

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Abdelhamid Ibn Badis-Mostaganem

Faculté des Sciences Exactes et d'Informatique

Département de Mathématiques et informatique

Filière : Informatique

**Mémoire de fin d'étude en vue de l'obtention du diplôme de Master en
informatique**

Spécialité IA&IOT

Thème :

**Synergie entre Intelligence Artificielle et Systèmes d'Information
Géographique pour la Modélisation Prédictive des Incendies de Forêt :
Intégration des Données Géospatiales, Indices de Combustion et
Données Météorologiques.**

Réalisé par :

BENDREF FATIMA.

LAOUDJ AMINA.

Encadré par :

Dr. MIDOUN Mohammed.

Année 2024/2025

Résumé

Ce mémoire explore la synergie entre l'intelligence artificielle et les systèmes d'information géographique (SIG) pour la modélisation prédictive des incendies de forêt. Il s'intéresse aux différents types de données environnementales et météorologiques, et à leur intégration dans des modèles d'apprentissage automatique. Une attention particulière est portée aux indices de combustion, aux données spatiales et à leur traitement avec des outils géospatiales. Le travail examine les approches de prédiction basées sur des modèles tels que les réseaux de neurones et les machines à vecteurs de support (SVM), en détaillant les choix méthodologiques, l'architecture des modèles et leur mise en œuvre. Enfin, les résultats expérimentaux sont présentés, mettant en évidence les performances obtenues et les défis rencontrés en matière de précision, de généralisation et d'applicabilité sur le terrain.

Mots clés : Intelligence Artificielle, Systèmes d'Information Géographique, Incendies de forêt ; Modélisation prédictive

Abstract

This thesis explores the synergy between artificial intelligence and geographic information systems (GIS) for the predictive modeling of forest fires. It focuses on various types of environmental and meteorological data and their integration into machine learning models. Particular attention is given to combustion indices, spatial data, and their processing using geospatial tools. The study examines prediction approaches based on models such as neural networks and support vector machines (SVM), detailing methodological choices, model architectures, and their implementation. Finally, the experimental results are presented, highlighting the performances achieved and the challenges encountered in terms of accuracy, generalization, and applicability in the field.

Keywords: Artificial Intelligence; Geographic Information Systems, Forest Fires, Predictive Modeling

Remerciement

Nous tenons à exprimer notre profonde gratitude à toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce travail.

Nous remercions tout d’abord Dr. MIDOUN Mohammed, notre encadrant universitaire, pour son accompagnement précieux, ses conseils avisés et sa disponibilité tout au long de ce projet. Sa rigueur scientifique et ses orientations méthodologiques ont grandement enrichi ce travail.

Nos remerciements s’adressent aussi à l’ensemble des enseignants et intervenants de la formation Master 2 Intelligence Artificielle pour l’Internet des Objets, pour la qualité de leur enseignement et le savoir qu’ils nous ont transmis tout au long de notre cursus.

Un grand merci à nos familles et à nos proches, pour leur soutien indéfectible, leur patience et leurs encouragements constants.

Enfin, nous remercions toutes les personnes — collègues, amis et professionnels — qui ont contribué, directement ou indirectement, à la réalisation de ce mémoire.

Liste des Figures

Figure 1 : Localisation de la zone d'étude Park Naturel Montesinho au Portugal	44
Figure 2 : Pipeline de traitement et de modélisation pour la prévision des risques d'incendies de forêt	55
Figure 4 : Distributions des indices d'inflammabilité du système FWI (FFMC, ISI, DMC, DC) 59	
Figure 5 : Analyse de la distribution des variables climatiques influençant les incendies dans le Parc Naturel de Montesinho.....	60
Figure 6 : Analyse des valeurs aberrantes des variables météorologiques et des indices du comportement du feu via des boxplots	62
Figure 7 : Distribution de la variable cible surface brûlée avant et après transformation...	62
Figure 8 : Matrices de corrélation entre les variables météorologiques et la surface brûlée et les indices FWI et la surface brûlée	63
Figure 9 : Matrice de corrélation entre toutes les variables numériques du jeu de données sur les incendies de forêt	65
Figure 10 : Histogrammes mensuels et hebdomadaires des incendies	66
Figure 11 : Nombre d'incendies et Surfaces totales brûlées par cellule	67
Figure 12 : Cartes mensuelles (9x9) de fréquence et de surface brûlée.....	68
Figure 13 : Visualisation des Facteurs de Risque d'Incendie (FFMC, ISI, DMC, DC) sur une Grille Géographique 9x9.....	69
Figure 14 : Dynamique Mensuelle des Facteurs de Risque d'Incendie (FFMC, ISI, DMC, DC) sur Grille 9x9.....	70
Figure 15 : Analyse Spatiale des Facteurs Météorologiques Clés du Risque d'Incendie (Grille 9x9)	71
Figure 16 : Dynamique Spatio-Temporelle mensuelle des Facteurs Météorologiques du Risque d'Incendie (Grille 9x9).....	72
Figure 17 : Détermination du Nombre Optimal de Clusters pour la Classification des Zones Inflammables (Méthode du Coude et Score de Silhouette)	73
Figure 18 : Classification des Zones à Risque d'Incendie par K-Means++ (Grille 9x9)	73

Figure 19 : Matrices de confusion du modèle Random Forest avant et après optimisation.	76
Figure 20 : Matrices de confusion du modèle SVM avant et après optimisation.	76
Figure 21: Matrices de confusion du modèle XGBoost avant et après optimisation.	77
Figure 23 : Courbes d'apprentissage du modèle LSTM : perte sur l'ensemble d'entraînement et de validation.....	80
Figure 24: Dispersion des prédictions du modèle LSTM par rapport aux valeurs réelles de surface brûlée.....	81

Liste des Tableaux

<i>Tableau 1: Données utilisées pour l'évaluation et la prédiction des incendies de forêt</i>	<i>25</i>
<i>Tableau 2 : Récapitulatif des indicateurs et indices de risque d'incendie.....</i>	<i>27</i>
<i>Tableau 3 : Comparaison des systèmes de gestion des incendies de forêt.....</i>	<i>30</i>
<i>Tableau 4 : Tableau comparatif des modules intégrés et des indicateurs utilisés.....</i>	<i>31</i>
<i>Tableau 5 : comparatif des modèles de ML/DL pour la gestion des incendies de forêt</i>	<i>41</i>
<i>Tableau 6 : Description des variables utilisée pour les modèles de prédiction des incendies de foret</i>	<i>49</i>
<i>Tableau 7 : Statistiques descriptives des variables météorologiques, topographiques et de localisation utilisée pour la modélisation des incendies de forêt.</i>	<i>58</i>
<i>Tableau 8 : Tableau Comparatif Optimisé</i>	<i>77</i>
<i>Tableau 9 : Performances quantitatives du modèle LSTM</i>	<i>81</i>
<i>Tableau 10 : Tableau récapitulatif des performances des modèles de ML : Random Forest Optimisé, XGBoost Optimisé, SVM Optimisé et du modèle de DL : LSTM</i>	<i>83</i>

Liste des abréviations

Abréviation	Expression Complète
IA	Intelligence Artificielle
IOT	Internet Of Think
SIG	Systèmes d'Information Géographique
EFFIS	European Forest Fire Information System
NFDRS	National Fire Danger Rating System
CFFDRS	Canadian Forest Fire Danger Rating System
AFDRS	Australian Fire Danger Rating System

Table des matières

Résumé	2
Abstract	3
Remerciement	4
CHAPITRE 1 : CONTEXTE ET PROBLÉMATIQUE DES INCENDIES DE FORÊT	16
1.1. Introduction.....	16
1.2. Introduction générale aux incendies de forêt.....	16
1.2.1. Définition et caractéristiques des incendies de forêt :.....	16
1.2.2.1 Types d'incendies de forêt :	16
1.2.1.2 Évolution des incendies :	17
1.2.2. Facteurs déclencheurs des incendies de forêt :.....	17
1.2.2.1. Les facteurs naturels :	17
1.2.2.2. Facteurs anthropiques :	18
1.2.3. Impacts des incendies de forêt :	18
1.2.3.1. Conséquences écologiques :	19
1.2.3.2. Conséquences économiques et sociales :	19
1.3. Stratégies de gestion des incendies de forêt	20
1.3.1. Surveillance et détection des incendies :	20
1.3.1.1. Méthodes traditionnelles :	20
1.3.1.2. Technologies modernes :	20
1.3.2. Prévention des incendies :	21
1.3.3. Intervention et suppression des incendies :	21
1.4. Modélisation et prévision des incendies de forêt.....	22
1.4.1. Importance de la prévision des incendies :	22
1.4.2. Modèles de prévision des incendies :	23
1.4.2.1. Modèles empiriques et statistiques :	23
1.4.2.2. Modèles physiques et mécanistiques :	23
1.4.3. Données et indicateurs utilisés pour la prévision des incendies :.....	23
1.4.3.1. Données météorologiques.....	23

