90 μm (vis et proche infrarouge)	1 m
Multispectral	1	0,45 - 0,53 μm (bleu)	4 m
	2	0,52 - 0,61 μm (vert)	4 m
	3	0,64 - 0,72 μm (rouge)	4 m
	4	0,77 - 0,88 μm (proche infrarouge)	4 m

II.6.2. LANDSAT

Le programme LANDSAT est une série de satellites, développée par la NASA et gérée par l'institut des études géologique des États-Unis (USGS), pour l'observation de la Terre. Le premier satellite LANDSAT-1 a été lancé le 23 juillet 1972, par la suite, une série

de satellites a été mise en œuvre jusqu'à la dernière version LANDSAT-7 lancée le 15 avril 1999 [2], [18].

Tableau II.2- Résolutions spatiale et spectrale du satellite LANDSAT-7

Mode	Canal	Bande spectrale	Résolution Spatiale
Panchromatique	PAN	0,45 - 0,90 μm (vis et proche infrarouge)	15 m
Multispectral	1	0,45 - 0,52 μm (bleu)	28,5 m
	2	0,52 - 0,60 μm (vert)	28,5 m
	3	0,63 - 0,69 μm (rouge)	28,5 m
	4	0,76 - 0,90 μm (proche infrarouge)	28,5 m
	5	1,55 - 1,75 μm (moyen infrarouge)	28,5 m
	6	10,40 - 12,50 μm (infrarouge thermique)	28,5 m
	7	2,08 - 2,35 μm (moyen infrarouge)	28,5 m

II.6.3. SPOT

Le programme SPOT (Satellite Pour l'Observation de la Terre) est une série de satellites d'observation de la Terre initiée par la France en 1978 et développée par le CNES (Centre National d'Études Spatiales) en collaboration avec la Belgique et la Suède. Il constitue l'un des premiers programmes européens dédiés à la télédétection à haute résolution. Le premier satellite, SPOT-1, a été lancé le 22 février 1986, marquant le début d'une longue série d'observations de la surface terrestre. Par la suite, plusieurs satellites (SPOT-2, SPOT-3, SPOT-4 et SPOT-5) ont été successivement mis en orbite, assurant une continuité des acquisitions jusqu'au lancement de SPOT-5 le 3 mai 2002 [2], [18].

Les satellites SPOT se distinguent par leur capacité à fournir des images de haute qualité avec différentes résolutions spatiales et une revisite régulière, grâce notamment à leur capacité de pointage latéral. Ils ont permis de nombreuses applications dans des domaines variés tels que la cartographie, l'agriculture, la gestion des ressources naturelles, l'aménagement du territoire et la surveillance de l'environnement. Ainsi, le programme SPOT

a joué un rôle majeur dans le développement et la démocratisation de la télédétection à l'échelle mondiale.

Tableau II.3- Résolutions spatiale et spectrale du satellite SPOT-5.

Mode	Canal	Bande spectrale	Résolution Spatiale
Super-mode panchromatique	SM-PAN	(0,48 - 0,71 μm)	2,5 m
Panchromatique	PAN	(0,48 - 0,71 μm)	5 m
Multispectral	1	0,50 - 0,59 μm (vert)	10 m
	2	0,61 - 0,68 μm (rouge)	10 m
	3	0,78 - 0,89 μm (proche infrarouge)	10 m
	4	1,58 - 1,75 (moyen infrarouge)	20 m

II.6.4. Sentinel-2

Sentinel-2 est une série de satellites d'observation de la Terre de l'Agence spatiale européenne développée dans le cadre du programme Copernicus dont les deux premiers exemplaires ont été mis en orbite en 2015 et 2017. L'objectif du programme est de fournir aux pays européens des données complètes et actualisées leur permettant d'assurer le contrôle et la surveillance de l'environnement. Les satellites Sentinel-2 constituent une des composantes spatiales de ce programme qui comprend également notamment les Sentinel-1 (observation radar tout temps) et Sentinel-3. Ils doivent fournir l'imagerie optique haute résolution permettant l'observation des sols (utilisation des sols, végétation, zones côtières, fleuves, etc.) ainsi que le traitement des situations d'urgence (catastrophes naturelles...) [2], [18].

Tableau II.4- Résolutions spatiale et spectrale du satellite Sentinel-2.

Bande	Résolution spatiale	Résolution spectrale
B1 - Coastal aerosol	60 m	0.43 - 0.45 μm
B2 - Blue	10 m	0.45 - 0.51 μm

B3 - Green	10 m	0.53 - 0.59 μm
B4 - Red	10 m	0.64 - 0.68 μm
B5 - Red Edge 1	20 m	0.69 - 0.71 μm
B6 - Red Edge 2	20 m	0.73 - 0.75 μm
B7 - Red Edge 3	20m	0.77 - 0.79 μm
B8 - NIR	10 m	0.78 - 0.86 μm
B8A - Narrow NIR	20 m	0.85 - 0.88 μm
B9 - SWIR - Cirrus	60 m	1.36 - 1.38 μm
B10 - SWIR 2	20 m	1.57 - 1.65 μm
B11 - SWIR 2	20 m	2.10 - 2.30 μm

II.7. Caractéristiques d'un satellite de télédétection (orbite et sa fauchée)

Un satellite est un objet artificiel placé en orbite autour de la Terre pour accomplir une mission précise (communication, navigation, météorologie, observation...). Un satellite de télédétection est spécialement conçu pour observer la surface terrestre à distance grâce à des capteurs optiques, infrarouges ou radar. Il enregistre l'énergie réfléchie ou émise par la Terre afin de produire des images et des données utilisées en agriculture, cartographie, gestion des ressources naturelles, surveillance environnementale et prévision météorologique. Des exemples connus sont Landsat 8, Sentinel-2 et Sentinel-1. Ces satellites fournissent des informations régulières, précises et répétitives sur l'évolution de notre planète [19].

Pour un satellite de télédétection, deux caractéristiques fondamentales déterminent la zone couverte et la qualité des données : l'orbite et la fauchée.

II.7.1. Orbitographie

L'orbitographie décrit la trajectoire d'un satellite autour de la terre et joue un rôle clé en télédétection, car elle influence la couverture, la fréquence de revisite et les conditions d'éclairement. Les principales orbites sont les orbites polaires, qui permettent une couverture globale du globe, les orbites géostationnaires, offrant une observation continue d'une même

région, et les orbites héliosynchrones, assurant des conditions d'éclairement constantes. Ces orbites sont définies par des paramètres tels que l'altitude, l'inclinaison et la période orbitale.

II.7.2. Fauchée du satellite

La fauchée correspond à la largeur de la bande de surface terrestre observée par un satellite lors d'un seul passage. Elle dépend principalement de l'altitude du satellite et de l'angle d'ouverture du capteur. Plus le satellite est bas et plus le capteur est focalisé, plus la fauchée est étroite et la résolution spatiale élevée. À l'inverse, un satellite à plus haute altitude couvre une bande plus large, mais avec une résolution généralement plus faible.

Par exemple, un satellite en orbite basse comme Sentinel-2 possède une fauchée large (environ 290 km) permettant de couvrir rapidement de grandes surfaces, tandis que des satellites d'observation à très haute résolution ont souvent une fauchée plus réduite pour obtenir des images plus détaillées.

II.8. La résolution des images satellitaires

La résolution d'une image satellitaire définit la capacité d'un satellite à distinguer des détails spatiaux, spectraux ou temporels. Elle est essentielle pour déterminer l'utilité des images selon les applications.

II.8.1. Résolution spatiale

La résolution spatiale d'une image satellitaire correspond à la taille minimale d'un objet à la surface de la Terre pouvant être distingué. Elle est généralement exprimée en mètres ou centimètres (ex : 30 m, 10 m, 1 m).

En télédétection, la notion d'échelle utilisée en photographie aérienne est remplacée par celle de résolution spatiale, qui traduit le niveau de détail des images. Cette résolution correspond à la plus petite surface observable au sol, appelée pixel. Plus la résolution spatiale est fine (valeur faible), plus les détails visibles sont précis. Toutefois, une amélioration de la résolution s'accompagne généralement d'une réduction de la surface couverte par l'image : le gain en précision se fait donc au détriment de la vue d'ensemble.

En pratique, la résolution spatiale joue un rôle essentiel en télédétection, car elle permet d'identifier avec précision des éléments tels que les routes, les bâtiments ou les parcelles agricoles. Dans le cas des feux de forêt, elle facilite également la détection de foyers de petite

taille, contribuant ainsi à une surveillance plus efficace et détaillée (tel que présenté dans la figure II.7).




Figure II.7 - Résolution spatiale.

II.8.2. Résolution spectrale

La résolution spectrale d'un capteur satellitaire correspond à sa capacité à distinguer différentes longueurs d'onde du spectre électromagnétique. Elle dépend du nombre de bandes spectrales enregistrées ainsi que de leur largeur. Chaque capteur observe un ensemble de bandes spécifiques, telles que le bleu, le rouge ou le proche infrarouge, et plus le nombre de bandes est élevé et leur largeur étroite, plus l'information spectrale est détaillée, permettant une meilleure identification des matériaux et des phénomènes présents à la surface terrestre (voir figure II.8). À titre d'exemple, le satellite Landsat 8 est un capteur multispectral qui dispose de plusieurs bandes (entre 4 et 11 selon les capteurs embarqués), tandis que le capteur Hypérion est un capteur hyper spectral offrant plus de 200 bandes très étroites.

Cette capacité améliore considérablement la discrimination entre différents types de végétation, de sols, d'eau ou de minéraux. En télédétection des feux de forêt, elle permet notamment de détecter avec précision les zones brûlées, d'identifier les surfaces affectées et d'évaluer l'intensité des dégâts, contribuant ainsi à une analyse fine et fiable des incendies.




Figure II.8 - Résolution spectrale.

II.8.3. Résolution temporelle

La résolution temporelle d'un satellite correspond à la fréquence à laquelle il revisite et acquiert des images d'une même zone, généralement exprimée en jours (cf. figure III.9). Plus cette résolution est élevée, c'est-à-dire plus le temps de revisite est court, plus il est possible de suivre de manière fine et quasi continue les changements à la surface de la Terre. Cette caractéristique dépend de l'orbite du satellite, de son angle d'observation et de sa capacité de pointage. À titre d'exemple, le satellite Sentinel-2 offre une fréquence de revisite d'environ 5 jours, tandis que le satellite Landsat 8 présente un temps de revisite d'environ 16 jours.

Une bonne résolution temporelle est essentielle pour le suivi des phénomènes dynamiques tels que l'évolution de la végétation, la déforestation, les inondations, l'urbanisation ou encore la progression des feux de forêt. Elle permet ainsi d'assurer une surveillance efficace et d'améliorer la prise de décision en matière de gestion et de protection de l'environnement.



Figure II.9 - Résolution temporelle.

II.9. Domaine d'applications de la télédétection

La télédétection est largement utilisée dans divers domaines pour observer, analyser et surveiller l'environnement ainsi que les activités humaines. Parmi ses nombreuses applications, la détection et la cartographie des incendies de forêt occupent une place particulièrement importante.

II.9.1. Applications de la télédétection pour la détection et la cartographie des incendies de forêts

La télédétection des feux de forêt permet de détecter, suivre et évaluer les incendies grâce aux satellites équipés de capteurs spécialisés.

- Détection des zones en feu : Les capteurs détectent les températures élevées et les signatures spectrales caractéristiques des incendies. Les bandes infrarouges moyennes et thermiques sont particulièrement efficaces pour repérer les feux actifs, même à travers la fumée.
- Cartographie des zones brûlées : Après l'incendie, les images satellitaires permettent de cartographier l'étendue des surfaces touchées. Des indices comme le Normalized Burn Ratio (NBR) aident à différencier la végétation brûlée de la végétation saine.
- Suivi temporel et évaluation des dommages : Les satellites offrent un suivi dans le temps pour observer la propagation du feu, les zones à risque et la régénération de la végétation. La télédétection permet également d'évaluer la perte de biomasse, l'impact sur la faune et la flore, ainsi que les risques de nouvelles catastrophes comme l'érosion ou les inondations.
- Aide à la planification et à la prévention : Les données satellitaires aident les services forestiers et les autorités à planifier les interventions d'urgence, identifier les zones à haut risque et développer des stratégies de prévention.

II.10. Conclusion

Dans ce chapitre, une revue de la littérature a été réalisée concernant les satellites en orbite utilisés pour la détection des feux de forêt. Nous avons présenté le processus de télédétection en mettant en évidence le rôle du rayonnement électromagnétique, ainsi que les différents types d'images satellitaires et les données contextuelles associées. Cette étude a permis d'avoir une vision globale des ressources et des outils disponibles pour la détection, le suivi et l'analyse des incendies.

CHAPITRE III

LES APPORTS MAJEURS DE L'INTELLIGENCE ARTIFICIELLE

L'intelligence artificielle permet de détecter efficacement les feux de forêt grâce à l'analyse automatique des images satellites. Grâce à l'apprentissage automatique, elle permet d'identifier rapidement la fumée et les flammes, assurant ainsi une détection précoce des incendies. Cette technologie permet d'améliorer la rapidité et la précision des interventions, tout en réduisant les dégâts humains, matériels et environnementaux.

Dans ce chapitre, nous aborderons les fondements théoriques de l'intelligence artificielle, ses impacts et ses principales approches conceptuelles, ainsi que les différences entre ses divers sous-domaines, comme le Machine Learning et le Deep Learning. Nous présenterons également les différentes étapes du Deep Learning, ainsi que les principales techniques utilisées pour le traitement des images, notamment pour la détection des feux de forêt.

III.1. Introduction

L'intelligence artificielle (IA) est aujourd'hui reconnue comme l'un des domaines les plus dynamiques et stratégiques des sciences et des technologies, ce qui en fait une discipline d'avenir. Elle transforme en profondeur les secteurs économiques, sociaux, médicaux et industriels. Son évolution rapide, que soutiennent l'augmentation de la puissance de calcul et la disponibilité massive des données, offre de nombreuses opportunités tout en soulevant des enjeux éthiques, juridiques et sociétaux importants.

Parmi les branches les plus développées de l'IA, le Deep Learning occupe une place essentielle grâce à sa capacité à analyser automatiquement de grandes quantités de données complexes, notamment dans le domaine de la vision par ordinateur, ce qui en fait un outil très puissant pour l'analyse des images. Cette technologie possède plusieurs applications concrètes. Elle permet notamment de détecter en amont les feux de forêt. Cela permet de prévenir les catastrophes environnementales et de protéger les écosystèmes.

III.2. Intelligence artificielle

III.2.1. Définition de l'intelligence artificielle

L'intelligence artificielle (IA) désigne l'ensemble des concepts et méthodes visant à créer des systèmes capables d'imiter certaines facultés cognitives humaines, telles que l'apprentissage, le raisonnement, la perception, la résolution de problèmes et la prise de décision. Selon John McCarthy, qui a introduit ce terme en 1956, l'IA correspond à « la science et l'ingénierie de la conception de machines intelligentes ». Par ailleurs, Stuart Russell et Peter Norvig identifient quatre grandes approches de l'IA : penser comme un être humain, agir comme un être humain, raisonner de manière logique et agir de façon rationnelle [17].

III.2.2. L'impact de l'intelligence artificielle

L'intelligence artificielle joue un rôle important dans de nombreux secteurs. Dans le secteur de la santé, elle permet d'assister au diagnostic et à l'analyse d'images médicales. Dans l'industrie, elle permet d'améliorer l'automatisation et la maintenance prédictive. Dans le secteur de la finance, elle sert à détecter les fraudes et à gérer les risques. Dans les transports, elle est utilisée pour les véhicules autonomes et la gestion du trafic, et dans l'éducation pour mettre en place des systèmes d'apprentissage personnalisés. Elle est

également utilisée pour la reconnaissance faciale, permettant d'identifier des personnes et de surveiller des zones dans un contexte de sécurité.

Par ailleurs, l'IA est très efficace pour détecter précocement les feux de forêt grâce au deep learning et aux réseaux de neurones convolutifs (CNN). Elle analyse des images satellitaires, de drones ou de caméras pour repérer rapidement la fumée ou les flammes et réduire les délais d'intervention. Cependant, son développement soulève plusieurs défis importants, notamment en matière d'emploi, de protection des données personnelles, de biais algorithmiques et de responsabilité des décisions automatisées [18].

III.2.3. Les axes de l'intelligence artificielle

Les bases de l'intelligence artificielle reposent sur plusieurs approches philosophiques et méthodologiques, qui sont au nombre de deux : l'approche analytique et l'approche des systèmes. On étudie généralement l'IA selon deux grandes perspectives : l'approche centrée sur le comportement humain et l'approche orientée vers la rationalité. Cette classification, proposée par Stuart Russell et Peter Norvig dans leur ouvrage "Intelligence artificielle" : Approche moderne (A Modern Approach), distingue deux objectifs principaux : reproduire les capacités et le raisonnement humains, ou concevoir des systèmes capables d'agir de manière rationnelle et optimale [18].

III.2.3.1. L'approche humaine

L'approche humaine a pour objectif de mettre au point des systèmes qui sont capables de reproduire la manière de penser ou de se comporter d'un être humain. Dans le cas de « penser comme un humain », les chercheurs cherchent à modéliser les processus cognitifs. Ces processus incluent la mémoire, la perception ou le raisonnement. Pour cela, ils s'appuient notamment sur la psychologie cognitive et les neurosciences. Des scientifiques comme Allen Newell et Herbert Simon ont largement contribué à cette approche en explorant la simulation des mécanismes mentaux, ce qui a grandement contribué à son développement.

En ce qui concerne « agir comme un humain », l'objectif est de générer un comportement impossible à distinguer de celui d'une personne réelle, c'est-à-dire de créer un personnage qui imite si fidèlement l'être humain que celui-ci devient indiscernable. Le test proposé par Alan Turing en 1950, appelé « test de Turing », demeure une référence essentielle dans ce domaine [20].

III.2.3.2. L'approche rationnelle

L'approche rationnelle, quant à elle, ne cherche pas à imiter le fonctionnement humain, mais à développer un raisonnement ou un comportement optimal, fondé sur des principes logiques et mathématiques. « Penser rationnellement » consiste à appliquer les règles de la logique formelle pour parvenir à des conclusions cohérentes et valides. « Agir rationnellement » renvoie à la notion d'agent rationnel, c'est-à-dire un système capable de choisir l'action la plus adaptée pour atteindre un objectif donné, en tenant compte des informations disponibles et du niveau d'incertitude. Cette approche s'appuie principalement sur la logique, les probabilités et la théorie de la décision [20].

III.2.4. Distinction entre IA, apprentissage automatique et apprentissage profond

L'intelligence artificielle est un domaine de l'informatique qui vise à créer des systèmes capables de reproduire certaines capacités humaines, telles que le raisonnement et la prise de décision. Le Machine Learning, sous-domaine de l'IA, permet aux machines d'apprendre à partir de données sans programmation explicite. Le Deep Learning, évolution du Machine Learning (voir figure III.1), utilise des réseaux de neurones à plusieurs couches pour traiter de grandes quantités de données et résoudre des problèmes complexes, notamment dans le domaine de la reconnaissance d'images et de la reconnaissance vocale [20], [21].




Figure III.1 - Intelligences Artificielles, Machine Learning, et l'apprentissage profond.

III.3. Apprentissage automatique (Machine Learning)

III.3.1. Définition

L'apprentissage automatique (Machine Learning) est une branche de l'intelligence artificielle qui permet aux systèmes informatiques d'apprendre à partir de données et

d'améliorer leurs performances sans être programmés explicitement pour chaque tâche. Il repose sur la conception d'algorithmes capables de détecter des schémas dans les données, puis d'effectuer des prédictions ou de prendre des décisions à partir de ces modèles [22].

III.4. Fonctionnement de l'apprentissage automatique

Le Machine Learning repose sur l'idée que les données contiennent des motifs cachés que les algorithmes peuvent apprendre à reconnaître. Au lieu de programmer des règles fixes, on entraîne un modèle à partir de données afin qu'il puisse effectuer des prédictions sur de nouvelles informations. Plus les données sont nombreuses et pertinentes, plus le modèle est performant.

Le processus de Machine Learning suit plusieurs étapes. Il commence par la collecte, puis la préparation des données. On choisit ensuite un modèle adapté au problème, comme la régression, les arbres de décision ou les réseaux de neurones.

Le modèle est ensuite entraîné en ajustant ses paramètres afin de réduire l'écart entre les prédictions et les résultats réels. Il est ensuite évalué sur de nouvelles données afin de vérifier sa capacité de généralisation et d'éviter le sur-apprentissage. Enfin, le modèle est déployé pour des applications concrètes, telles que la détection de fraudes ou les systèmes de recommandation [22].

III.5. Types d'apprentissage automatique

Les types d'apprentissage automatique désignent les différentes méthodes permettant à un modèle d'apprendre à partir de données. On les divise principalement en apprentissage supervisé, non supervisé, semi-supervisé et par renforcement. Chaque approche répond à des besoins spécifiques, en fonction de la disponibilité des données et des objectifs visés : utilisation de données annotées, détection de structures cachées ou apprentissage par interaction avec un environnement. Cette classification permet de choisir la méthode la plus adaptée au problème étudié.

III.5.1. Apprentissage supervisé

L'apprentissage supervisé est une technique d'apprentissage automatique dans laquelle un modèle est entraîné à partir d'un ensemble de données étiquetées, c'est-à-dire des exemples pour lesquels la sortie attendue est déjà connue. L'objectif est d'établir une relation

entre les variables d'entrée et la variable de sortie afin de pouvoir effectuer des prédictions sur de nouvelles données.

Cette méthode englobe principalement deux types de tâches : la classification, qui consiste à prédire une catégorie, et la régression, qui vise à estimer une valeur numérique continue. Elle suit généralement un processus structuré comprenant la préparation des données, l'entraînement du modèle, puis l'évaluation de ses performances à l'aide de métriques appropriées.

L'apprentissage supervisé est l'un des piliers essentiels de l'intelligence artificielle moderne et est largement utilisé dans des domaines variés, comme la reconnaissance d'images, le diagnostic médical ou la prévision économique [22].

III.5.2. Apprentissage non supervisé

L'apprentissage non supervisé est une méthode d'apprentissage automatique dans laquelle le modèle est entraîné à partir de données non étiquetées, c'est-à-dire sans disposer des résultats attendus au préalable. Son objectif principal est de mettre en évidence automatiquement des structures cachées, des regroupements ou des relations sous-jacentes dans les données.

À la différence de l'apprentissage supervisé, il ne vise pas à prédire une variable cible, mais plutôt à identifier des motifs ou des structures internes, comme dans le cas du clustering, qui permet de regrouper des éléments similaires, ou de la réduction de dimension, qui simplifie les variables tout en préservant l'information essentielle. Cette approche est couramment utilisée dans des domaines tels que la segmentation de la clientèle, l'analyse exploratoire de données et la détection d'anomalies [22].

III.5.3. Apprentissage semi-supervisé

L'apprentissage semi-supervisé est une approche de l'apprentissage automatique située entre l'apprentissage supervisé et l'apprentissage non supervisé. Dans ce cadre, le modèle est entraîné à partir d'un petit ensemble de données étiquetées, complété par une grande quantité de données non étiquetées. L'objectif est d'améliorer les performances du modèle en exploitant l'information présente dans les données non annotées, qui sont généralement moins coûteuses à obtenir.

Cette méthode repose sur l'hypothèse que les données proches dans l'espace des caractéristiques ont tendance à partager la même étiquette. Elle est particulièrement pertinente

lorsque l'annotation manuelle est longue, coûteuse ou difficile, comme dans le cas de la reconnaissance d'images ou du traitement automatique du langage naturel. L'apprentissage semi-supervisé permet ainsi de réduire les efforts d'étiquetage tout en conservant de bonnes performances prédictives [23].

III.5.4. Apprentissage par renforcement

L'apprentissage par renforcement est une branche de l'apprentissage automatique dans laquelle un agent apprend à prendre des décisions en interagissant avec un environnement. Il reçoit des récompenses ou des pénalités en fonction de ses actions et cherche à maximiser ses gains à long terme. À la différence de l'apprentissage supervisé, il apprend par essais et erreurs, en adaptant progressivement sa stratégie. Basé sur les processus de décision markoviens (MDP), ce type d'apprentissage est utilisé en robotique, dans les jeux vidéo, le contrôle automatique et l'intelligence artificielle. Il permet de créer des agents capables de surpasser l'humain dans certains environnements complexes.