1.4.3.2. Données sur la végétation et les combustibles.....	24
1.4.3.3. Données topographiques.....	24
1.4.3.4. Données historiques sur les incendies.....	24
1.4.3.5. Données anthropiques et infrastructures.....	24
1.4.3.6. Données de surveillance en temps réel.....	25
1.4.3.7. Indicateurs et indices de risque d'incendie.....	26
1.5. Systèmes de gestion et de prévision des incendies de forêt	28
1.5.1. European Forest Fire Information System (EFFIS) – Europe	28
1.5.2. National Fire Danger Rating System (NFDRS) – États-Unis.....	28
1.5.3. Canadian Forest Fire Danger Rating System (CFFDRS) – Canada	29
1.5.4. Australian Fire Danger Rating System (AFDRS) – Australie.....	29
1.5.5. Comparaison des systèmes	30
1.6. Limites des approches traditionnelles et justification d'une nouvelle approche.....	32
1.6.1. Contraintes des méthodes classiques :.....	32
1.6.2. Nécessité d'intégrer des approches innovantes :	33
1.7. Problématique et objectifs de la recherche	33
1.8. Conclusion	34
CHAPITRE 2 : Intelligence Artificielle et Systèmes d'Information Géographique (SIG) pour la Prévision et la Gestion des Feux de Forêt	35
2.1. Introduction :.....	35
2.2. Systèmes d'Information Géographique (SIG) pour la Gestion des Feux de Forêt.....	35
2.2.1. Définition et rôle des SIG :	35
2.2.2. Sources de données SIG utilisées pour la gestion des feux :.....	36
2.2.3. Indicateurs géospatiaux pour la gestion des incendies :	36
2.2.4. Plateformes SIG pour la gestion des incendies :	36
2.3. Intelligence Artificielle pour la Détection et la Prévision des Feux de Forêt	37
2.3.1. Apports de l'IA dans la gestion des incendies :.....	37
2.3.2. Modèles de Machine Learning pour la prévision des incendies	37

3.3.2.1. Modèles classiques supervisés	37
2.3.2.2. Modèles profonds (Deep Learning) pour la prévision et la propagation des feux.....	38
2.3.2.3. Modèles génératifs et apprentissage par renforcement.....	39
2.4. Comparaison des Modèles et Approches Utilisés	40
2.5. Intégration des Systèmes d'Information Géographique et de l'Intelligence Artificielle pour une Gestion Intelligente des Incendies.....	42
2.5.1. Systèmes hybrides combinant SIG et IA.....	42
2.5.2. Études de cas et applications réelles	42
2.6. Conclusion	43
Chapitre 3 : Méthodologie de Développement d'un Modèle Prédictif des Incendies de Forêt Basé sur l'Intelligence Artificielle et les Systèmes d'Information Géographique	44
3.1. Objectif et Approche Générale	44
3.2. Environnement et Outils de Développement	45
3.2.1. Plateforme de Développement	45
3.2.2. Bibliothèques Python Utilisées	46
3.2.3. Ressources matérielles	48
3.2.4. Intégration SIG.....	48
3.3. Description des Données	48
3.4. Développement des Modèles Prédictifs	50
3.4.1. Modèles de Machine Learning pour la Prévision des Incendies.....	50
3.4.1.1. Modèles classiques supervisés	50
3.4.1.2. Modèles profonds pour la prévision et la propagation des feux	50
3.4.2. Évaluation de la Performance.....	51
3.5. Pipeline de Traitement des Données.....	51
3.5.1. Collecte des Données	51
3.5.2. Acquisition des Données	51
3.5.3. Prétraitement des Données.....	52

3.5.4. Analyse et Visualisation Exploratoire.....	53
3.5.5. Modélisation Prédictive	53
3.5.6. Intégration et Visualisation Finale.....	54
3.6. Conclusion	56
CHAPITRE 4 : Implémentation et Analyse des Résultats.	57
4.1. Présentation de la Zone d'Étude et des Données.....	57
4.2. Description des jeux de données utilisés.....	57
4.3. Prétraitement et Intégration des Données	61
4.3.1. Préparation des Données Catégorielles	61
4.3.2. Normalisation des Variables Numériques	61
4.3.3. Visualisation des Valeurs Aberrantes	61
4.3.4. Transformation de la Variable Cible	62
4.3.5. Création de Variables Temporelles.....	63
4.4. Analyse Exploratoire et Visualisation des Données.....	63
4.4.1. Analyse de corrélation	63
4.4.2. Analyse temporelle	65
4.4.3. Analyse spatiale	66
4.4.4. Analyse spatio-temporelle	67
4.4.5. Analyse des indices FWI	68
4.4.6. Analyse Spatiale des Facteurs Météorologiques.....	70
4.4.7. Classification des Zones Inflammables	72
4.5. Modélisation Prédictive : Feux de Forêt	74
4.5.1. Objectif de modélisation	74
4.5.2. Constitution du jeu de données pour le Machine learning.....	74
4.5.3. Séparation des données.....	75
4.5.4. Application des Modèles de Machine Learning (ML)	75
4.5.4.1. Modèles de Machine Learning utilisés	75
4.5.4.2. Résultats Après Optimisation des modèles de machine learning	77
4.5.4.3. Analyse des Résultats :.....	78
4.5.5. Application des Modèles de Deep Learning (DL).....	78
4.5.5.1. Le modèle LSTM (Long Short-Term Memory)	78

4.5.5.2 Construction des Séquences Temporelles	79
4.5.5.3. Architecture du Modèle.....	79
4.5.5.4. Analyse des Résultats et Interprétation	79
4.6. Discussion et Interprétation des Résultats	82
4.6.1. Rappel des Performances des Modèles Classiques	82
4.6.2. Bilan des Modèles et Recommandations	83
4.7. Conclusion	84
Conclusion générale	85
Bibliographie.....	Error! Bookmark not defined.

Introduction Générale

Les incendies de forêt sont un phénomène mondial aux conséquences dévastatrices, touchant divers écosystèmes et ayant des impacts majeurs sur l'environnement, l'économie et la société. Autrefois perçus comme des événements naturels, ils sont aujourd'hui amplifiés par le changement climatique et les activités humaines, devenant ainsi un enjeu crucial du 21^e siècle.

Ces dernières décennies, la fréquence et l'intensité de ces incendies ont connu une hausse alarmante. Des conditions climatiques extrêmes, telles que les températures élevées, les sécheresses prolongées et les vents forts, favorisent leur propagation. Par ailleurs, l'expansion urbaine, la déforestation et certaines pratiques agricoles accentuent les risques.

Les conséquences sont multiples : sur le plan environnemental, on observe une perte de biodiversité, des émissions accrues de CO₂ et une dégradation des sols ; sur le plan économique, des pertes matérielles importantes et des coûts élevés de lutte ; sur le plan social, des déplacements de populations, des pertes humaines et des traumatismes psychologiques.

Face à cette menace croissante, il devient impératif de mettre en place des systèmes de surveillance et de gestion efficaces. L'intégration de technologies avancées, telles que la télédétection, l'intelligence artificielle (IA) et les systèmes d'information géographique (SIG), permet d'améliorer la prévention, la détection et la réponse face aux incendies. Une coordination à différents niveaux est également nécessaire pour atténuer leurs effets et protéger les écosystèmes vulnérables.

La complexité de ces feux réside dans l'interaction de nombreux facteurs : conditions météorologiques, topographie, type de végétation, ou encore activités humaines. Les méthodes traditionnelles, comme les patrouilles ou les brûlages contrôlés, montrent leurs limites, notamment dans les zones reculées et en termes de coût et d'efficacité.

Dans ce contexte, ce travail de recherche vise à développer un modèle innovant combinant IA et SIG pour prédire, détecter et mieux gérer les incendies de forêt. L'objectif principal est d'intégrer des données multidimensionnelles (météorologiques, environnementales, topographiques et historiques) afin de produire des prévisions fiables et des outils d'aide à la décision en temps réel.

Les objectifs spécifiques sont les suivants :

Étudier les stratégies actuelles de gestion des incendies pour en identifier les limites;

- Collecter et analyser les données pertinentes pour la modélisation du risque ;**
- Développer des modèles prédictifs d'IA (réseaux de neurones, forêts aléatoires, etc.);**
- Concevoir un système intégré SIG-IA de cartographie dynamique des zones à risque.**

La méthodologie adoptée repose sur quatre étapes clés :

- **Collecte et analyse de données environnementales, météorologiques et historiques ;**
- **Exploitation des SIG pour la cartographie et l'analyse spatiale ;**
- **Développement de modèles prédictifs en machine learning et deep learning ;**
- **Validation du modèle à l'aide de données réelles et d'indicateurs de performance.**

Cette approche technologique vise à fournir des solutions innovantes pour anticiper les incendies et en réduire les impacts.

Ce mémoire s'articule autour de quatre chapitres structurants. Le premier chapitre pose le cadre général de la recherche en présentant le contexte et la problématique des incendies de forêt, en abordant les facteurs déclencheurs, les impacts, les stratégies de gestion ainsi que les limites des approches classiques. Le deuxième chapitre explore les synergies entre Systèmes d'Information Géographique (SIG), Intelligence Artificielle (IA) et IoT pour la prévision et la gestion intelligente des feux de forêt, en détaillant les méthodes, outils et plateformes mobilisés. Le troisième chapitre est consacré à la méthodologie de développement d'un modèle prédictif des Incendies . Enfin, le quatrième chapitre présente l'implémentation, les tests et l'analyse des résultats obtenus à travers une étude de cas, avant de proposer des perspectives d'amélioration et de déploiement du système développé.

CHAPITRE 1 : CONTEXTE ET PROBLÉMATIQUE DES INCENDIES DE FORÊT

1.1. Introduction

Ce chapitre introduit le sujet des incendies de forêt en mettant en lumière leur importance en tant que phénomène mondial aux conséquences environnementales, économiques et sociales majeures. Il explore l'augmentation de leur fréquence et de leur intensité, largement influencée par le changement climatique et les activités humaines. La problématique est ensuite définie, soulignant les difficultés de prédiction en raison de la complexité des facteurs impliqués, les limites des méthodes traditionnelles de gestion, et la nécessité d'intégrer des technologies avancées comme les SIG et l'IA pour une approche plus efficace et proactive. Ce chapitre pose ainsi les bases pour la recherche en identifiant les enjeux clés et en justifiant l'importance de développer des solutions innovantes.