III.6. Deep Learning

III.6.1. Définition

Le Deep Learning, ou apprentissage profond, est une branche de l'apprentissage automatique basée sur des réseaux de neurones à plusieurs couches cachées. S'inspirant du cerveau humain, il permet d'apprendre automatiquement à représenter des données de manière complexe à partir de grandes quantités d'informations. Cette approche s'avère particulièrement efficace pour des tâches telles que la reconnaissance d'images, la vision par ordinateur, la reconnaissance vocale ou encore le traitement du langage naturel. Son développement a été rendu possible par les progrès de la puissance de calcul, la disponibilité massive des données et les avancées en intelligence artificielle.

III.6.2. Historique de Deep Learning

Le Deep Learning trouve son origine dans les premières recherches sur les réseaux de neurones artificiels s'inspirant du cerveau humain. En 1958, Frank Rosenblatt a développé le perceptron, le premier modèle d'apprentissage supervisé. Cependant, les limites de ce modèle, mises en évidence par Minsky et Papert, ont ensuite ralenti les recherches dans ce domaine.

Dans les années 1980, l'algorithme de rétropropagation relance l'intérêt pour les réseaux multicouches, car il permet un meilleur ajustement des poids des neurones. Malgré cette avancée, les progrès restent limités par le manque de puissance de calcul et de données disponibles.

Le véritable essor du Deep Learning débute dans les années 2000, grâce aux travaux de Geoffrey Hinton, à l'augmentation de la puissance des GPU et à la disponibilité massive de données. En 2012, les réseaux de neurones convolutifs (CNN) ont démontré leur efficacité dans le domaine de la vision par ordinateur et de la classification d'images. En 2017, les architectures Transformer révolutionnent le traitement automatique du langage naturel en améliorant la compréhension du contexte entre les mots. Elles permettent également le développement de grands modèles capables d'accomplir diverses tâches, telles que la génération de texte et la traduction automatique.

Ces avancées ont donné lieu à l'apparition de modèles fondamentaux (foundation models), entraînés sur de très grandes quantités de données et réutilisables dans plusieurs domaines. Aujourd'hui, le Deep Learning est largement utilisé dans les secteurs de la santé, de la finance, de l'éducation et de l'industrie.

Malgré leurs performances, les modèles de Deep Learning soulèvent encore plusieurs défis importants, notamment les biais algorithmiques, la forte consommation énergétique, le manque d'interprétabilité et les questions éthiques liées à l'intelligence artificielle.

III.6.3. Domaines d'application du Deep Learning

Le Deep Learning est aujourd'hui utilisé dans de nombreux domaines, car il permet de traiter des données complexes et volumineuses. Il intervient notamment dans les domaines suivants :

- La vision par ordinateur (reconnaissance d'images, détection d'objets, analyse et segmentation d'images) ;
- Reconnaissance vocale : transcription automatique de la parole et assistants vocaux intelligents ;
- Le traitement automatique du langage naturel (TALN) : traduction automatique, analyse de texte et génération de contenu ;
- Dans le domaine de la santé, pour assister au diagnostic médical, détecter des maladies et pratiquer la médecine prédictive ;

- Transports : véhicules autonomes, systèmes d'aide à la conduite et gestion intelligente du trafic ;
- Cybersécurité : détection d'anomalies et identification des menaces informatiques.
- Systèmes de recommandation : suggestions personnalisées sur les plateformes numériques.
- Surveillance environnementale : détection des incendies de forêt à partir d'images satellitaires, de drones ou de caméras, avec analyse des données météorologiques pour anticiper les zones à risque et améliorer les systèmes d'alerte précoce.

III.6.4. Forces et faiblesses du Deep Learning

Le Deep Learning offre des performances remarquables dans de nombreux domaines, mais il présente également certaines contraintes qu'il est important de considérer en fonction des applications visées.

III.6.4.1. Points forts de l'apprentissage profond

- Apprentissage automatique des caractéristiques : contrairement aux méthodes classiques, le Deep Learning ne nécessite pas d'extraction manuelle des variables pertinentes. Il apprend directement à partir des données brutes, ce qui simplifie le processus de conception des modèles.
- Exploitation efficace des grandes bases de données : les réseaux de neurones profonds sont particulièrement adaptés au traitement de volumes massifs de données, ce qui permet d'améliorer progressivement les performances et la robustesse des modèles.
- Excellentes performances dans les tâches complexes : le Deep Learning offre des résultats de pointe en vision par ordinateur, en reconnaissance d'images, en détection d'objets et en reconnaissance vocale, surpassant souvent les approches traditionnelles.

III.6.4.2. Limites de l'apprentissage profond

- Besoin important en données : ces modèles nécessitent généralement de grandes quantités de données, souvent annotées, pour atteindre un bon niveau de performance ;
- Un coût de calcul élevé : l'entraînement des réseaux de neurones profonds nécessite des ressources matérielles importantes (cartes graphiques ou processeurs TPU), ce qui peut rendre leur utilisation coûteuse et moins accessible ;

- Faible interprétabilité : les modèles de Deep Learning sont souvent considérés comme des « boîtes noires », car leurs décisions sont difficiles à interpréter et à expliquer clairement [21].

III.6.5. Principe de fonctionnement de Deep Learning

Le Deep Learning repose sur des réseaux de neurones profonds composés de plusieurs couches interconnectées qui permettent d'extraire progressivement des informations complexes à partir des données. Le fonctionnement du modèle commence par la propagation avant, au cours de laquelle les données traversent le réseau et sont transformées par des fonctions d'activation. Une fonction de coût mesure ensuite l'écart entre les prédictions et les résultats attendus. Cette erreur est corrigée lors de la rétropropagation, qui ajuste les poids des neurones à l'aide d'algorithmes d'optimisation, comme la descente de gradient. Ce processus est répété sur plusieurs itérations jusqu'à ce que les performances soient satisfaisantes. Grâce à ce mécanisme, le Deep Learning permet de résoudre efficacement des tâches complexes telles que la vision par ordinateur, la reconnaissance vocale ou le traitement automatique du langage naturel.

III.6.6. Architectures et algorithmes

Le Deep Learning repose sur différentes architectures de réseaux de neurones et des algorithmes d'apprentissage adaptés aux types de données et aux tâches à effectuer. Chaque architecture est conçue pour traiter un type spécifique d'information (images, texte, séquences, etc.), afin d'optimiser les performances selon l'application [24].

- **Les réseaux de neurones anticipation (Feedforward) “MLP – Multi-Layer Perceptron”** : Il s'agit de l'architecture de base du Deep Learning. Les informations circulent dans un seul sens, de l'entrée vers la sortie, sans boucle. Ces réseaux sont principalement utilisés pour des tâches de classification et de régression sur des données structurées (voir figure III.2).




Figure III.2 - Les réseaux de neurones anticipation (Feedforward) - MLP.

- **Les réseaux de neurones convolutifs (CNN – Convolutional Neural Networks) :** Ces architectures sont spécialement conçues pour le traitement des données visuelles (cf. figure III.3). Elles permettent d'extraire automatiquement des caractéristiques spatiales à partir des images (bords, formes, textures), ce qui les rend très efficaces en vision par ordinateur (classification d'images, détection d'objets, segmentation).




Figure III.3 - Les réseaux de neurones convolutifs (CNN).

- **Les réseaux de neurones récurrents (RNN – Recurrent Neural Networks) :** Adaptés aux données séquentielles, les RNN prennent en compte l'ordre des informations (figure III.4). Ils sont utilisés pour le traitement du langage naturel, la reconnaissance vocale et les séries temporelles. Des variantes comme les LSTM et GRU améliorent leur capacité à mémoriser des dépendances à long terme.




Figure III.4 - Les réseaux de neurones récurrents (RNN).

- **Les architectures transformeurs (Transformers) :** Ces modèles reposent sur un mécanisme d'attention qui permet de traiter simultanément l'ensemble des éléments d'une séquence (figure III.5). Ils ont révolutionné le traitement du langage naturel et sont aujourd'hui utilisés dans de nombreuses applications, notamment la traduction automatique, les modèles de langage et la génération de texte.




Figure III.5 – Architecture du transformeur.

- **Les autoencodeurs (Autoencoders) :** Ils sont utilisés pour l'apprentissage non supervisé et la réduction de dimension (voir figure III.6). Leur objectif est de compresser les données en une représentation plus simple, puis de les reconstruire, ce qui permet de détecter des anomalies ou d'extraire des caractéristiques importantes.




Figure III.6 - Les autoencodeurs.

L'entraînement de ces architectures repose principalement sur des algorithmes d'optimisation, notamment :

- La rétropropagation du gradient (backpropagation), qui permet de calculer l'erreur et d'ajuster les poids du réseau.
- Les méthodes de descente de gradient (SGD, Adam), qui optimisent progressivement les paramètres afin de minimiser la fonction de perte.

Ainsi, la combinaison des architectures adaptées et des algorithmes d'optimisation performants permet au Deep Learning d'atteindre des résultats très avancés dans des domaines variés [21].

III.7. Les réseaux de neurones convolutifs

Les réseaux de neurones convolutifs (CNN) sont une catégorie de réseaux de neurones profonds conçus pour analyser des données structurées en grille, comme des images ou des vidéos. Ils exploitent la structure spatiale des données afin d'en extraire automatiquement des caractéristiques hiérarchiques, ce qui les rend très efficaces pour les applications de vision par ordinateur, telles que la reconnaissance d'images ou la détection d'objets.

L'architecture d'un CNN repose sur plusieurs couches successives (voir figure III.7 [25]) : les couches de convolution extraient les caractéristiques importantes, les fonctions d'activation introduisent la non-linéarité, les couches de pooling réduisent la dimension des données et les couches entièrement connectées réalisent la classification finale. Cette structure permet au réseau d'apprendre progressivement des motifs simples jusqu'à des représentations plus complexes.




Figure III.7- Architecture générale d'un CNN.

III.7.1. Les différentes couches d'un CNN

III.7.1.1. La couche de convolution

La couche de convolution utilise des filtres (ou « noyaux ») appliqués à l'image d'entrée afin d'en extraire des caractéristiques locales, telles que les contours, les textures ou les formes. Chaque filtre produit une carte de caractéristiques (feature Map) indiquant la présence et l'intensité d'un motif spécifique dans l'image, (voir la figure III.8).




Figure III.8 - Application d'un filtre.

Les caractéristiques d'un filtre dans une couche de convolution incluent la taille du noyau, le pas de convolution et le remplissage (voir la figure III.8). La taille du filtre détermine l'échelle des motifs détectés, allant des détails fins avec de petits noyaux aux structures globales avec de plus grands noyaux. Le stride définit le déplacement du filtre sur l'image et influence la réduction des dimensions de sortie. Le padding, quant à lui, ajoute des bordures à l'image afin de préserver les informations relatives aux contours et de contrôler la taille des résultats [26].




Figure III.9 - Caractéristique d'un filtre.

Le nombre de filtres correspond à la quantité de cartes de caractéristiques (feature maps) générées par la couche. Chaque filtre est chargé d'apprendre et de détecter un motif particulier dans l'image, ce qui permet d'extraire différents types de caractéristiques. Ainsi, l'utilisation de plusieurs filtres conduit à l'obtention de multiples représentations des informations contenues dans l'image (voir la figure III.10).




Figure III.10 - Taille d'un filtre.

III.7.1.2. La couche de Pooling

La couche de pooling, ou sous-échantillonnage, permet de réduire la taille spatiale des cartes de caractéristiques tout en préservant les informations essentielles (Comme le montre la figure III.11) . Elle permet de diminuer la complexité des données tout en conservant les éléments importants. Les méthodes les plus couramment utilisées sont le max pooling, qui retient la valeur maximale de chaque région, et l'average pooling, qui calcule la moyenne des valeurs présentes dans chaque sous-région [26].




Figure III.11 - Opérations de sous-échantillonnage : Max Pooling et Average Pooling

Le max Pooling permet de réduire la complexité de l'image tout en conservant les informations les plus importantes. Cette opération simplifie les données, ce qui rend le CNN plus rapide et plus efficace lors du traitement [27].

III.7.1.3. La couche de correction ReLU

La fonction ReLU (Rectified Linear Unit) est une fonction d'activation qui introduit de la non-linéarité dans le réseau de neurones. Elle remplace toutes les valeurs négatives par zéro tout en conservant les valeurs positives, ce qui permet au modèle d'apprendre des relations plus complexes (Comme illustré à la figure III.12). Elle est définie par la règle suivante : $\text{ReLU}(z) = \max(0, z)$.



Figure III.12 - La fonction ReLU (Rectified Linear Unit).

III.7.1.4. La couche fully-connected

Les couches fully-connected (entièrement connectées) ont pour rôle de regrouper l'ensemble des caractéristiques extraites par les couches précédentes et de les utiliser pour produire la sortie finale du réseau (cf. figure III.13). Le produit scalaire du vecteur de poids et du vecteur d'entrée est calculé afin d'obtenir la sortie finale, par exemple la classification d'une image dans une catégorie donnée [28].




Figure III.13 - Couche fully-connected

III.8. La fonction du cout

La fonction de coût (ou fonction de perte) est un élément essentiel de l'apprentissage automatique et du Deep Learning. Elle permet de quantifier l'écart entre les prédictions du modèle et les valeurs réelles. Lors de l'entraînement d'un réseau de neurones, l'objectif est de minimiser cette fonction afin d'optimiser les performances du modèle et d'améliorer sa capacité de généralisation à de nouvelles données [28].

III.8.1. Définition

La fonction de coût attribue une valeur numérique à l'erreur produite par les prédictions du modèle. Dans les problèmes de classification, on utilise souvent la perte de cross-entropie, tandis que dans les problèmes de régression, on privilégie généralement l'erreur quadratique moyenne (MSE). Cette valeur permet ensuite de guider l'algorithme d'optimisation lors de l'ajustement des poids du réseau de neurones, afin de réduire progressivement l'erreur et d'améliorer les performances du modèle.

III.8.2. Réduction de la fonction du cout

La réduction de la fonction de coût est assurée par des algorithmes d'optimisation, tels que la descente de gradient et ses variantes (stochastiques, mini-batch ou adaptatives), qui permettent d'obtenir une fonction de coût minimale. La démarche s'articule ainsi : en premier lieu, il s'agit de calculer le gradient de la fonction de coût par rapport aux poids du réseau. Puis, il est nécessaire d'ajuster ces poids dans le sens qui permet de réduire l'erreur. Ces étapes sont répétées de manière itérative jusqu'à ce que le modèle converge. Une optimisation efficace de la fonction de coût permet ainsi d'améliorer la précision des prédictions et de réduire l'erreur sur de nouvelles données [28], ce qui est un atout pour la fiabilité des résultats.

III.9. Transfer Learning

Le Transfer Learning (apprentissage par transfert) est une technique du Deep Learning qui consiste à réutiliser un modèle déjà entraîné sur une tâche afin de l'adapter à une nouvelle tâche. Cette méthode permet de bénéficier des connaissances acquises par le modèle à partir de grands ensembles de données, ce qui réduit considérablement le temps d'entraînement ainsi que les ressources nécessaires, en particulier lorsque les données disponibles pour la nouvelle tâche sont limitées [28].

III.9.1. Principe

Le principe du Transfer Learning repose sur l'idée que les premières couches d'un réseau de neurones profond apprennent des caractéristiques générales, telles que les bords, les textures ou les formes dans le cas des images, qui peuvent être réutilisées dans différentes tâches. Ainsi, il est possible de geler certaines couches d'un modèle pré-entraîné afin de conserver ces connaissances générales, puis de réentraîner uniquement les dernières couches sur la nouvelle tâche spécifique. Cette approche permet d'obtenir un modèle performant même lorsque la quantité de données disponibles est limitée.

III.9.2. Les avantages du Transfer Learning

Le Transfer Learning présente plusieurs avantages importants dans le domaine du Deep Learning. Il permet tout d'abord une réduction du temps d'entraînement, car le modèle nécessite moins d'itérations et donc moins de ressources computationnelles pour converger. Ensuite, il réduit la quantité de données nécessaires, ce qui est particulièrement utile lorsque le nouveau jeu de données est limité ou difficile à annoter. Enfin, il améliore souvent la performance globale du modèle, car les réseaux préentraînés sur de grandes bases de données comme ImageNet fournissent des représentations riches et générales, facilitant ainsi l'apprentissage sur de nouvelles tâches.

III.9.3. Les principaux défis liés au Transfer Learning

Le Transfer Learning présente également certains défis. Tout d'abord, la différence de domaine peut poser problème : si les données du domaine source et celles du domaine cible sont trop éloignées, les performances du modèle peuvent se dégrader. Ensuite, il existe un risque de sur apprentissage (overfitting), notamment lorsque le jeu de données cible est très limité, ce qui peut amener le modèle à trop s'adapter aux données d'entraînement. Enfin, la sélection du modèle pré-entraîné est une étape cruciale, car il est nécessaire de choisir une architecture adaptée à la tâche cible afin d'assurer un transfert de connaissances efficace [29].

III.10. Les travaux de recherche basés sur l'architecture CNN pour la détection des feux de forêts à partir des images satellitaires.

Les réseaux de neurones convolutifs (CNN) sont largement utilisés pour la détection automatique des feux de forêt, car ils sont capables d'analyser et d'extraire des caractéristiques complexes à partir d'images satellitaires. Plusieurs études ont démontré que ces modèles

permettent d'identifier la fumée ou les flammes avec une grande précision et en temps quasi réel, ce qui améliore les systèmes d'alerte précoce et la gestion des catastrophes naturelles.

Muhammad et al. (2018, IEEE) ont par exemple proposé un modèle CNN capable de détecter précocement les incendies à partir d'images de surveillance, réduisant ainsi les faux positifs et améliorant la rapidité de détection. De leur côté, Zhang et al. (2016, Springer) ont développé un CNN pour l'analyse d'images satellites, exploitant les variations spectrales de la végétation et de la fumée afin d'identifier automatiquement les zones touchées par les incendies. Plus récemment, Li et al. (2021, Elsevier) ont combiné les CNN à des images issues de drones (UAV) afin d'améliorer la détection dans les zones difficiles d'accès, démontrant ainsi une capacité d'anticipation accrue de la propagation des incendies.

Ces travaux montrent que les architectures CNN, associées aux images multispectrales et aux données satellitaires, constituent une solution efficace pour la surveillance environnementale et la prévention des catastrophes. De plus, l'utilisation du transfert d'apprentissage permet de réduire le temps d'entraînement et d'améliorer les performances lorsque les données disponibles sont limitées [29].

III.11. Conclusion

Ce chapitre a présenté les concepts fondamentaux de l'intelligence artificielle, de la Machine Learning et du Deep Learning, ainsi que leurs principales architectures et méthodes. Il a notamment mis en évidence le rôle des réseaux de neurones, et plus particulièrement des CNN, dans l'extraction automatique de caractéristiques pour le traitement des images. Le Transfer Learning a également été abordé comme une approche efficace pour optimiser l'entraînement des modèles. Enfin, les applications récentes montrent l'importance de ces techniques dans des domaines variés, tout en soulignant les défis liés à la complexité, aux données et à l'interprétabilité des modèles.

CHAPITRE IV

MISE EN ŒUVRE DE LA DÉTECTION

Ce chapitre est consacré à la conception et au déploiement d'un système intelligent de détection et de classification des feux de forêt, s'appuyant sur les techniques de télédétection et de traitement d'images. L'ambition de ce travail est de proposer une solution automatisée capable d'analyser des images satellitaires ou aériennes pour distinguer les zones sinistrées par les incendies de celles présentant un risque potentiel. Nous décrivons l'ensemble du processus de développement, depuis la collecte et la préparation des données jusqu'à l'évaluation des performances du modèle, en passant par les choix méthodologiques effectués à chaque étape, et nous discutons des résultats obtenus à l'issue de cette démarche.

IV.1. Introduction

Les feux de forêt figurent parmi les catastrophes naturelles les plus dévastatrices pour l'environnement, l'économie et les populations. Ils entraînent la destruction de vastes superficies forestières, la perte de biodiversité, la dégradation des écosystèmes et l'émission de grandes quantités de gaz à effet de serre. Ils représentent également une menace majeure pour les infrastructures, les activités humaines et la santé publique.

Dans de nombreuses régions du monde, la détection précoce des incendies de forêt est devenue un enjeu crucial pour limiter leur propagation et réduire leurs impacts. Cependant, la surveillance de vastes territoires forestiers par des moyens conventionnels reste coûteuse, complexe et souvent insuffisante pour offrir une vue d'ensemble en temps réel de la situation. Les gestionnaires forestiers et les services de protection civile ont donc besoin d'outils capables d'assurer un suivi efficace et continu des zones à risque.

L'imagerie satellitaire constitue une source de données particulièrement adaptée à cette problématique. Les avancées récentes dans le domaine de la télédétection, notamment grâce aux satellites Sentinel-1 (radar) et Sentinel-2 (optique), permettent d'observer fréquemment et avec précision la surface terrestre. Ces données permettent de détecter les zones affectées par les incendies, de suivre leur évolution et d'évaluer les dégâts causés. Elles fournissent également des séries temporelles précieuses pour l'analyse des risques et la prévention.

L'exploitation de ces données nécessite des méthodes de traitement capables de gérer un grand volume d'images tout en fournissant des résultats rapides et fiables. Dans ce contexte, les techniques d'intelligence artificielle, en particulier les réseaux de neurones convolutifs (CNN), jouent un rôle important dans l'analyse automatique des images satellitaires. Grâce à leur capacité d'apprentissage et d'extraction des caractéristiques visuelles pertinentes, ces modèles permettent de détecter et de classer efficacement les zones touchées par les feux de forêt. Leur utilisation contribue ainsi à améliorer la précision de la surveillance des incendies et à renforcer les systèmes de prévention et de gestion des risques.

IV.2. Environnement de développement

L'implémentation d'une application repose sur une phase d'analyse préalable permettant de définir les besoins, les contraintes et les objectifs afin de concevoir une solution adaptée. Dans le cadre de ce projet, l'objectif est de développer un système de détection automatique des feux de forêt à partir d'images satellitaires ou aériennes, en utilisant

l'environnement Python et ses bibliothèques dédiées au traitement d'images et à l'intelligence artificielle.

IV.2.1. Outil de développement : PYTHON

IV.2.1.1. Définition

Python est un langage de programmation très prisé pour l'intelligence artificielle, l'apprentissage automatique et le traitement d'images. Sa simplicité et ses nombreuses bibliothèques spécialisées en font un outil très apprécié. Dans ce projet, l'environnement Spyder a été utilisé pour le développement et l'expérimentation des modèles, ce qui a permis de valider l'utilisation de cet environnement pour ce type de projet. Des bibliothèques telles que TensorFlow, Keras, OpenCV et NumPy ont permis de concevoir des modèles de Deep Learning. Elles ont aussi permis de les entraîner et de les optimiser. De plus, elles ont permis de traiter les images satellitaires. Cela a été fait pour la détection et la classification des feux de forêt [30].

IV.2.2. Base de données

Le dataset utilisé est constitué d'un ensemble d'images satellitaires. Ces images ont été acquises par le satellite Sentinel-2. Il est destiné à l'apprentissage et à l'évaluation du modèle de classification. Il existe deux catégories dans cette base de données : « fire », qui inclut les images de zones sinistrées par des incendies, et « nofire », qui regroupe les images dépourvues de toute trace de feu. Pour garantir une évaluation fiable des performances du modèle, nous divisons le dataset en deux sous-ensembles : un ensemble d'entraînement pour l'apprentissage et un ensemble de test pour la validation des résultats.

IV.3. Élaboration du système de détection

IV.3.1. Objectif

L'objectif principal de ce système est de développer une solution automatisée de détection et de classification des feux de forêt à partir d'images satellitaires en utilisant des techniques de Deep Learning, afin de permettre une meilleure prévention et une intervention plus rapide en cas de départ d'un incendie. Le système, qui repose sur des réseaux de neurones convolutifs (CNN), notamment les architectures DenseNet201 et MobileNet, vise à identifier avec précision les images contenant des incendies et celles qui n'en présentent pas.

Cette approche vise à améliorer la fiabilité de la classification tout en réduisant le temps de traitement et l'intervention humaine. Grâce à l'apprentissage profond, les caractéristiques pertinentes des images satellitaires sont automatiquement extraites par le modèle et des résultats rapides et précis sont fournis pour la surveillance des feux de forêt.

IV.3.2. Schéma général de conception

La conception du système proposé pour la détection et la classification des feux de forêt repose sur plusieurs étapes successives, illustrées ci-dessous à la figure IV.1. Les étapes sont le prétraitement des images, l'extraction des caractéristiques, l'entraînement du modèle et l'évaluation de ses performances. Le but à atteindre est le suivant : mettre en place une solution qui soit à la fois fiable et performante. Cela aura pour effet d'accroître la rapidité et la précision de la détection des feux de forêt. Ce faisant, on pourra renforcer la prévention et limiter les impacts environnementaux.