1.2. Introduction générale aux incendies de forêt

1.2.1. Définition et caractéristiques des incendies de forêt :

Un incendie de forêt est un feu incontrôlé qui se propage dans une zone boisée, brûlant la végétation, les arbres et les écosystèmes environnants. Il peut être d'origine naturelle (par exemple, causé par la foudre) ou humaine (activités agricoles, négligence, ou actes criminels). Ces feux se caractérisent par leur capacité à se propager rapidement, en fonction des conditions météorologiques, du type de végétation et de la topographie du terrain.

1.2.2.1 Types d'incendies de forêt :

Les incendies de forêt peuvent être classés en trois types principaux, en fonction de la partie de l'écosystème qu'ils affectent et de leur mode de propagation :

- **Feux de surface :** Brûlent la litière végétale, les herbes, les buissons et les petits arbustes, Ils se propagent rapidement en surface, mais leur intensité est généralement modérée. Nous pouvons citer comme exemple les feux dans les prairies ou les sous-bois.
- **Feux de cime :** Affectent la canopée des arbres, se propageant de cime en cime, Ces feux sont souvent très intenses et difficiles à contrôler en raison de leur vitesse de

propagation. Nous pouvons citer comme exemple les feux dans les forêts denses ou les zones avec une végétation arborée élevée.

- **Feux souterrains** : Se propagent sous la surface du sol, brûlant les racines, la tourbe et les matières organiques enfouies. Ils sont lents mais peuvent persister pendant des jours, voire des semaines, et sont difficiles à éteindre. Nous pouvons citer comme exemple, les feux dans les zones de tourbières ou les sols riches en matière organique [1] [2].

1.2.1.2 Évolution des incendies :

L'évolution et la propagation des incendies de forêt dépendent de plusieurs facteurs environnementaux clés :

- **Influence des vents** : Les vents forts accélèrent la propagation des incendies en transportant des braises et en alimentant le feu en oxygène. Ils peuvent également changer la direction du feu de manière imprévisible, rendant la lutte contre les incendies plus difficile.
- **Influence de l'humidité** : Une faible humidité assèche la végétation, la rendant plus inflammable et favorisant la propagation rapide du feu, À l'inverse, une humidité élevée ou des précipitations peuvent ralentir ou éteindre un incendie. Les périodes de sécheresse prolongée augmentent considérablement le risque d'incendies.
- **Influence du type de végétation** : Les végétations denses et sèches (comme les broussailles, les herbes sèches ou les forêts de conifères) brûlent plus rapidement et intensément, Les feuillus humides ou les zones avec une végétation moins inflammable peuvent ralentir la propagation. Par exemple, les forêts méditerranéennes, riches en résineux, sont particulièrement vulnérables aux incendies.

1.2.2. Facteurs déclencheurs des incendies de forêt :

Les incendies de forêt peuvent être déclenchés par des facteurs naturels ou anthropiques (liés à l'activité humaine). Voici une analyse détaillée de ces deux catégories [3] [4].:

1.2.2.1. Les facteurs naturels :

Plusieurs éléments naturels peuvent favoriser l'éclosion d'un incendie :

a. Conditions météorologiques extrêmes :

- **Températures élevées** : Elles assèchent la végétation, augmentant son inflammabilité.

- **Vents forts** : Ils accélèrent la propagation des flammes et dispersent les braises sur de longues distances.
- **Sécheresse prolongée** : Elle réduit l'humidité du sol et de la couverture végétale, créant un environnement propice aux feux.
- **Orages secs** : Les éclairs, en l'absence de pluie, sont une source fréquente d'allumage dans les zones isolées.

b. Accumulation de combustibles naturels :

- La présence de débris végétaux, tels que feuilles mortes ou branches sèches, alimente rapidement un feu une fois déclenché.

1.2.2.2. Facteurs anthropiques :

Les activités humaines sont responsables d'une grande partie des départs de feu [5]:

a. Pratiques agricoles :

- Les brûlages de défrichage mal maîtrisés peuvent dégénérer en incendies incontrôlés.

b. Comportements négligents :

- Mégots de cigarette jetés dans la nature.
- Feux de camp non éteints ou mal surveillés.
- Étincelles causées par des outils ou machines en fonctionnement.

c. Actes intentionnels :

- Certains incendies sont criminels, déclenchés volontairement pour des motifs divers (vandalisme, conflits fonciers, etc.).

d. Pression humaine sur les espaces forestiers :

- L'urbanisation croissante à proximité des forêts (interface forêt-ville) augmente les risques d'incendie.
- Les infrastructures humaines (lignes électriques, routes, etc.) peuvent aussi être des sources d'allumage.

1.2.3. Impacts des incendies de forêt :

Les incendies de forêt ont des impacts profonds et multidimensionnels, touchant à la fois l'environnement, l'économie et la société. Voici une analyse détaillée de ces conséquences [6] [7] [8]:

1.2.3.1. Conséquences écologiques :

- **Dégradation de la biodiversité :** Les incendies détruisent les habitats naturels, entraînant la mort d'animaux et la disparition d'espèces végétales. Les écosystèmes mettent des années, voire des décennies, à se rétablir complètement.
- **Augmentation des émissions de CO₂ et impact sur le climat :** Les incendies libèrent d'énormes quantités de dioxyde de carbone (CO₂), contribuant au réchauffement climatique. Ils détruisent également les puits de carbone naturels que sont les forêts, aggravant ainsi l'effet de serre.
- **Érosion des sols et perturbation des cycles hydrologiques :** La végétation brûlée ne retient plus les sols, ce qui augmente l'érosion et les risques de glissements de terrain. Les incendies perturbent les cycles de l'eau en réduisant l'infiltration de l'eau dans le sol et en altérant les bassins versants.

1.2.3.2. Conséquences économiques et sociales :

- **Destruction des infrastructures et habitations :** Les incendies détruisent des maisons, des routes, des lignes électriques et d'autres infrastructures essentielles. Les coûts de reconstruction sont souvent très élevés.
- **Perte de revenus liée à la destruction de forêts exploitées économiquement :** Les forêts exploitées pour le bois, les produits forestiers non ligneux ou d'autres ressources perdent leur valeur économique. Les industries locales dépendantes de ces ressources sont gravement affectées.
- **Impact sur le tourisme et l'économie locale :** Les zones touchées par les incendies deviennent moins attractives pour les touristes, réduisant les revenus liés au tourisme. Les activités récréatives sont perturbées, affectant les entreprises locales.
- **Déplacement des populations affectées :** Les incendies obligent souvent les populations à évacuer leurs maisons, entraînant des déplacements massifs. Les communautés touchées subissent des traumatismes psychologiques et des difficultés socio-économiques.

1.3. Stratégies de gestion des incendies de forêt

1.3.1. Surveillance et détection des incendies :

La surveillance et la détection des incendies de forêt sont des étapes cruciales pour une intervention rapide et efficace. Elles reposent sur des méthodes traditionnelles et des technologies modernes, chacune ayant ses avantages et ses limites. [9] [10]

1.3.1.1. Méthodes traditionnelles :

- **Tours de guet et patrouilles humaines :** Des tours de guet sont installées dans les zones forestières pour permettre aux gardes-forestiers de surveiller visuellement les départs de feu. Des patrouilles terrestres ou aériennes sont également menées pour inspecter les zones à risque,
 - **Avantages :** Simplicité et faible coût technologique,
 - **Limites :** Couverture limitée, dépendance aux conditions météorologiques (visibilité réduite par la fumée ou la nuit).
- **Signalements citoyens via appels d'urgence :** Les habitants ou les touristes peuvent signaler des départs de feu en appelant les services d'urgence,
 - **Avantages :** Réactivité dans les zones fréquentées,
 - **Limites :** Dépend de la présence humaine et peut entraîner des retards dans les zones reculées.

1.3.1.2. Technologies modernes :

- **Surveillance satellitaire (MODIS, VIIRS) :** Les satellites comme MODIS (Moderate Resolution Imaging Spectroradiometer) et VIIRS (Visible Infrared Imaging Radiometer Suite) détectent les points chauds et les fumées à l'échelle mondiale.
 - **Avantages :** Couverture large et détection en temps quasi réel
 - **Limites :** Résolution spatiale limitée, difficulté à détecter les petits feux.
- **Capteurs IoT et réseaux de capteurs sans fil pour détection précoce :** Des capteurs connectés (Internet des Objets) mesurent la température, l'humidité et la présence de fumée, envoyant des alertes en temps réel.
 - **Avantages :** Précision et capacité à couvrir des zones difficiles d'accès,
 - **Limites :** Coût d'installation et maintenance des réseaux de capteurs.
- **Systèmes d'alerte basés sur des caméras et drones :** Des caméras thermiques et des drones équipés de capteurs surveillent les zones à risque et détectent les départs de feu.

- **Avantages :** Flexibilité, capacité à couvrir de vastes zones et à fournir des images haute résolution.
- **Limites :** Coût élevé et dépendance aux conditions météorologiques (vent, pluie).

1.3.2. Prévention des incendies :

La prévention des incendies de forêt est une étape essentielle pour réduire les risques et limiter les dégâts. Elle repose sur des stratégies d'aménagement du territoire, des campagnes de sensibilisation et des réglementations strictes. Voici une analyse détaillée de ces approches :

- **Aménagement du territoire :** Création de pare-feu : Les pare-feu sont des zones dégagées ou traitées pour empêcher la propagation des incendies. Ils peuvent être naturels (rivières, rochers) ou artificiels (zones défrichées). Leur objectif est de rompre la continuité du combustible et ralentir la progression du feu.
- **Réduction de la charge combustible :** Cela implique l'élimination des matériaux inflammables (branches mortes, herbes sèches) par le débroussaillage, le brûlage contrôlé ou le pâturage. L'objectif est de diminuer la quantité de combustible disponible pour alimenter les incendies. [11] [12]
- **Plans de prévention et campagnes de sensibilisation :** Les autorités locales et nationales élaborent des plans de prévention pour identifier les zones à risque et mettre en place des mesures adaptées. L'objectif est d'anticiper les risques et organiser une réponse coordonnée en cas d'incendie.
- **Campagnes de sensibilisation :** Des campagnes éducatives informent le public sur les comportements à risque et les mesures de précaution à adopter. L'objectif est de réduire les départs de feu d'origine humaine (mégots de cigarette, feux de camp, etc.).
- **Interdiction des feux en période à risque :** Pendant les périodes de sécheresse ou de vent fort, les feux de camp, les brûlages de déchets et l'utilisation d'outils générant des étincelles sont interdits. Ceci permet de réduire les départs de feu accidentels.
- **Contrôle des activités humaines :** Des réglementations strictes encadrent les activités susceptibles de provoquer des incendies (travaux forestiers, feux agricoles, etc.). L'objectif est de minimiser les risques liés aux activités humaines.

1.3.3. Intervention et suppression des incendies :

L'intervention et la suppression des incendies de forêt reposent sur une combinaison de moyens terrestres, aériens et technologiques visant à contrôler et éteindre les feux [13] [14].

- **Moyens terrestres :**

- Brigades de pompiers : Intervention directe sur le terrain pour lutter contre les flammes, créer **des pares-feux manuels** et protéger les zones à risque.
- Camions-citernes : Transport d'eau ou de retardant pour éteindre les flammes et refroidir les zones brûlées.
- Bulldozers : Création de pare-feu en dégageant la végétation et creusant des tranchées pour limiter la propagation.

- **Moyens aériens :**

- Avions bombardiers d'eau : Largage de grandes quantités d'eau ou de retardant sur les feux pour ralentir leur progression.
- Hélicoptères : Intervention ciblée dans les zones difficiles d'accès et soutien logistique aux équipes au sol.
- Systèmes fixes et technologies innovantes :
- Systèmes d'extinction automatiques : Sprinklers ou canons à eau déployés dans les zones à haut risque.
- Technologies avancées : Utilisation de drones ou de robots pour intervenir dans des zones dangereuses et réduire les risques humains.

1.4. Modélisation et prévision des incendies de forêt

1.4.1. Importance de la prévision des incendies :

La prévision joue un rôle clé dans la réduction des impacts des incendies et dans l'optimisation des interventions.

- **Anticipation des zones à risque :** Identification des zones vulnérables selon les conditions météorologiques, topographiques et la végétation, permettant la mise en place de mesures préventives.
- **Optimisation des ressources :** Déploiement ciblé des moyens humains et matériels pour une intervention plus efficace et moins coûteuse.
- **Aide à la décision :** Appui en temps réel pour guider les responsables dans la gestion des feux.

1.4.2. Modèles de prévision des incendies :

1.4.2.1. Modèles empiriques et statistiques :

Ces modèles reposent sur l'analyse de données historiques et environnementales pour prédire le risque d'incendie [15] [16].

- **Basés sur les données passées :** Analyse de l'occurrence des incendies, de la météo et de la végétation pour identifier des tendances.
- **Méthodes utilisées :** Modèles de régression (linéaire, logistique) et modèles probabilistes estimant la probabilité d'un incendie selon les conditions actuelles.

1.4.2.2. Modèles physiques et mécanistiques :

Ces modèles simulent la propagation du feu à l'aide de lois physiques et chimiques.

- **Simulation du comportement du feu :** Intégration de la topographie, du vent et du type de combustible pour prédire la dynamique de propagation.
- **Types de modèles :** Modèles thermodynamiques (transfert de chaleur) et modèles de combustion (réactions chimiques impliquées).

1.4.3. Données et indicateurs utilisés pour la prévision des incendies :

La prévision des incendies de forêt repose sur une variété de données et d'indicateurs permettant d'évaluer le risque, de modéliser la propagation du feu et d'optimiser les stratégies de réponse. Ces données se répartissent en plusieurs catégories essentielles [17] [18] [19] :

1.4.3.1. Données météorologiques

Les conditions météorologiques influencent directement le comportement du feu. Les principales variables utilisées sont :

- **Température de l'air (°C) :** Des températures élevées assèchent la végétation, augmentant son inflammabilité.
- **Humidité relative (%) :** Une humidité faible favorise la sécheresse des combustibles.
- **Vitesse et direction du vent (m/s) :** Le vent alimente le feu et peut transporter des braises.
- **Précipitations (mm) :** Elles réduisent le risque en humidifiant le sol et la végétation.

- **Pression atmosphérique (hPa)** : Elle influence les phénomènes météorologiques locaux.

1.4.3.2. Données sur la végétation et les combustibles

Ces données permettent d'évaluer la disponibilité et l'inflammabilité du combustible :

- **Type de végétation** : Certaines espèces, comme les conifères, sont plus inflammables.
- **Fuel Moisture Content (FMC)** : Mesure de l'humidité dans les combustibles végétaux.
- **Charge en combustible (t/ha)** : Quantité de matière inflammable disponible.

1.4.3.3. Données topographiques

La topographie influence fortement la propagation du feu :

- **Altitude (m)** : Impacte la température et l'humidité.
- **Pente (%)** : Une pente accentue la vitesse de propagation vers le sommet.
- **Orientation du terrain (aspect)** : Les versants sud, plus exposés au soleil, sont généralement plus secs.

1.4.3.4. Données historiques sur les incendies

L'historique des feux est un indicateur important des zones à risque :

- **Localisation et fréquence des feux** : Identifie les zones sensibles.
- **Surface brûlée (ha)** : Donne une idée de l'intensité passée.
- **Durée des incendies** : Évalue la difficulté d'intervention.

1.4.3.5. Données anthropiques et infrastructures

Les facteurs humains jouent un rôle déterminant dans le déclenchement des feux :

- **Densité de population (hab/km²)** : Corrélée à un risque accru d'ignition.
- **Proximité des routes et infrastructures** : Risques liés aux véhicules et équipements.
- **Nombre de départs de feux d'origine humaine** : Incidents liés à des causes volontaires ou accidentelles.
- **Présence de lignes électriques** : Source fréquente d'étincelles en cas de défaut.

1.4.3.6. Données de surveillance en temps réel

Les technologies actuelles permettent une détection et une intervention rapide :

- **Détection thermique** : Identification de points chauds.
- **Imagerie satellitaire multispectrale** : Suivi à grande échelle.
- **Caméras de surveillance** : Détection visuelle des fumées.
- **Capteurs IoT** : Mesurent température, humidité, fumée, CO₂.
- **Drones et aéronefs** : Surveillance aérienne des zones difficiles d'accès.

Tableau 1: Données utilisées pour l'évaluation et la prédiction des incendies de forêt

Catégorie	Donnée	Description / Rôle	Unité / Type
Données météorologiques	Température de l'air	Influence l'assèchement de la végétation	°C
	Humidité relative	Faible humidité favorise la sécheresse des combustibles	%
	Vitesse et direction du vent	Accélère la propagation et transporte les braises	m/s, °
	Précipitations	Réduit le risque en humidifiant la végétation	mm
	Pression atmosphérique	Impacte les phénomènes météo locaux	hPa
Données sur la végétation et les combustibles	Type de végétation	Certaines essences sont plus inflammables	Qualitatif (catégories)
	Fuel Moisture Content (FMC)	Taux d'humidité dans la matière végétale	%
	Charge en combustible	Quantité de biomasse disponible pour brûler	t/ha
Données topographiques	Altitude	Impact sur température et humidité	m
	Pente	Influence la vitesse de propagation	%
	Orientation du terrain (aspect)	Détermine l'exposition au soleil (influence l'assèchement)	Degrés / orientation

Données historiques sur les incendies	Localisation et fréquence des feux	Identifie les zones récurrentes de feux	Coordonnées / Nb/an
	Surface brûlée	Indicateur de gravité	ha
	Durée des incendies	Mesure de la difficulté d'extinction	Heures / jours
Données anthropiques et infrastructures	Densité de population	Corrélée au risque d'ignition	Hab/km ²
	Proximité des routes et infrastructures	Risques accrus à proximité des routes, chemins, infrastructures humaines	m / réseau linéaire
	Nombre de départs de feux humains	Sources volontaires ou accidentelles	Nb/an
	Présence de lignes électriques	Sources d'étincelles en cas de défaillance	Présence / absence
Données de surveillance en temps réel	Détection thermique	Identification de foyers actifs par capteurs IR	Images / température
	Imagerie satellitaire multispectrale	Suivi de l'évolution des foyers sur de larges zones	Image multispectrale
	Caméras de surveillance	Observation visuelle pour détection précoce	Vidéo
	Capteurs IoT	Mesure locale des conditions : température, humidité, fumée, CO ₂	Données capteurs
	Drones et aéronefs	Surveillance aérienne des zones inaccessibles	Vidéo / Image thermique

1.4.3.7. Indicateurs et indices de risque d'incendie

Les indices et indicateurs permettent d'évaluer le danger potentiel d'incendie, la propagation possible, et les facteurs aggravants liés à la météo, à la végétation, à l'environnement ou à l'activité humaine. Le tableau suivant regroupe l'ensemble des principaux indicateurs utilisés dans les systèmes de prévision et de gestion des incendies de forêt.