IV.3.2.1 Prétraitement des images

Le prétraitement des images représente une étape clé dans les systèmes de détection et de classification des images satellitaires, puisqu'il permet d'optimiser la qualité des données en amont de leur exploitation par les modèles de Deep Learning [31].

IV.3.2.1.1. Importance du prétraitement

Le prétraitement des images satellitaires est une étape fondamentale des systèmes de détection et de classification basés sur l'apprentissage profond. Il permet d'améliorer la qualité des données et d'optimiser les performances des réseaux de neurones convolutifs (CNN). En effet, les images satellitaires peuvent présenter diverses imperfections, telles que du bruit, des variations d'illumination ou encore des dimensions non uniformes, qui sont susceptibles d'affecter la précision des résultats. Grâce à des opérations de redimensionnement, de normalisation, d'amélioration du contraste et de réduction du bruit, les données deviennent plus homogènes et mieux adaptées aux architectures DenseNet et MobileNet. Cette étape contribue ainsi de manière significative à améliorer la précision, la rapidité et la fiabilité du système de classification développé sous Python [31], [32].




Figure IV.1 - Schéma général de conception.

IV.3.2.1.2. Correction des artefacts

La correction des artefacts est une étape essentielle du prétraitement des images satellitaires. Elle vise à éliminer ou à réduire les imperfections telles que le bruit, les pixels aberrants, les effets atmosphériques, les ombres et les variations de luminosité qui peuvent affecter les performances des modèles de Deep Learning. Pour cela, des techniques telles que le filtrage, la correction radiométrique et l'amélioration du contraste sont utilisées afin d'améliorer la qualité des images et d'accroître la précision des tâches de détection et de classification [33].

IV.3.2.1.3. Normalisation des intensités

La normalisation des intensités constitue une étape importante du prétraitement des images satellitaires. Elle consiste à ramener les valeurs des pixels à une échelle standard, de manière à réduire les variations liées aux conditions d'acquisition, à l'éclairage ou aux capteurs. Cette opération facilite l'apprentissage des modèles de Deep Learning, améliore leur stabilité et accélère leur convergence. En optimisant les performances d'architectures telles que DenseNet et MobileNet, la normalisation contribue à accroître la précision et la robustesse de la classification des images satellitaires.

IV.3.2.1.4. Réduction du bruit

La réduction du bruit est une étape essentielle du prétraitement des images satellitaires. Elle consiste à éliminer les perturbations causées par les capteurs, les conditions atmosphériques ou les erreurs de transmission, afin d'améliorer la qualité des données. Grâce à des techniques de filtrage, telles que les filtres gaussien et médian, il est possible de réduire le bruit tout en préservant les détails importants de l'image. Cette opération permet d'améliorer l'extraction des caractéristiques et de renforcer les performances des modèles de Deep Learning, notamment DenseNet et MobileNet, en augmentant la précision de la classification.

IV.3.2.1.5. Évaluation de l'efficacité du processus de prétraitement

La réduction du bruit est une étape essentielle du prétraitement des images satellitaires. Elle consiste à éliminer les perturbations causées par les capteurs, les conditions atmosphériques ou les erreurs de transmission, afin d'améliorer la qualité des données. Grâce à des techniques de filtrage, telles que les filtres gaussien et médian, il est possible de réduire

le bruit tout en préservant les détails importants de l'image. Cette opération permet d'améliorer l'extraction des caractéristiques et de renforcer les performances des modèles de Deep Learning, notamment DenseNet et MobileNet, en augmentant la précision de la classification.

a) Erreur quadratique moyenne (Mean Square Error (MSE))

L'erreur quadratique moyenne (MSE) est une métrique qui permet de quantifier la différence entre une image originale et son image prétraitée. Elle correspond à la moyenne des carrés des écarts entre les valeurs des pixels des deux images, obtenue en comparant chaque pixel de l'image initiale à celui de l'image transformée. Une valeur faible de MSE traduit une forte similarité entre les deux images, indiquant ainsi un prétraitement efficace. À l'inverse, une valeur élevée reflète une différence importante et donc une dégradation plus marquée. Pour deux images I et K de dimension $m \times n$, la MSE est définie par l'expression suivante :

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} (I(i, j) - K(i, j))^2 \quad \dots (IV.1)$$

où $I(i, j)$ représente le pixel de l'image originale, $K(i, j)$ celui de l'image traitée, et m, n les dimensions de l'image.

b) Rapport crête signal sur bruit (Peak Signal to Noise Ratio (PSNR))

Le PSNR (Peak Signal-to-Noise Ratio) est une mesure dérivée du MSE. Elle sert à évaluer la qualité d'une image reconstruite par rapport à une image de référence. Il est exprimé en décibels (dB) et le rapport entre la puissance maximale du signal et la puissance du bruit introduit lors du traitement est indiqué. Une valeur élevée du PSNR traduit une meilleure qualité d'image et une faible distorsion.

Le PSNR est défini par la formule suivante :

$$PSNR = 10 \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad \dots (IV.2)$$

où MAX_I représente la valeur maximale des pixels de l'image (par exemple 255 pour une image en 8 bits).

Cette métrique permet d'évaluer la qualité des images après traitement et de vérifier que les opérations appliquées, telles que l'ajustement du contraste ou de la luminosité, n'ont pas altéré les informations visuelles de manière significative. En pratique, un PSNR supérieur à 40 dB indique une qualité d'image excellente, une valeur comprise entre 30 et 40 dB correspond à une qualité bonne, entre 20 et 30 dB à une qualité moyenne, tandis qu'une valeur inférieure à 20 dB traduit une qualité d'image faible.

c) Résultats illustratifs

Les résultats du prétraitement peuvent également être évalués de manière visuelle, en comparant les images avant et après traitement, ce qui permet de visualiser les changements opérés. Cette comparaison permet d'observer à la fois la réduction du bruit, l'amélioration du contraste et la clarification des contours. En pratique, les résultats sont souvent présentés sous forme de figures et de tableau. Ces observations qualitatives, qui offrent une évaluation plus complète de la qualité du processus de prétraitement (voir le tableau IV.1), complètent les mesures quantitatives telles que le MSE et le PSNR.

Tableau IV.1- Résultats MSE et PSNR après le prétraitement de quelque images satellitaires.

IMAGE	MSE	PSNR (dB)
Image 1	2.5807490965136055	44.013345768960534 dB
Image 2	0.11636373299319729	57.472627157358104 dB
Image 3	0.07175409226190477	59.57233686178492 dB
Image 4	1.917330994897959	45.30383267891223 dB
Image 5	2.0525018601190474	45.00796801488577 dB
Image 6	1.8523862670068028	45.4534880825307 dB

Le tableau IV.1 présente les valeurs de l'Erreur Quadratique Moyenne (MSE) et du Rapport Signal sur Bruit de Crête (PSNR) obtenues pour six images après l'étape de prétraitement. Les résultats montrent globalement des valeurs de MSE très faibles et des valeurs de PSNR élevées, ce qui indique une bonne qualité des images traitées et une faible dégradation par rapport aux images d'origine. Figures IV.2 illustrent l'image originale et l'image après prétraitement (comme montré ci-dessous).



Figure IV.2 - Résultat de prétraitement des images satellitaires : (a) image originale, (b) image après le prétraitement.

Les images 2 et 3 affichent les meilleures performances avec des valeurs de MSE de 0,116 et 0,072, associées à des PSNR de 57,47 dB et 59,57 dB respectivement. Ces résultats traduisent une excellente conservation des informations visuelles après prétraitement. Les images 1, 4, 5 et 6 présentent des valeurs de MSE légèrement plus élevées, comprises entre 1,85 et 2,58, avec des PSNR variant de 44,01 dB à 45,45 dB. Bien que ces performances soient inférieures à celles des images 2 et 3, les valeurs de PSNR restent largement supérieures à 40 dB, ce qui correspond généralement à une très bonne qualité d'image et à une faible présence d'erreurs perceptibles.

Dans l'ensemble, ces résultats confirment l'efficacité des techniques de prétraitement appliquées. La faible erreur MSE observée et les valeurs élevées de PSNR montrent que les opérations réalisées ont permis d'améliorer la qualité des images tout en préservant leurs caractéristiques essentielles, ce qui favorise une meilleure performance des modèles de classification basés sur le Deep Learning.

IV.3.2.2. Détection et classification des images satellitaires

La détection des feux constitue l'étape principale du système proposé, dont l'objectif est d'identifier automatiquement la présence d'incendies dans les images satellitaires. Cette tâche s'appuie sur des réseaux de neurones convolutifs (CNN), capables d'extraire les caractéristiques visuelles associées aux foyers d'incendie.

Dans ce travail, les architectures DenseNet201 et MobileNet sont utilisées pour analyser les images prétraitées. DenseNet201 favorise une extraction approfondie des caractéristiques, tandis que MobileNet offre une solution légère et rapide, adaptée aux environnements à ressources limitées.

IV.3.2.2.1 Les architectures du DenseNet201 & MobileNet : Modèles (CNN)

IV.3.2.2.1.1. Le modèle DenseNet201

Le modèle DenseNet est une architecture de réseaux de neurones convolutifs fortement connectée dans laquelle chaque couche est reliée à l'ensemble des couches précédentes. Cette organisation favorise une meilleure circulation de l'information ainsi qu'une propagation efficace du gradient, ce qui améliore l'apprentissage et limite le problème de disparition du gradient.

DenseNet201 est une variante de l'architecture DenseNet (Densely Connected Convolutional Networks) proposée par Gao Huang et ses collaborateurs. Le nombre 201

indique que le réseau comporte environ 201 couches, ce qui lui confère une grande profondeur. Cette architecture est particulièrement performante pour l'extraction de caractéristiques complexes à partir d'images satellitaires, grâce à sa profondeur et à sa capacité à réutiliser les caractéristiques déjà apprises. Dans DenseNet, chaque couche dense reçoit en entrée la concaténation des sorties de toutes les couches précédentes (comme présenté dans la figure IV.3), ce qui permet une meilleure réutilisation des caractéristiques et une propagation plus efficace du gradient. Mathématiquement, la sortie de la couche (l) est donnée par:

$$x_l = H_l([x_0, x_1, \dots, x_{m-1}]) \quad \dots (IV.3)$$

où :

- x_l : sortie de la couche l ,
- $H_l(\cdot)$: transformation appliquée par la couche l (souvent BatchNorm + ReLU + Convolution),
- $[x_0, x_1, \dots, x_{l-1}]$: concaténation des cartes de caractéristiques produites par toutes les couches précédentes.




Figure IV.3 - Architecture de modèle DenseNet201.

- Input ($224 \times 224 \times 3$). L'image d'entrée représente les données brutes. Ces données brutes sont utilisées par le modèle. Elle est redimensionnée à une taille standard de 224×224 pixels avec trois canaux (RGB) afin d'être compatible avec l'architecture du réseau de neurones. Cette étape, qui est essentielle, permet de normaliser toutes les images avant leur traitement.

- Pre-trained DenseNet201 (Features Extraction). DenseNet201 est utilisé ici. Il sert d'extracteur de caractéristiques. Cela se fait dans un contexte de Transfer learning. Le modèle, déjà entraîné sur de grandes bases de données, permet d'extraire automatiquement des caractéristiques complexes telles que les textures, les formes et les structures importantes dans l'image, ce qui est un atout considérable pour l'analyse et la compréhension des images.

- Average Pooling : La couche d'Average Pooling permet de réduire la dimension des données. Elle conserve aussi les informations essentielles. Elle transforme les cartes de caractéristiques en un vecteur plus compact, ce qui, d'une part, facilite le traitement par les couches de classification et, d'autre part, réduit la complexité du modèle.

- Flatten (transition vers la classification) : La couche Flatten transforme les données multidimensionnelles issues du réseau convolutionnel en un vecteur unidimensionnel. Cette étape est nécessaire pour connecter la partie d'extraction des caractéristiques aux couches « fully connected » qui sont utilisées pour la classification.

- Full Connected Layers (classification) : les couches fully connected représentent la composante décisionnelle du modèle. Elles combinent les caractéristiques extraites pour apprendre à distinguer les différentes classes, ce qui permet de les identifier avec précision. Les fonctions d'activation ReLU introduisent la non-linéarité, tandis que le dropout réduit le surapprentissage en désactivant certains neurones pendant l'entraînement.