Tableau 2 : Récapitulatif des indicateurs et indices de risque d'incendie

Catégorie	Indice / Indicateur	Description
Météorologie et propagation du feu	FWI (Fire Weather Index)	Indice global du danger basé sur météo (température, humidité, vent, pluie) ; combine plusieurs sous-indices.
	FFMC (Fine Fuel Moisture Code)	Humidité des combustibles légers (ex. feuilles) ; plus il est faible, plus le risque d'ignition est élevé.
	DMC (Duff Moisture Code)	Humidité des couches moyennes du sol (humus) ; indique le niveau de sécheresse intermédiaire.
	DC (Drought Code)	Sécheresse profonde du sol ; un DC élevé signale un risque d'incendie intense.
	ISI (Initial Spread Index)	Vitesse initiale de propagation du feu selon vent et sécheresse.
	BUI (Buildup Index)	Quantité totale de combustible disponible (combine DMC et DC).
2. Sécheresse et stress hydrique	KBDI (Keetch-Byram Drought Index)	Mesure de la sécheresse du sol ; plus il est élevé, plus le risque est fort.
	SPI (Standardized Precipitation Index)	Évalue les déficits hydriques à court et long terme (sécheresses).
Végétation et combustible	NDVI (Normalized Difference Vegetation Index)	Indice de santé de la végétation ; un NDVI bas indique un stress hydrique élevé.
	FMC (Fuel Moisture Content)	Teneur en humidité des combustibles (herbe, broussailles, bois mort) ; faible FMC = forte inflammabilité.
Topographie et environnement	Pente du terrain	Une pente accentue la vitesse de propagation du feu vers le sommet.
	Orientation (aspect)	Influence l'exposition solaire ; les versants sud sont souvent plus secs.
Activités humaines et historique	Densité de population	Corrélée à une probabilité plus élevée de départ de feu d'origine humaine.
	Proximité des routes/infrastructures	Risques associés aux activités humaines (véhicules, feux, étincelles, etc.).

	Nombre de feux précédents	Donne un aperçu des zones historiquement à risque ou récurrentes.
--	----------------------------------	---

1.5. Systèmes de gestion et de prévision des incendies de forêt

Plusieurs systèmes de gestion et de prévision des incendies de forêt ont été développés à travers le monde pour faire face aux risques croissants d'incendies liés au changement climatique et aux pressions anthropiques. Ces systèmes ont pour objectif d'anticiper les feux, d'en surveiller l'évolution et de soutenir les interventions. Cette section présente les principaux systèmes internationaux – EFFIS, NFDRS, CFFDRS et AFDRS – en détaillant leurs composants, indicateurs clés, et en les comparant selon des critères techniques.

1.5.1. European Forest Fire Information System (EFFIS) – Europe [20] [21]

EFFIS est un système européen centralisé dédié à la surveillance, la prévision et la gestion des incendies de forêt. Il fournit aux autorités locales et aux décideurs des outils pour évaluer les risques, détecter les départs de feu et coordonner les réponses à l'échelle du continent. Ses fonctionnalités principales sont :

- **Évaluation du danger** : basée sur des indices météorologiques comme le *Fire Weather Index* (FWI), qui combine température, humidité, vent et précipitations.
- **Surveillance active des feux** : grâce aux satellites (MODIS, Sentinel-2) et à des capteurs au sol pour la détection en temps réel.
- **Prévision de la propagation** : via la modélisation de l'évolution des incendies selon le vent, la topographie et le type de combustible.
- **Support à la décision** : aide à la mobilisation des ressources (équipes, moyens aériens) et à l'évaluation post-incendie des dommages environnementaux et économiques.

1.5.2. National Fire Danger Rating System (NFDRS) – États-Unis

Le NFDRS est le système officiel des États-Unis pour évaluer le danger d'incendie à différentes échelles (locale, régionale, nationale). Il repose sur une collecte fine de données météorologiques et environnementales pour modéliser les risques et appuyer la planification opérationnelle. Ses fonctionnalités principales sont :

- **Suivi du risque d'incendie** : à partir d'indicateurs météorologiques et d'humidité des combustibles.
- **Simulation du comportement du feu** : modélisation de la propagation selon le terrain et le climat.
- **Gestion des ressources** : appui à la répartition stratégique des équipes et des équipements de lutte.

1.5.3. Canadian Forest Fire Danger Rating System (CFFDRS) – Canada [22]

Le CFFDRS est spécialement conçu pour les forêts boréales canadiennes. Il combine des indices météorologiques et d'humidité des combustibles pour estimer le niveau de danger et prédire la dynamique du feu. Ses fonctionnalités principales sont :

- **Évaluation du danger** : via le *Fire Weather Index* (FWI) et des codes d'humidité (FFMC, DMC, DC).
- **Prévision du comportement** : grâce au *Fire Behavior Prediction System* (FBP), qui simule la propagation selon le vent, la pente et le type de combustible.
- **Adaptabilité** : système modulaire adapté aux caractéristiques écologiques locales.

1.5.4. Australian Fire Danger Rating System (AFDRS) – Australie [23] [24] [25]

L'AFDRS est un système moderne et intégré, conçu pour faire face aux incendies fréquents en Australie, notamment dans un contexte de conditions extrêmes. Il s'appuie sur des technologies avancées pour fournir des alertes précises à l'échelle locale. Ses fonctionnalités principales sont :

- **Prédiction des conditions favorables** : avec des indices comme le *Forest Fire Danger Index* (FFDI) et le *Grass Fire Danger Index* (GFDI).
- **Simulation de la propagation** : via des modèles prenant en compte les données climatiques et de végétation.
- **Évaluation de l'impact** : environnemental, humain et économique après les incendies.

1.5.5. Comparaison des systèmes

Afin de mieux comprendre les spécificités, les points forts et les limites des principaux systèmes internationaux de gestion des incendies de forêt, cette section propose une double comparaison. La première porte sur des critères globaux de fonctionnement tels que l'échelle, la précision ou les technologies employées. La seconde se concentre sur les modules intégrés dans chaque système ainsi que sur les indicateurs utilisés pour l'évaluation du risque et le suivi des feux.

Le tableau suivant met en parallèle les quatre principaux systèmes (EFFIS, NFDRS, CFFDRS et AFDRS) selon des critères d'analyse objectifs, notamment leur portée géographique, leur précision opérationnelle, les indicateurs météorologiques employés, la prise en compte de la végétation, les technologies utilisées, ainsi que les limites identifiées dans leur fonctionnement. Cette vue d'ensemble permet de souligner les spécificités de chaque système dans son contexte géographique et institutionnel. [26] [27] [28]

Tableau 3 : Comparaison des systèmes de gestion des incendies de forêt.

Critères	EFFIS (Europe)	NFDRS (USA)	CFFDRS (Canada)	AFDRS (Australie)
Échelle	Continentale	Nationale	Nationale	Nationale
Précision	Moyenne	Bonne	Très bonne	Excellente
Indicateurs météo	FWI, FPMC, DC	ERC, BI, SC	FFMC, DMC, DC	FFDI, GFDI, KBDI
Végétation prise en compte	Oui	Oui	Oui	Oui
Technologies utilisées	Satellites	Stations météo	Satellites + stations	Satellites, IoT, drones
Limites	Résolution moyenne	Dépendance capteurs météo	Complexité du modèle	Sensibilité aux aléas climatiques

Le tableau ci-dessous dresse une analyse comparative plus technique, en listant pour chaque système les modules logiciels ou fonctionnels qu'il intègre ainsi que les indicateurs qu'il mobilise pour modéliser, surveiller et anticiper les incendies. Cette comparaison met en lumière les approches choisies (empiriques, satellitaires, IA, etc.), ainsi que les niveaux de complexité et d'intégration dans la chaîne de gestion du risque.

Les critères de comparaison concernent plusieurs aspects essentiels. L'échelle d'application varie : EFFIS couvre l'ensemble de l'Europe, tandis que NFDRS (USA), CFFDRS (Canada) et AFDRS (Australie) sont conçus à l'échelle nationale, mieux adaptés aux contextes locaux. En termes de précision, EFFIS présente une précision moyenne en raison de la diversité climatique européenne, alors que NFDRS bénéficie d'un réseau dense de stations météo. CFFDRS affiche une très bonne précision grâce à l'intégration de modèles complexes, et AFDRS se distingue par une précision excellente grâce à l'usage de technologies avancées comme l'IoT et les drones. Chaque système mobilise des indicateurs météorologiques spécifiques (FWI, FFMC, FFDI, etc.) pour évaluer le risque d'incendie. Tous prennent en compte la végétation, élément déterminant dans la propagation du feu. Enfin, les technologies utilisées varient : satellites pour EFFIS et CFFDRS, stations météo pour NFDRS, et technologies combinées pour AFDRS. Chaque système présente également des limites propres, comme la résolution spatiale moyenne d'EFFIS ou la complexité du modèle canadien. [29]

Tableau 4 : Tableau comparatif des modules intégrés et des indicateurs utilisés

Système	Modules intégrés	Indicateurs utilisés
EFFIS (Europe)	▪ Module d'évaluation du danger ▪ Module de surveillance active (détection par satellite) ▪ Module de cartographie des zones brûlées ▪ Module d'évaluation de l'impact post-incendie	▪ FWI (Fire Weather Index) ▪ DC (Drought Code) ▪ DMC (Duff Moisture Code) ▪ FFMC (Fine Fuel Moisture Code) ▪ Images MODIS, Sentinel-2 ▪ VCI (Vegetation Condition Index)
NFDRS (USA)	▪ Module d'estimation de l'humidité des combustibles ▪ Module de calcul des indices de danger ▪ Module d'intégration météo (RAWS) ▪ Module d'aide à la décision opérationnelle	▪ ERC (Energy Release Component) ▪ BI (Burning Index) ▪ SC (Spread Component) ▪ Température, humidité relative, vent
CFFDRS (Canada)	▪ Système FWI (indices météo et humidité) ▪ Modules FFMC, DMC, DC (humidité des combustibles) ▪ Système FBP (prédiction du comportement du feu) ▪ Module de prévision de l'occurrence des feux	▪ FWI, FFMC, DMC, DC ▪ ISI (Initial Spread Index) ▪ BUI (Build-Up Index) ▪ Topographie, type de combustibles

AFDRS (Australie)	▪ Module de modélisation du comportement du feu (par type de végétation) ▪ Module de prévision du danger (conditions météo locales) ▪ Module d'intégration de l'imagerie satellite ▪ Module de communication du risque (alertes publiques)	▪ FFDI (Forest Fire Danger Index) ▪ GFDI (Grassland Fire Danger Index) ▪ Température, vent, humidité ▪ Données satellites, IA
-----------------------------	---	--

Les critères de comparaison concernent plusieurs aspects essentiels. L'échelle d'application varie : EFFIS couvre l'ensemble de l'Europe, tandis que NFDRS (USA), CFFDRS (Canada) et AFDRS (Australie) sont conçus à l'échelle nationale, mieux adaptés aux contextes locaux. En termes de précision, EFFIS présente une précision moyenne en raison de la diversité climatique européenne, alors que NFDRS bénéficie d'un réseau dense de stations météo. CFFDRS affiche une très bonne précision grâce à l'intégration de modèles complexes, et AFDRS se distingue par une précision excellente grâce à l'usage de technologies avancées comme l'IoT et les drones. Chaque système mobilise des indicateurs météorologiques spécifiques (FWI, FFMC, FFDI, etc.) pour évaluer le risque d'incendie. Tous prennent en compte la végétation, élément déterminant dans la propagation du feu. Enfin, les technologies utilisées varient : satellites pour EFFIS et CFFDRS, stations météo pour NFDRS, et technologies combinées pour AFDRS. Chaque système présente également des limites propres, comme la résolution spatiale moyenne d'EFFIS ou la complexité du modèle canadien. [29]

1.6. Limites des approches traditionnelles et justification d'une nouvelle approche

1.6.1. Contraintes des méthodes classiques :

Les méthodes traditionnelles de prévision et de gestion des incendies de forêt présentent plusieurs limites qui réduisent leur efficacité. Voici les principales contraintes :

- **Manque de précision des modèles prédictifs actuels :** Les modèles traditionnels reposent souvent sur des données limitées ou des hypothèses simplifiées, ce qui réduit leur capacité à prédire avec précision les risques d'incendie. Des prévisions imprécises peuvent entraîner une mauvaise allocation des ressources ou des alertes tardives.
- **Difficulté d'adaptation aux particularités locales :** Les modèles généraux ne tiennent pas toujours compte des spécificités locales, comme les microclimats, les types de végétation

uniques ou les activités humaines spécifiques à une région. Une mauvaise adaptation aux conditions locales peut entraîner des prévisions erronées ou des mesures de prévention inefficaces.

- **Temps de réaction parfois insuffisant pour éviter la propagation :** Les méthodes traditionnelles de détection (tours de guet, patrouilles) peuvent entraîner des retards dans l'identification des départs de feu. Un temps de réaction lent permet au feu de se propager rapidement, rendant son contrôle plus difficile et coûteux. [30] [31]

1.6.2. Nécessité d'intégrer des approches innovantes :

Pour dépasser les limites des méthodes traditionnelles, il est indispensable d'adopter des approches innovantes, en particulier en combinant les Systèmes d'Information Géographique (SIG) et l'Intelligence Artificielle (IA). Ces technologies apportent des contributions majeures dans la gestion et la prévention des incendies :

- Les SIG offrent une cartographie fine et dynamique des zones à risque en permettant de visualiser et d'analyser des données spatiales complexes telles que la topographie, la couverture végétale ou la proximité des infrastructures. Grâce à leur capacité à intégrer des données multidimensionnelles, ils facilitent une lecture précise de l'environnement et produisent des cartes interactives utiles pour la prise de décision stratégique. [32]
- L'Intelligence Artificielle, quant à elle, permet de traiter de vastes ensembles de données météorologiques, historiques ou satellitaires afin de prédire avec une grande précision l'occurrence et la propagation potentielle des incendies. Les techniques d'apprentissage automatique permettent une détection précoce des risques, s'adaptent à l'évolution des données et assurent une surveillance continue avec génération d'alertes en temps réel. [33]

1.7. Problématique et objectifs de la recherche

La recrudescence des incendies de forêt met en évidence les limites des approches traditionnelles de prévention et de gestion, souvent peu réactives et faiblement adaptées aux dynamiques spatiales des territoires. Cette recherche vise à explorer comment l'intégration de l'intelligence artificielle et des données spatiales peut améliorer significativement la prévision du risque.

En combinant des techniques d'apprentissage automatique avec des données **spatiales**, l'objectif est de développer un modèle prédictif capable d'anticiper les foyers d'incendie de manière fine. Pour cela, il s'agira d'abord d'analyser les faiblesses des systèmes existants, puis d'identifier et structurer les variables les plus pertinentes à la modélisation du risque. Des

algorithmes tels que les réseaux de neurones ou les forêts aléatoires seront expérimentés pour optimiser la capacité prédictive du système. Enfin, les résultats de l'IA seront exploités pour produire des cartes dynamiques du risque, facilitant ainsi l'aide à la décision pour les acteurs de terrain. [34] [35]

1.8. Conclusion

Ce premier chapitre a permis de dresser un état des lieux complet des incendies de forêt, en mettant en avant leur importance en tant que phénomène mondial aux conséquences multiples. Nous avons exploré les causes naturelles et anthropiques de ces incendies, ainsi que leurs impacts écologiques, économiques et sociaux. Les méthodes traditionnelles de prévention et de gestion, bien que utiles, montrent leurs limites en termes de précision, d'adaptabilité et de réactivité.

Face à ces défis, l'intégration des Systèmes d'Information Géographique (SIG) et de l'Intelligence Artificielle (IA) apparaît comme une solution prometteuse pour améliorer la prévision et la gestion des incendies. Ces technologies permettent une analyse plus précise des données, une détection précoce et une cartographie dynamique des zones à risque.

Les chapitres suivants approfondiront ces aspects en détaillant la méthodologie, les résultats et les implications de cette recherche, avec pour ambition de proposer des solutions concrètes et innovantes pour relever les défis posés par les incendies de forêt. [36] [37]

CHAPITRE 2 : Intelligence Artificielle et Systèmes d'Information Géographique (SIG) pour la Prévision et la Gestion des Feux de Forêt

2.1. Introduction :

Ce chapitre explore le rôle crucial des Systèmes d'Information Géographique (SIG) et de l'Intelligence Artificielle (IA) dans la gestion des incendies de forêt. Alors que les systèmes traditionnels montrent leurs limites face à la complexité et à l'ampleur croissante des feux, les technologies innovantes offrent des solutions plus efficaces pour anticiper, prévenir et gérer ces catastrophes.

Les SIG permettent une cartographie précise des zones à risque, en intégrant des données spatiales (topographie, végétation, infrastructures).

L'IA, grâce à des techniques comme le machine learning, analyse de vastes ensembles de données pour prédire les risques d'incendie et optimiser les interventions.

Le chapitre précédent a mis en lumière les limites des systèmes de gestion traditionnels, tels que leur manque de précision et leur difficulté à s'adapter aux particularités locales. Ce chapitre montre comment les SIG et l'IA comblent ces lacunes en offrant des solutions plus intelligentes et adaptatives.

Comprendre comment les SIG et l'IA améliorent la prévision et la gestion des incendies.

Explorer les applications concrètes de ces technologies dans la surveillance, la détection et la lutte contre les feux de forêt. Identifier les avantages et les défis liés à l'intégration de ces outils innovants [38] [39] [40]

2.2. Systèmes d'Information Géographique (SIG) pour la Gestion des Feux de Forêt

2.2.1. Définition et rôle des SIG :

Les Systèmes d'Information Géographique (SIG) sont des outils informatiques permettant de collecter, stocker, analyser et visualiser des données spatiales. Ils sont utilisés pour évaluer les risques environnementaux, notamment les incendies de forêt, en combinant

des données géographiques, météorologiques et topographiques. La cartographie dynamique générée par les SIG, permet de visualiser en temps réel l'évolution des incendies et des zones à risque. Elle facilite la prise de décision rapide et l'allocation des ressources pour la lutte contre les feux. [41] [42]

2.2.2. Sources de données SIG utilisées pour la gestion des feux :

La gestion des feux de forêt repose sur diverses sources de données géospatiales. Les données satellitaires jouent un rôle central, avec MODIS pour la détection des points chauds et des fumées, Sentinel-2 pour l'imagerie haute résolution de la végétation, et Landsat pour le suivi historique et actuel des changements de couverture terrestre. À cela s'ajoutent les données météorologiques (température, humidité, précipitations, vent), indispensables à la prévision du comportement des incendies. Les données topographiques, telles que la pente, l'altitude, la nature du sol et le type de végétation, permettent de modéliser la propagation du feu. Enfin, les capteurs IoT, déployés sur le terrain, fournissent en temps réel des mesures de température et d'humidité, renforçant la surveillance continue des zones à risque. [43] [44] [45]