- Output : la couche de sortie utilise une fonction sigmoïde. Cette fonction permet de produire une probabilité comprise entre 0 et 1. La valeur obtenue permet de classer l'image en deux catégories. Ces catégories sont « présence » ou « absence de feu ». Le modèle fournit ainsi une décision binaire basée sur les caractéristiques apprises. Ce modèle combine deux éléments : un réseau pré-entraîné pour l'extraction de caractéristiques et des couches fully connected pour la classification finale. Cette combinaison permet une détection automatique efficace à partir d'images.

IV.3.2.2.1.2. MobileNet

Le modèle MobileNet est une architecture de réseau de neurones convolutifs. Elle est légère. Elle est conçue pour être efficace en termes de calcul et de mémoire. Elle repose sur les convolutions séparables en profondeur. Cela réduit le nombre de paramètres. Les performances de classification sont conservées. Les systèmes qui ont besoin d'une exécution rapide ou de ressources limitées peuvent donc utiliser MobileNet. Ce dernier assure une classification fiable des images satellitaires.




Figure IV.4 - Architecture de model MobileNet.

Images d'entrée : les images d'entrée représentent les données brutes fournies au modèle. Ces images peuvent être médicales, industrielles ou forestières. Avant d'être traitées, elles sont converties en matrices numériques pour que le réseau de neurones puisse les analyser.

- Convolution 3x3 + Batch Normalization + ReLU : Cette première étape permet d'extraire les caractéristiques basiques des images, telles que les bords et les textures, ce qui est essentiel pour la qualité du résultat final. Ces motifs sont détectés par la convolution 3x3, les valeurs sont stabilisées et l'apprentissage est accéléré par la batch normalisation, tandis que la non-linéarité nécessaire au réseau est introduite par la fonction ReLU.

- DW Conv Blocks (Depthwise Convolution Blocks) : Les blocs de convolution depthwise constituent le cœur du réseau, qui est un élément essentiel pour l'apprentissage automatique. Ils permettent de bien séparer les caractéristiques en traitant chaque canal séparément. Ces blocs sont répétés plusieurs fois. Cela permet au modèle d'apprendre progressivement. Le modèle apprend des représentations de plus en plus complexes des images.

- La couche Global Average Pooling réduit la dimension des données en transformant chaque carte de caractéristiques en une seule valeur moyenne. Elle permet de conserver les informations essentielles tout en diminuant fortement la complexité du modèle, ce qui la rend très efficace.

- Dense Layer + Dropout + Softmax : la dernière partie du réseau est dédiée à la classification. Les caractéristiques extraites sont combinées par la couche dense, le sur

apprentissage est réduit par le dropout qui désactive certains neurones, et une distribution de probabilités sur les différentes classes est générée par la fonction Softmax.

Ce modèle, qui transforme progressivement une image brute en une prédiction finale, utilise une succession de couches de convolution, d'extraction de caractéristiques et de classification.

IV.3.2.2.1.3 Différence entre MobileNet et DenseNet

MobileNet utilise des convolutions séparables en profondeur, ce qui permet de réduire le coût de calcul tout en conservant de bonnes performances. DenseNet, en revanche, utilise des convolutionnaires classiques organisées en blocs denses. Chaque couche est reliée à toutes les couches précédentes. Cela permet une extraction plus riche et plus détaillée des caractéristiques. Ainsi, MobileNet privilégie la rapidité et l'efficacité computationnelle grâce à une architecture légère. DenseNet met l'accent sur la précision et la qualité des représentations. Il exploite une structure plus profonde et fortement connectée.

IV.3.2.2.2 Évaluation des métriques de détection

L'évaluation des performances du système de détection et de classification des images satellitaires constitue une étape essentielle pour mesurer la fiabilité et l'efficacité des modèles de Deep Learning utilisés, qui sont des modèles d'apprentissage profond utilisés dans le domaine de l'imagerie satellitaire. De manière générale, les spécialistes entraînent et testent les algorithmes de classification sur des images réelles. Cette section présente les principaux critères d'évaluation permettant d'apprécier les performances de modèles tels que DenseNet201 et MobileNet. Dans ce cadre, différentes métriques sont exploitées pour analyser la qualité des prédictions obtenues.

IV.3.2.2.2.1. Évaluation de la robustesse

La robustesse désigne la capacité de l'algorithme à fournir des résultats fiables et cohérents dans diverses conditions d'analyse d'images satellitaires. Elle permet de détecter correctement la présence ou l'absence de feux, malgré les variations des données (luminosité, conditions atmosphériques, résolution ou type de végétation), tout en réduisant les erreurs de classification. Cette caractéristique est essentielle pour garantir une prise de décision fiable dans le cadre de la surveillance et de la gestion des feux de forêt.

IV.3.2.2.2. Évaluation des performances. Mise en œuvre de l'Accuracy.

L'Accuracy est l'une des métriques les plus couramment utilisées pour évaluer les performances d'un système de détection et de classification d'images satellitaires. Elle correspond à la proportion d'images correctement classées par rapport à l'ensemble des images testées. Une valeur élevée de l'Accuracy indique que le modèle possède une bonne capacité de généralisation. Il fournit des prédictions fiables sur des données inédites [32].

Dans le cadre de ce projet, cette métrique est utilisée pour évaluer les performances des réseaux de neurones convolutifs. Ces derniers incluent DenseNet et MobileNet. Cela permet de comparer leur efficacité en phase d'entraînement et de test. Elle permet ainsi d'identifier le modèle offrant les meilleurs résultats en matière de classification des images satellitaires.

La formule de l'Accuracy est:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad \dots \text{ (IV.4)}$$

où :

- TP: True Positives (vrais positifs)
- TN: True Negatives (vrais négatifs)
- FP: False Positives (faux positifs)
- FN: False Negatives (faux négatifs)

IV.3.2.2.2. 3. Sensibilité (ou Recall)

La sensibilité, ou Recall, est une métrique d'évaluation qui sert à mesurer la capacité d'un modèle de classification à identifier correctement l'ensemble des instances positives d'une classe donnée. Dans le cadre de la détection des feux de forêt à partir d'images satellitaires, elle correspond à la proportion des zones réellement touchées par un incendie qui sont correctement détectées par le modèle, ce qui permet d'évaluer l'efficacité de ce dernier. Une valeur élevée du Recall indique une réduction des faux négatifs, c'est-à-dire des incendies présents mais non détectés.

Dans ce projet, cette métrique est utilisée pour évaluer les performances des modèles de réseaux de neurones convolutifs tels que DenseNet et MobileNet. Cela permet d'analyser leur efficacité dans la détection des zones incendiées sur les images satellitaires. Elle revêt une importance particulière dans les systèmes de surveillance environnementale, où la non-détection d'un feu peut avoir des conséquences graves sur l'écosystème, la biodiversité et la sécurité humaine [33].

La formule du Recall est donnée par :

$$\text{Recall} = \frac{\text{TP}}{(\text{TP} + \text{FN})} \quad \dots \text{ (IV.5)}$$

où :

- TP: nombre de vrais positifs (True Positives),
- FN: nombre de faux négatifs (False Négatives).

IV.3.2.2.4. Spécificité

La spécificité est une métrique d'évaluation qui sert à mesurer la capacité d'un modèle de classification à identifier correctement les éléments négatifs, c'est-à-dire les éléments qui ne correspondent pas à une classe donnée. Dans le cadre de la détection et de la classification des images satellitaires, le taux de rejet correspond à la proportion de zones ou de pixels qui ne sont pas classés, c'est-à-dire qui ne présentent pas la classe étudiée. Une valeur élevée de la spécificité traduit un faible taux de faux positifs, ce qui améliore la fiabilité des résultats obtenus [33].

Dans ce projet, la spécificité est utilisée pour évaluer les performances des modèles de réseaux de neurones convolutifs tels que DenseNet et MobileNet. Cela permet d'analyser leur capacité à reconnaître correctement les zones dépourvues de feux de forêt dans les images satellitaires. Cette métrique permet ainsi de vérifier la réduction des cas où une zone non incendiée est classée à tort comme étant en feu.

La formule de la spécificité est la suivante :

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad \dots \text{ (IV.6)}$$

où :

- TN: vrais négatifs (True Négatives),
- FP: faux positifs (False Positives).

IV.3.2.2.5. Précision

La précision (Precision) est une métrique d'évaluation qui mesure la capacité d'un modèle de classification à identifier correctement les prédictions positives, c'est-à-dire les éléments qui, selon le modèle, ont une probabilité élevée d'appartenir à la catégorie « positif ». Dans le cas de la détection des feux de forêt à partir d'images satellitaires, elle correspond à la proportion des zones détectées comme incendiées qui sont réellement en feu, c'est-à-dire

que si une zone est détectée comme incendiée, cela signifie qu'il y a une probabilité qu'elle soit réellement en feu.

Une précision élevée signifie que le modèle produit peu de faux positifs, c'est-à-dire qu'il classe rarement à tort des zones non incendiées comme des incendies. Cette métrique est donc essentielle dans les systèmes de surveillance et d'alerte, car elle permet de limiter les fausses détections et d'améliorer la fiabilité globale du système.

Dans ce projet, la précision est utilisée pour évaluer les performances des modèles de réseaux de neurones convolutifs. Ces modèles sont par exemple DenseNet et MobileNet. Cela permet d'analyser leur capacité à détecter correctement les incendies dans les images satellitaires [34].

La formule de la précision est la suivante :

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad \dots \text{ (IV.7)}$$

où :

- TP: nombre de vrais positifs (True Positives),
- FP: nombre de faux positifs (False Positives).

Une valeur élevée de la précision signifie que la majorité des zones détectées comme des incendies correspondent réellement à des feux de forêt.

IV.3.2.2.2 .6. False Positive Rate (FPR)

Le False Positive Rate, ou FPR, est un indicateur qui évalue la part des zones non incendiées qui sont classées comme des feux de forêt dans les images satellite. Dans le domaine de la détection des incendies, un FPR faible est essentiel, car il permet, d'une part, de réduire les fausses alertes et, d'autre part, d'améliorer la fiabilité du système.

Cette métrique est utilisée pour évaluer les performances des modèles de réseaux de neurones convolutifs. Ces modèles sont par exemple DenseNet et MobileNet. Ils sont utilisés dans le domaine de la télédétection [34].

La formule est la suivante :

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad \dots \text{ (IV.8)}$$

où

- FP: nombre de faux positifs (False Positives),
- TN: vrais négatifs (True Négatives).

IV.4. Résultats expérimentaux

Nous avons étudié les méthodes de classification. Ces méthodes sont basées sur l'apprentissage profond. Nous les appliquons ici à un ensemble d'images satellitaires. Cet ensemble est en couleurs réelles (RGB).

Les images que nous avons analysées ont des résolutions différentes. Par exemple, certaines ont une résolution de 2244×3384 pixels. Autrement dit, elles ont une largeur de 2244 pixels et une hauteur de 3384 pixels. Toutefois, l'ensemble des images partage les mêmes caractéristiques techniques. En effet, la résolution est de 72 ppp (pixels par pouce) dans les deux directions, ce qui correspond à une qualité d'affichage standard. Elles possèdent une profondeur de couleur de 24 bits, permettant une représentation fidèle des couleurs selon le standard sRGB. Aucune compression spécifique n'est indiquée et l'unité de résolution est de type 2. Ces caractéristiques décrivent des images de grande taille, adaptées aux opérations de prétraitement et d'analyse dans les systèmes de traitement d'images satellitaires.

IV.4.1. Présentation des résultats

Les exemples traités sont des images satellitaires en couleur de tailles variées. Cette série d'expérimentations porte sur des images satellitaires réelles appartenant à deux classes : « feu » et « non-feu ». L'objectif est de permettre la classification automatique des images satellitaires afin d'identifier les zones touchées par les incendies et de les distinguer de celles qui ne sont pas affectées, ce qui permettra de mieux comprendre l'étendue des dégâts et d'intervenir plus efficacement pour éteindre les incendies et protéger les zones non touchées. L'objectif de ces exemples est d'obtenir :

- Procéder à une analyse détaillée des résultats expérimentaux obtenus dans le cadre de la tâche de classification, en s'appuyant sur deux modèles de Deep Learning, à savoir DenseNet201 et MobileNet. Cette analyse prend en compte l'impact de deux techniques de prétraitement appliquées aux images : l'amélioration du contraste et la détection des artefacts, afin d'évaluer leur contribution aux performances des modèles.
- Identifier le modèle le plus performant : Cette étape consiste à comparer les performances des différentes architectures de Deep Learning utilisées, notamment DenseNet201 et MobileNet, à travers plusieurs métriques d'évaluation telles que l'exactitude (Accuracy), la précision (Precision), le rappel (Recall) et Spécificité. L'objectif est de déterminer le modèle offrant le meilleur compromis entre capacité de généralisation, robustesse et efficacité de classification.