2.2.3. Indicateurs géospatiaux pour la gestion des incendies :

La gestion efficace des incendies de forêt s'appuie sur plusieurs indicateurs géospatiaux clés. Les indices de sécheresse, tels que le KBDI (Keetch-Byram Drought Index), permettent d'évaluer le niveau de sécheresse du sol, tandis que le FWI (Fire Weather Index) estime le danger d'incendie en fonction des conditions météorologiques. Du côté de la végétation, l'indice NDVI (Normalized Difference Vegetation Index) renseigne sur l'état de santé de la couverture végétale et son potentiel inflammable. Pour estimer la quantité de matériaux combustibles, le BUI (Build-Up Index) est utilisé. Enfin, l'analyse de l'accessibilité via les SIG permet de calculer les temps d'intervention des secours, contribuant ainsi à l'optimisation des stratégies de lutte contre les incendies. [46] [47]

2.2.4. Plateformes SIG pour la gestion des incendies :

Plusieurs outils SIG avancés sont utilisés pour la gestion des feux de forêt. ArcGIS, avec son extension Spatial Analyst, permet de réaliser des analyses spatiales complexes, tandis que les Fire Incident Mapping Tools facilitent la cartographie et le suivi des incendies. De son côté, QGIS propose une gamme de plugins spécialisés dédiés à l'évaluation du risque d'incendie et à la modélisation spatiale. L'intégration des SIG avec des bases de données spatiales comme PostGIS permet de stocker, interroger et analyser efficacement de grandes quantités de données

géographiques. Enfin, Google Earth Engine constitue une plateforme cloud puissante pour le traitement à grande échelle des données satellitaires, particulièrement utile pour la surveillance environnementale continue. [48] [49]

2.3. Intelligence Artificielle pour la Détection et la Prévion des Feux de Forêt

2.3.1. Apports de l'IA dans la gestion des incendies :

L'intelligence artificielle (IA) joue un rôle essentiel dans la détection précoce des départs de feux, en analysant en temps réel les données satellitaires, les images thermiques et les informations provenant des capteurs IoT. Elle permet également la prédiction de la propagation des incendies en fonction des conditions climatiques telles que le vent, la température et l'humidité, à travers des modèles de simulation avancés. Enfin, l'IA contribue à l'optimisation des stratégies d'intervention, en proposant des plans d'action adaptés aux ressources disponibles et aux caractéristiques du terrain, améliorant ainsi la rapidité et l'efficacité de la réponse opérationnelle. [50]

2.3.2. Modèles de Machine Learning pour la prévision des incendies

L'intensification des feux de forêt, alimentée par le changement climatique, la sécheresse et la pression anthropique, rend impératif le recours à des approches d'intelligence artificielle avancées. Le Machine Learning (ML), en particulier, permet de traiter d'importants volumes de données hétérogènes (images satellites, données météorologiques, topographiques, capteurs IoT, etc.) pour **prédire, détecter et modéliser les incendies de forêt** avec un haut degré de précision et d'adaptabilité.

3.3.2.1. Modèles classiques supervisés

Les modèles supervisés reposent sur l'apprentissage à partir de données étiquetées pour identifier des patterns de déclenchement ou de propagation d'incendies.

- **Random Forest (RF)** : Ce modèle d'ensemble est utilisé pour classifier les zones à risque en apprenant des règles de décision à partir de multiples variables environnementales : humidité relative, température, vitesse du vent, type de couverture végétale, indice de sécheresse (FWI, KBDI), altitude, pente, etc. Il permet de générer une cartographie de la susceptibilité au feu à différentes échelles spatiales. Sa capacité

à mesurer l'importance des variables le rend particulièrement utile pour interpréter les facteurs dominants des incendies dans une région donnée.

- **Decision Trees (DT)** : Bien que moins robustes que RF, ils permettent une compréhension transparente du processus décisionnel, utile dans un cadre opérationnel. Ils sont souvent utilisés comme base pour des systèmes de recommandation en matière de prévention et d'évacuation.
- **Support Vector Machines (SVM)** : Très performants pour les tâches de classification binaire, notamment pour la détection des points chauds (hotspots) dans des images thermiques ou multispectrales. Les SVM permettent de différencier les zones actives des zones inertes sur la base de signatures spectrales, même avec un faible nombre d'exemples d'entraînement, ce qui est fréquent pour les événements rares comme les départs de feu.
- **Gradient Boosting Machines (GBM)** : Des implémentations comme XGBoost, LightGBM ou CatBoost offrent des performances élevées sur des données tabulaires issues de multiples sources (satellites, stations météo, topographie). Elles sont utilisées pour prédire l'occurrence, la durée et l'intensité des feux, en intégrant les effets combinés de plusieurs variables et leurs interactions non linéaires. Ces modèles sont également utilisés dans les tableaux de bord prédictifs temps réel.

2.3.2.2. Modèles profonds (Deep Learning) pour la prévision et la propagation des feux

Le Deep Learning permet d'intégrer des données plus complexes telles que des images multidimensionnelles, des séries temporelles multi-sources, ou encore des cartes raster en haute résolution.

- **Convolutional Neural Networks (CNN)** : Les CNN sont utilisés pour analyser des images satellites optiques et thermiques (MODIS, Sentinel-2, Landsat) dans le but de détecter des anomalies thermiques, des panaches de fumée ou des zones de combustion active. Ces modèles sont capables d'apprendre automatiquement des caractéristiques spatiales comme les formes, textures et gradients liés aux feux. Ils sont utilisés aussi bien pour la détection initiale que pour le suivi de la progression des incendies à travers des séries temporelles d'images.

- **Recurrent Neural Networks (RNN), LSTM et GRU** : Les modèles RNN, notamment les Long Short-Term Memory (LSTM) et Gated Recurrent Unit (GRU), sont employés pour modéliser les dynamiques temporelles des variables climatiques (température, précipitations, vitesse du vent, humidité) afin de prévoir les périodes à risque accru. Leur capacité à capturer les dépendances à long terme dans les séries temporelles les rend utiles pour anticiper les conditions propices à l'éclosion ou à l'extension des incendies.
- **Transformers appliqués aux séries temporelles** : Initialement développés pour le NLP, les modèles Transformer sont aujourd'hui adaptés aux données environnementales via des architectures comme Informer ou Temporal Fusion Transformer (TFT). Ils surpassent souvent les RNN pour les prédictions de longues séquences, en intégrant efficacement l'attention temporelle et contextuelle. Ils peuvent modéliser des phénomènes complexes comme les interactions entre météo, végétation et stress hydrique dans l'évolution d'un incendie.

2.3.2.3. Modèles génératifs et apprentissage par renforcement

Ces modèles avancés visent à **simuler des scénarios** ou à **optimiser des décisions stratégiques** dans des contextes dynamiques et incertains. [51] [52] [53]

- **Generative Adversarial Networks (GANs)** : Les GANs sont utilisés pour générer des scénarios synthétiques réalistes de propagation du feu, en apprenant à partir de données historiques. Ils peuvent modéliser des cas extrêmes, prédire l'expansion d'un feu selon différents vents ou humidités, et alimenter les systèmes de formation des équipes d'intervention. Par exemple, un GAN peut générer une carte de progression plausible d'un feu à l'échelle d'une journée à partir d'une image initiale et des prévisions météorologiques.
- **Deep Reinforcement Learning (DRL)** : Cette approche apprend des stratégies optimales à travers des environnements simulés. Des agents intelligents sont entraînés à choisir les meilleures actions (allocation de ressources, déclenchement d'évacuation, déploiement d'avions-citernes ou de camions-pompes) en fonction d'un état du système (propagation du feu, accès routier, disponibilité des moyens). Les algorithmes comme Deep Q-Networks (DQN) ou Proximal Policy Optimization (PPO) permettent d'améliorer les temps de réponse et réduire les pertes humaines, matérielles et écologiques dans un contexte dynamique.

2.4. Comparaison des Modèles et Approches Utilisés

Les modèles et approches utilisés pour la gestion des incendies de forêt varient en fonction de leurs caractéristiques, avantages et inconvénients. Les modèles supervisés, comme le Random Forest, offrent une bonne interprétabilité et sont efficaces pour la classification des zones à risque, bien qu'ils soient moins précis que les modèles de deep learning. Les algorithmes de XGBoost et LightGBM se distinguent par leur haute précision dans l'analyse des facteurs de risque, mais ils sont sensibles aux valeurs aberrantes. Les Support Vector Machines (SVM) sont performants pour les petits jeux de données, notamment pour la détection d'incendies dans les images satellitaires, mais leur efficacité diminue avec des volumes de données plus importants.

Les modèles de deep learning apportent des solutions plus avancées. Les Réseaux de Neurones Convolutionnels (CNN) sont très efficaces pour la reconnaissance d'images, ce qui les rend idéaux pour la détection des feux par imagerie satellite, bien qu'ils soient gourmands en données et en calcul. Les Réseaux de Neurones Récurents (LSTM) excellent dans la gestion des séries temporelles, ce qui est utile pour prédire l'évolution des incendies, mais leur temps d'apprentissage est long. Les Transformers capturent mieux les tendances climatiques, mais ils nécessitent des ressources importantes. Les GANs (Generative Adversarial Networks) permettent de générer des scénarios réalistes pour simuler la propagation du feu, bien que leur entraînement soit complexe.