- L'objectif de cette analyse est d'évaluer l'influence de la couche de transition utilisée entre l'extracteur de caractéristiques et les couches de classification. Pour cela, on va étudier l'impact des couches Flatten et Global Average Pooling (GAP), ainsi que de leurs différentes architectures. La couche Flatten convertit les cartes de caractéristiques en un vecteur unidimensionnel, ce qui accroît de manière significative le nombre de paramètres entraînaibles. En revanche, la couche Global Average Pooling (GAP) réduit chaque carte de caractéristiques à une seule valeur représentative, ce qui limite la complexité du modèle. Les performances, la capacité de généralisation, le risque de surapprentissage et le coût computationnel de ces deux approches seront comparés par l'étude, tout en analysant leur comportement au sein des architectures DenseNet201 et MobileNet.

- Trois scénarios ont été considérés pour évaluer les performances du classifieur :
 - 1er cas : la base d'apprentissage est constituée de 90 % des images sélectionnées aléatoirement, tandis que la base de test représente les 10 % restantes.
 - Dans le deuxième cas, la base d'apprentissage est composée d'un pourcentage d'images sélectionnées aléatoirement de 80 %, et la base de test de 20 % restantes.
 - Dans le troisième cas, la base d'apprentissage est constituée de 70 % des images sélectionnées au hasard, tandis que la base de test représente les 30 % restants.

IV.4.2. Analyse et discussion

Les résultats expérimentaux obtenus à l'aide des modèles MobileNet et DenseNet201 sont présentés de manière comparative, ce qui permet de mettre en évidence les différences entre les deux méthodes. Les performances de chaque modèle sont détaillées en termes de précision, ce qui permet de les comparer et de choisir celui qui correspond le mieux à ses besoins.

L'efficacité des techniques de prétraitement appliquées est mise en évidence par les résultats dans toutes les images traitées (voir Tableau IV-1). Ces résultats montrent notamment que le contraste est amélioré et que les artefacts sont détectés. Ils permettent également d'évaluer l'impact de ces techniques sur les performances des modèles. Les faibles valeurs de l'erreur quadratique moyenne (MSE) et les valeurs élevées du rapport signal sur bruit de crête (PSNR) indiquent que les opérations effectuées ont amélioré la qualité des images tout en préservant leurs caractéristiques essentielles. Cette amélioration permet une meilleure extraction des caractéristiques pertinentes, ce qui accroît les performances des modèles de classification basés sur l'apprentissage profond.

Le tableau IV.2 présente une comparaison des performances des architectures MobileNet et DenseNet201. Cette comparaison est effectuée en utilisant deux types de couches de sortie. Ces types de couches de sortie sont Flatten et Global Average Pooling (GAP). Les résultats montrent que le choix de la couche de sortie a une influence significative sur les performances de classification et sur la complexité des modèles.

Pour MobileNet, les performances sont optimisées avec une exactitude de 96,15 % en utilisant la couche GAP, contre 92,31 % avec la couche Flatten. Cette amélioration s'accompagne d'une réduction importante du nombre de paramètres, qui passe de 16,1 millions à 3,5 millions, soit une diminution d'environ 78 %. En outre, le modèle GAP présente une perte de test (Loss) nettement inférieure à celle du modèle Flatten (0,1067 contre 0,7345), ce qui démontre une meilleure capacité de généralisation de GAP. La spécificité atteint 100 %, indiquant l'absence de faux positifs sur l'ensemble du test.

Concernant DenseNet201, les résultats montrent une nette amélioration avec l'utilisation de la couche GAP, ce qui confirme l'efficacité de cette dernière dans le cadre de ce projet. L'exactitude passe de 84,62 % à 96,15 %, tandis que la spécificité atteint 100 %, ce qui signifie que toutes les images appartenant à la classe négatives ont été correctement détectées. Le nombre de paramètres est réduit de 42,5 millions à 18,9 millions, soit une réduction de plus de 55 %, tout en améliorant les performances globales du modèle, ce qui est un véritable atout. La perte de test diminue également de 0,4246 à 0,1834.

Les performances globales des versions utilisant GAP sont les meilleures. Elles ont une exactitude identique de 96,15 %. Cependant, MobileNet-GAP a un avantage significatif en termes de complexité : il a seulement 3,5 millions de paramètres, tandis que DenseNet201-GAP en a 18,9 millions. Cela le rend plus léger, plus rapide à entraîner et mieux adapté aux applications qui ont besoin d'une faible consommation de ressources.

L'analyse des résultats met en évidence un point important : l'utilisation de la couche Global Average Pooling (GAP) a un impact positif sur deux aspects clés des modèles. D'une part, elle améliore les performances de classification et, d'autre part, elle optimise l'efficacité computationnelle. Une légère supériorité est observée pour MobileNet-GAP, grâce à son excellent compromis entre précision et nombre de paramètres. Par conséquent, dans la suite de ce travail, nous avons décidé de nous concentrer sur l'utilisation de la couche GAP.

Tableau IV.2 – Comparaison des performances des modèles DenseNet et MobileNet utilisant les couches Flatten et Global Average Pooling (GAP).

Model	MobileNet		Densenet201	
layer	Flatten	GAP	Flatten	GAP
Total params	16, 128,028 (61.52 MB)	3, 545,116 (13.52 MB)	42, 460,572 (161.97 MB)	18, 867,612 (71.97 MB)
Test Accuracy	92.31 %	96.15%	84.62%	96.15%
Test Loss	0.7345	0.1067	0.4246	0.1834
Precision	92.31 %	96.54 %	84.73 %	96.37 %
Sensibilité (Recall)	92.31 %	96.15 %	84.62 %	96.15 %
Spécificité	88.89 %	100.00 %	66.67 %	88.89 %

Afin d'évaluer les performances des modèles DenseNet201 et MobileNet, nous avons réalisé plusieurs expérimentations en faisant varier la taille de l'ensemble de test. Cette taille a été modifiée à 10 %, 20 % et 30 % pour les tests. Les résultats présentés dans le tableau IV.3 montrent que les deux modèles obtiennent des performances globalement élevées, avec des valeurs de précision globale (Accuracy) supérieures à 93 % dans tous les cas, ce qui confirme l'efficacité de ces modèles.

Pour le modèle DenseNet201, la meilleure performance est obtenue avec une taille de test de 20 %. L'Accuracy atteint alors 98,08 %, accompagnée d'une faible valeur de perte (Loss = 0,0542). Lorsque nous augmentons la taille de test à 30 %, l'Accuracy diminue légèrement à 93,59 %, ce qui s'explique par une réduction de la quantité de données disponibles pour l'apprentissage. Concernant MobileNet, les résultats sont également satisfaisants et relativement stables. L'Accuracy présente une variation entre 96,15 % et 97,44 %, la meilleure valeur étant obtenue avec une taille de test de 30 %. En outre, les valeurs de précision, de rappel (Recall) et de spécificité attestent de la capacité du modèle à distinguer adéquatement les différentes classes.

Les deux architectures ont été comparées, et la meilleure précision globale (98,08 %) a été obtenue par DenseNet201 avec une taille d'ensemble de test de 20 %, tandis que des performances plus stables pour les différentes tailles de test sont présentées par MobileNet tout en nécessitant un nombre de paramètres nettement inférieur (3,5 millions contre 18,9 millions pour DenseNet201). Bien que MobileNet présente un meilleur équilibre entre

performances et coût de calcul, les résultats obtenus indiquent que la configuration basée sur DenseNet201 avec un ensemble de test de 20 % offre les meilleures performances de classification. Par conséquent, dans la suite de ce travail, nous avons choisi de fixer la taille de test à 20 % pour toutes les expérimentations. Cette décision nous a permis d'obtenir des résultats très satisfaisants en termes de précision et de capacité de généralisation du modèle.

Tableau IV.3 – Performances des modèles DenseNet201 et MobileNet (couche GAP) pour différentes tailles de l'ensemble de test.

Model	Densenet201			MobileNet		
Test size	10	20	30	10	20	30
Total params	18, 867,612 (71.97 MB)			3, 545,116 (13.52 MB)		
Test Accuracy	96.15%	98.08%	93.59%	96.15%	96.15%	97.44%
Test Loss	0.1834	0.0542	0.1939	0.1067	0.1253	0.0963
Precision	96.37 %	98.13 %	93.67 %	96.54 %	96.37 %	97.53 %
Sensibilité (Recall)	96.15 %	98.08 %	93.59 %	96.15 %	96.15 %	97.44 %
Spécificité	88.89 %	94.74 %	92.86 %	100.00 %	89.47 %	92.86 %

Le tableau IV.4 illustre les performances des modèles MobileNet et DenseNet201 en matière de classification. Ces deux modèles utilisent la couche Global Average Pooling (GAP) et une taille de test de 20 %. Ils se distinguent par leurs résultats, avec des variations notables en termes de précision et de complexité.

MobileNet est un modèle léger et efficace en termes de calcul. Il atteint un taux de précision de 96,15 %, avec un taux de perte de 0,1253, une précision de 96,37 % et une spécificité de 89,47 %. Ces résultats traduisent une bonne capacité de généralisation. Ils maintiennent aussi un coût computationnel réduit. Cela est dû à son faible nombre de paramètres (3,5 millions). Cependant, ses performances restent légèrement inférieures à celles de DenseNet201 en termes de précision globale, bien qu'elles soient tout de même très proches.

DenseNet201, quant à lui, est un modèle plus profond et plus complexe, ce qui le distingue des autres modèles existants. Il obtient de meilleures performances globales avec une précision maximale de 98,08 %, une perte réduite de 5,42 %, une précision de 98,13 %, ainsi qu'une spécificité de 94,74 %. Ces résultats indiquent une meilleure capacité de discrimination entre les classes par rapport à MobileNet, ce qui suggère que l'algorithme de ce

dernier pourrait être optimisé pour améliorer ses performances de classification. Toutefois, cette amélioration de performance se fait au prix d'un nombre de paramètres beaucoup plus élevé (18,9 millions). Cela implique un coût computationnel plus important.

On peut ainsi conclure que DenseNet201 est légèrement plus performant en termes de précision globale, tandis que MobileNet constitue une alternative plus légère et plus efficace en termes de ressources, offrant un bon compromis entre performance et complexité.

Tableau IV.4 - Performances des modèles DenseNet201 et MobileNet.

Model	MobileNet	Densenet201
layer	GAP	GAP
Test size	20	20
Total params	3, 545,116 (13.52 MB)	18, 867,612 (71.97 MB)
Test Accuracy	96.15%	98.08%
Test Loss	0.1253	0.0542
Precision	96.37%	98.13%
Sensibilité (Recall)	96.15%	98.08%
Spécificité	89.47%	94.74%

Ces résultats sont représentés sur la figure ci-dessous :




Figure IV.5 - Évolution de la perte Loss et de l'Accuracy de l'entraînement et de la validation du modèle DenseNet201.

La figure IV.5 présente l'évolution des courbes de perte (Loss) et de précision (Accuracy) du modèle DenseNet201 avec la couche GlobalAveragePooling, pour les ensembles d'entraînement et de validation.

Concernant la courbe de Loss, on observe une diminution rapide dès les premières époques, passant d'une valeur élevée à des valeurs proches de zéro, ce qui confirme l'hypothèse initiale. La perte d'entraînement et celle de validation suivent une tendance comparable avec de subtiles variations, ce qui suggère que le modèle apprend avec efficacité et réussit à minimiser l'erreur au fil du temps. On remarque, pour la courbe d'Accuracy, une augmentation progressive de la précision, qui atteint rapidement des valeurs proches de 98% à 100%. Les courbes d'entraînement et de validation se rejoignent presque, ce qui indique que le modèle peut généraliser efficacement et qu'il n'y a pas de surapprentissage significatif.

Dans l'ensemble, ces résultats montrent que l'architecture DenseNet201 avec GlobalAveragePooling offre de très bonnes performances pour la classification des feux de forêt. Cette classification présente une convergence rapide, une faible perte et une précision élevée.

IV.5. Conclusion

Dans ce chapitre, nous avons présenté les différentes expérimentations réalisées sur le dataset composé d'images fire et nofire. L'objectif était d'évaluer les performances des modèles MobileNet et DenseNet201. Avant l'entraînement, plusieurs techniques de prétraitement ont été appliquées aux images. Cela a notamment consisté en le redimensionnement, l'amélioration de la luminosité et du contraste, ainsi que l'évaluation de la qualité des images à l'aide du PSNR. Ces opérations ont permis d'améliorer la qualité des données et de faciliter l'apprentissage des modèles.

Les résultats obtenus montrent que l'intégration de la couche Global Average Pooling (GAP) améliore significativement les performances des deux architectures. Cela se fait en réduisant le nombre de paramètres. Cela permet aussi de réduire le risque de surapprentissage. Les modèles utilisant la GAP ont obtenu de meilleures performances en termes de précision, de rappel et de taux de réussite par rapport à ceux utilisant la couche Flatten.

L'étude comparative a également révélé que DenseNet201 offre les meilleures performances en matière de précision de classification, tandis que MobileNet se distingue par son efficacité, sa rapidité d'exécution et sa faible complexité computationnelle. Cette étude met en évidence l'importance du prétraitement des images. Elle met aussi en évidence l'importance du choix de l'architecture du réseau. Et enfin, elle met en évidence l'importance de l'optimisation des paramètres. Tout cela dans la conception d'un système intelligent de détection et de classification des incendies. Ce système est basé sur le Deep Learning.

V.1. Récapitulatif

Ce mémoire a permis d'explorer différents aspects. Ces aspects sont liés au traitement des images satellitaires. Ils sont aussi liés à l'application des techniques d'intelligence artificielle. Ces techniques servent à la détection et à la surveillance des incendies. Les principaux axes abordés au cours de cette étude peuvent être résumés comme suit :

- Étude des images.
- Pour réaliser cette étude, nous avons exploité des images satellitaires. Celles-ci sont dédiées à la surveillance environnementale et à la détection des feux de forêt.
 - i) Nous avons analysé les caractéristiques et les spécificités des images satellitaires utilisées dans ce domaine. Nous avons mis l'accent sur leur résolution spatiale, spectrale et temporelle. Nous avons aussi mis l'accent sur leur importance pour l'identification rapide et précise des zones touchées par les incendies.
 - ii) Nous avons étudié les différentes étapes du traitement des images satellitaires, notamment l'acquisition des données, le prétraitement, l'extraction des caractéristiques pertinentes et la classification, afin de comprendre comment les images sont traitées. L'amélioration de la qualité des données, la facilitation de leur analyse et l'accroissement des performances des systèmes de détection des feux de forêt sont rendues possibles par l'emploi de ces techniques.
- De nouvelles perspectives ont été ouvertes dans le domaine de la détection des feux de forêt à partir d'images satellitaires grâce aux avancées récentes de l'intelligence artificielle, et plus particulièrement de l'apprentissage profond. Ces approches reposent sur des architectures capables d'extraire automatiquement des caractéristiques pertinentes à partir de données de grande dimension, ce qui permet de faciliter le traitement de ces données et d'en extraire l'information souhaitée de manière efficace. Parmi ces méthodes, les réseaux de neurones convolutifs (CNN) se distinguent par leur efficacité dans les tâches de détection et de classification d'images. La rapidité et la précision de la détection des zones incendiées sont significativement améliorées grâce à leur utilisation, ce qui contribue à une meilleure surveillance et gestion des incendies de forêt.

Pour aboutir à cela nous avons fait les étapes suivantes :

- Dans la première partie de ce mémoire, nous avons consacré nos efforts à une revue de la littérature portant sur la détection des feux de forêt, les techniques de traitement des images satellitaires, ainsi que les principaux modèles de classification que l'on applique à ce domaine. Les approches fondées sur l'apprentissage automatique et l'apprentissage profond ont montré des résultats encourageants dans la détection et la surveillance des incendies, malgré certaines limitations liées à la variabilité des données et aux conditions environnementales.
- La deuxième partie de ce mémoire a porté sur les réseaux de neurones convolutifs (CNN). Ces derniers sont largement utilisés pour la classification des images satellitaires. Cela est dû à leur efficacité face à des données complexes et multidimensionnelles. Ces méthodologies offrent une solution à la fois résiliente et pleine de promesses pour la détection précoce des incendies de forêt. Les résultats de cette étude démontrent que les CNN peuvent être appliqués avec succès à la classification des images satellitaires, même en présence de jeux de données limités, ce qui ouvre la voie à de nouvelles possibilités pour l'analyse et l'interprétation des données d'imagerie satellite. Plusieurs expérimentations ont été réalisées à l'aide de Python, afin d'évaluer l'influence de différents paramètres sur les performances des modèles, et ce, dans le but de trouver les paramètres optimaux. Les résultats obtenus sont satisfaisants et la pertinence des CNN dans la détection des zones incendiées est confirmée.
- La troisième et dernière partie de ce travail a été consacrée à la mise en œuvre pratique. Cette mise en œuvre porte sur les modèles de réseaux de neurones convolutifs. Ces modèles ont été présentés précédemment. Nous avons implémenté une approche de classification sur des images satellitaires. Nous l'avons testée. Elle permet de distinguer les zones de feu et de non-feu. Dans le cadre de cette étude, les résultats obtenus montrent que la robustesse du modèle DenseNet201 permet d'atteindre des performances satisfaisantes. Ces performances sont obtenues pour la prise de décision « feu / non-feu ». Elles sont atteintes à partir des images satellitaires. Plusieurs améliorations sont néanmoins envisageables pour la classification des images satellitaires, notamment en ce qui concerne la précision des résultats et la facilité d'utilisation.

V.2. Perspectives

Ce travail ouvre plusieurs perspectives prometteuses dans le domaine de la détection des feux de forêt à partir d'images satellitaires et de l'intelligence artificielle, ce qui pourrait révolutionner la manière dont nous gérons ces catastrophes naturelles. L'utilisation de ces technologies permet d'améliorer la surveillance environnementale, la détection précoce des incendies et l'aide à la prise de décision pour la gestion des catastrophes naturelles.

Dans le futur, il serait intéressant d'expérimenter d'autres architectures d'apprentissage profond, comme VGG16, ResNet50 ou des modèles comparables, afin d'évaluer leurs performances. L'amélioration de la qualité des données et de la précision des systèmes de détection pourrait être atteinte par l'intégration de techniques plus avancées d'apprentissage profond. Cela inclut des réseaux de neurones convolutifs plus profonds, des modèles hybrides ou encore des réseaux antagonistes génératifs (GAN). Par ailleurs, l'utilisation de l'apprentissage par transfert (Transfer learning) à partir de modèles préentraînés constitue une piste intéressante. Cela permet de renforcer les performances. C'est particulièrement vrai lorsque les jeux de données sont limités.

En outre, l'expérimentation d'algorithmes appliqués aux données radar représente une perspective prometteuse, notamment pour améliorer la détection dans des conditions météorologiques défavorables, ce qui pourrait s'avérer particulièrement utile dans des situations où la visibilité est réduite. Enfin, l'intégration de ces approches à des systèmes de surveillance en temps réel, combinant des données issues de multiples sources (satellites, drones, capteurs au sol), représente une avancée significative pour améliorer la prévention et la gestion efficace des incendies de forêt.

BIBLIOGRAPHIE

- [1] FAO, "Organisation des Nations Unies pour l'alimentation et l'agriculture", Éditeur : Evaluation des ressources forestières mondiales: rapport principal, Rome, 2002.
- [2] Dahmane Bounoua Belghali, Nehal Habib «Amélioration du Contraste et la détection du ROI dans des Images satellitaire ; Application à l'environnement et au développement durable», master Système des Télécommunication ; 2023.
- [3] Atlas Magazine (17 octobre 2025). « L'Algérie enregistre plus de 800 incendies en 2025 », Atlas-Mag.net.
- [4] Bilan des incendies élaboré par la Direction générale des forêts (DGF). <http://www.djazair50.dz/?Bilan-des-incendies-de-forets> 15/09/2014.
- [5] Stephen J. Pyne, Patricia L. Andrews, and Richard D. Lave John Wiley & Sons; « Introduction to Wild land Fire » – second edition, 1996.
- [6] Edward A. Johnson & Kiyoko Miyonishi; « Forest Fires: Behavior and Ecological Effects» – Academic Press, 2001
- [7] INERIS – Étude technique portant sur le rôle des parcs photovoltaïques dans les feux de forêt (2023)
- [8] MARGERIT J., 1998-Modélisation et simulations numériques de la propagation de feus de forêts. Thèse. Doc. Inst. National polytechnique de lorraine. Nancy, France, 260 p.
- [9] Organisation Mondiale de la Santé (OMS/WHO) : Air Quality Guidelines et rapports sur l'impact sanitaire des particules fines issues de la combustion de biomasse.
- [10] Global Fire Emissions Data base (GFED) : Base de données scientifique utilisée pour les estimations mondiales de gaz à effet de serre issus des incendies (gfed.org).
- [11] Copernicus Atmosphere Monitoring Service (CAMS): Global Fire Monitoring and Carbon Emissions Reports. Ce service de l'Union européenne fournit les relevés satellites en temps réel sur les flux de carbone.
- [12] Campbell, J. B.; Introduction to Remote Sensing»; New York: Guilford Press mars 2011.

- [13] Télédétection par satellite : principes, techniques et applications. EOS Data Analytics. Consulté sur EOS.com le 09 janvier 2026.
- [14] John Wiley & Sons, Remote Sensing and Image Interpretation, New York, 2015.
- [15] Benkraouda Souleyman, « Détection des feux de forêts à partir d'images satellitaires infrarouges thermiques IRT en utilisant l'image de l'inverse de la probabilité d'appartenance », Doctorat LMD 2015 ; Génie Electrique.
- [16] www.mcours.net/fra15/laillfra15lan192.pdf.
- [17] Stuart Russell & Peter Norvig, Artificial Intelligence: A Modern Approach, 4^e edition, Pearson, 2021.
- [18] Tegmark M. (2017). Life 3.0: Being Human in the Age of Artificial Intelligence. Knopf.
- [19] OUAMOUNO ANTOINE KOLY; La télédétection spatiale et application en Géosciences ; projet de fin d'étude ; 12/07/2021; Université Abdelmalek Essaadi ; Faculté des Sciences de Tétouan.
- [20] Turing, A. (2004). Computing Machinery and Intelligence. In The Essential Turing. Oxford University Press.
- [21] Deep Learning – Good fellow, I., Bengio, Y., & Courville, A. (2016); Deep Learning MIT Press.
- [22] Pattern Recognition and Machine Learning – Bishop, C. M. (2006); Springer.
- [23] Zhu, X., & Goldberg, A. B. (2009); Introduction to Semi-Supervised Learning; Morgan & Claypool.
- [24] Sutton, R. S., & Barton, A. G. (2018). Reinforcement Learning: An Introduction (2nd Ed.); Massachusetts Institute of Technology (MIT) Press.
- [25] Convolutional Neural Networks (CNN) Architecture – Xavier, Ian Good fellow & Yoshua Bengio; Deep Learning Book / MIT Press, 2016.
- [26] Le Cun, Y., Bengio, Y., & Hinton, G. (2015); Deep learning; Nature, 521, 436–444.
- [27] Bombazine, R., et al. (2021); On the Opportunities and Risks of Foundation Models. Stanford Center for Research on Foundation Models.

- [28] DJABALLAH_MOHAMMED ABDELMOUMEN, « Système de prédiction de la consommation d'énergie basé Deep Learning », Université de 8 Mai 1945 – Guelma -, master LMD 2021 ; Département d'Informatique.
- [29] K. Muhammad, J. Ahmad, and S. W. Baik, "Early fire detection using Convolutional neural networks during surveillance for effective disaster management,"
- [30] Python Crash Course, Eric Matthes, *Python Crash Course*, No Starch Press, 2^e edition, 2019.
- [31] Digital Image Processing, Rafael C. Gonzalez et Richard E. Woods, *Digital Image Processing*, Pearson Education, 4^e edition, 2018.
- [32] Hands-On Machine Learning with Scikit -Learn, Keras & TensorFlow, Aurélien Géron, Hands- On Machine Learning with Scikit-Learn, Keras & TensorFlow, O'Reilly Media, 2^e edition, 2019.
- [33] Image Processing, Analysis, and Machine Vision, Milan Sonka, Vaclav Hlavac, Roger Boyle, Image Processing, Analysis, and Machine Vision, Cengage Learning, 4^e edition, 2014.
- [34] <https://www.scikit-learn.org/stable/presentations.html>