L'Apprentissage par Renforcement (DRL) est utilisé pour optimiser dynamiquement les stratégies d'intervention, mais il nécessite de nombreuses simulations pour être efficace. Enfin, les approches hybrides comme la Logique Floue sont utiles pour gérer l'incertitude dans la modélisation du risque d'incendie, bien qu'elles soient moins précises que les modèles de deep learning. [54] [55] [56] [57] [58]

Le tableau suivant présente une synthèse comparative des principales approches utilisées, depuis les algorithmes classiques supervisés jusqu'aux techniques avancées de deep learning, de modélisation générative et d'apprentissage par renforcement. Cette comparaison permet d'identifier les forces et limites spécifiques de chaque méthode, afin de guider le choix du modèle le plus adapté aux besoins opérationnels et aux contraintes des systèmes de gestion des feux.

Tableau 5 : comparatif des modèles de ML/DL pour la gestion des incendies de forêt

Modèle	Applications principales	Types de données	Avantages	Limites
Decision Tree	Classification de zones à risque	Données tabulaires environnementales	Simple, interprétable, rapide	Overfitting, performance limitée
Random Forest (RF)	Cartographie du risque, déclenchement	Météo, topographie, indices végétation	Robuste, moins de surapprentissage	Moins précis que DL, mémoire élevée
SVM	Détection dans images satellitaires	Images spectrales/satellites	Efficace pour petits jeux de données	Peu scalable, sensible au tuning
XGBoost / LightGBM	Prédiction d'occurrence d'incendie	Données environnementales variées	Précis, rapide, bien optimisé	Sensible aux valeurs aberrantes
CNN	Détection / suivi via images	Imagerie satellite, thermique	Très performant en reconnaissance d'images	Besoin de grandes bases annotées
LSTM / GRU	Prévision météo et de risque	Séries temporelles climatiques	Capture les dépendances temporelles	Lent à entraîner, sensible aux séquences longues
Transformers (TFT, Informer)	Prédiction météo & risques évolutifs	Séries enrichies (climat + spatial)	Très puissant sur les séries complexes	Coûteux en ressources, tuning délicat
GANs	Simulation propagation des feux	Images + cartes historiques	Génération de scénarios réalistes	Entraînement instable, validation difficile
Deep RL	Optimisation des interventions	État dynamique du terrain, ressources	Décision intelligente en environnement dynamique	Très complexe, besoin de nombreuses simulations

En pratique, des combinaisons hybrides (ex. CNN + LSTM ou XGBoost + logique floue) sont souvent les plus efficaces dans un système intégré de gestion des incendies de forêt, notamment en contexte SIG. [59] [60] [61]

2.5. Intégration des Systèmes d'Information Géographique et de l'Intelligence Artificielle pour une Gestion Intelligente des Incendies

L'intégration des Systèmes d'Information Géographique (SIG) et de l'Intelligence Artificielle (IA) constitue aujourd'hui un levier majeur pour améliorer la gestion des incendies de forêt. En combinant la puissance analytique des SIG avec les capacités prédictives et adaptatives de l'IA, il est possible de mettre en place des systèmes hybrides offrant une surveillance en temps réel, une prévision fine des risques et une optimisation des interventions. Cette synergie permet non seulement d'améliorer la précision des cartographies de risque, mais aussi de rendre les systèmes d'alerte plus réactifs et intelligents, tout en facilitant la prise de décision dans des contextes complexes et évolutifs. [62] [63] [64]

2.5.1. Systèmes hybrides combinant SIG et IA

Les technologies IoT jouent un rôle crucial en fournissant des données environnementales en temps réel via des capteurs installés en forêt, mesurant des paramètres tels que la température, l'humidité, la concentration de fumée ou encore la vitesse du vent. Ces données sont ensuite intégrées dans des plateformes SIG où l'IA intervient pour traiter et analyser en continu les informations. Cette combinaison permet une mise à jour dynamique et automatisée des cartes de risque d'incendie, en tenant compte des évolutions rapides des conditions locales. Par ailleurs, les systèmes d'alerte automatisés s'appuient sur ces analyses pour déclencher des notifications précoces, facilitant ainsi la mobilisation rapide des équipes de secours. Cette approche hybride améliore la précision, la rapidité et la pertinence des actions de prévention et d'intervention. [65] [66] [67]

2.5.2. Études de cas et applications réelles

Plusieurs solutions concrètes illustrent cette intégration réussie. Par exemple, des systèmes basés sur ArcGIS couplés à des modèles de deep learning permettent d'allier la cartographie spatiale précise des incendies à des capacités avancées de prédiction et de suivi. De même, l'usage de drones équipés de capteurs intelligents facilite la détection précoce des

départs de feu, notamment dans des zones difficiles d'accès où les moyens traditionnels sont limités. Sur le plan des plateformes, Google Earth Engine offre une infrastructure cloud puissante pour l'analyse à grande échelle des données satellitaires, tandis que le système FIRMS (Fire Information for Resource Management System) assure une surveillance mondiale continue des incendies, en intégrant données spatiales et algorithmes d'IA. Ces exemples démontrent le potentiel concret des technologies combinées pour une gestion plus efficace, proactive et coordonnée des risques d'incendie. [68] [69] [70]

2.6. Conclusion

Ce chapitre a mis en lumière le rôle crucial des Systèmes d'Information Géographique (SIG) et de l'Intelligence Artificielle (IA) dans la gestion des incendies de forêt. Les SIG permettent une cartographie précise et dynamique des zones à risque, tandis que l'IA, grâce à des modèles de machine learning et de deep learning, améliore la détection précoce, la prédiction de la propagation et l'optimisation des interventions. L'intégration de ces technologies avec l'Internet des Objets (IoT) offre une approche globale et proactive pour anticiper et gérer les incendies de manière plus efficace.

Cependant, chaque modèle et approche présente des avantages et des limites. Les modèles supervisés, comme le Random Forest et XGBoost, sont interprétables et précis, mais moins adaptés aux données complexes. Les modèles de deep learning, tels que les CNN et LSTM, offrent une grande précision mais nécessitent des ressources importantes. Les approches hybrides et l'apprentissage par renforcement apportent une gestion dynamique, bien qu'elles demandent des simulations intensives.

Pour aller plus loin, des perspectives d'amélioration incluent l'exploitation du Edge Computing pour un traitement local des données, le développement de systèmes prédictifs en temps réel et l'amélioration des modèles génératifs pour simuler des scénarios complexes. En combinant ces technologies, il est possible de créer des solutions innovantes et robustes pour relever les défis posés par les incendies de forêt, tout en protégeant les écosystèmes et les communautés vulnérables. [71] [72] [73] [74]

Chapitre 3 : Méthodologie de Développement d'un Modèle Prédicatif des Incendies de Forêt Basé sur l'Intelligence Artificielle et les Systèmes d'Information Géographique

3.1. Objectif et Approche Générale

L'objectif de ce chapitre est de présenter de manière détaillée la démarche méthodologique adoptée pour concevoir et évaluer un modèle prédictif des incendies de forêt, fondé sur les techniques de Machine Learning (ML), de Deep Learning (DL) et l'exploitation des Systèmes d'Information Géographique (SIG). Le cas d'étude porte sur les données environnementales du Parc Naturel de Montesinho au Portugal, issues de la plateforme Kaggle.




Figure 1 : Localisation de la zone d'étude Park Naturel Montesinho au Portugal

L'étude vise à :

- Analyser l'impact des facteurs spatio-temporels et climatiques sur les incendies ;
- Développer plusieurs modèles d'apprentissage automatique (Random Forest, SVM, XGBoost) et profond (LSTM) pour la classification et la prévision des feux;
- Comparer leurs performances à l'aide de métriques robustes (Accuracy, F1-Score, AUC-ROC) ;

- Visualiser les résultats dans un environnement géospatial pour soutenir une gestion intelligente des feux. [75] [76] [77]

3.2. Environnement et Outils de Développement

L'implémentation du système repose sur un environnement technologique polyvalent permettant de traiter des données hétérogènes (géospatiales, temporelles, météorologiques) et de déployer des modèles prédictifs hybrides.

3.2.1. Plateforme de Développement

Le développement du système prédictif repose sur une plateforme technologique robuste, modulaire et adaptée aux besoins spécifiques de la science des données appliquée aux phénomènes spatio-temporels complexes, tels que les incendies de forêt. L'objectif principal est de garantir un environnement reproductible, évolutif et propice à l'intégration de bibliothèques avancées de traitement, d'analyse et de visualisation. [78] [79] [80] [81] [82]

- **Distribution Python – Anaconda :** Anaconda constitue la base de l'environnement de développement. Il s'agit d'une distribution Python (et R) orientée vers la data science et l'analyse scientifique, regroupant plus de 1 500 packages essentiels. Elle simplifie grandement la gestion des dépendances logicielles grâce à son gestionnaire de paquets intégré conda, et offre un environnement stable pour les projets d'analyse de données à grande échelle. L'utilisation d'Anaconda évite les conflits de versions de bibliothèques, courants dans des projets comportant des dépendances multiples et complexes.
- **Environnement de codage – Jupyter Notebook :** Jupyter Notebook est l'interface principale utilisée pour le développement. Ce notebook interactif facilite la combinaison de code exécutable, de visualisations et de commentaires en format Markdown. Il favorise une démarche itérative et exploratoire, particulièrement utile lors du prototypage de modèles prédictifs, de l'analyse descriptive des données et de la documentation des résultats. Il permet également le partage des analyses de manière reproductible sous forme de fichiers .ipynb.
- **Gestion des environnements – Conda :** La gestion des environnements virtuels est assurée à l'aide de conda, permettant l'isolation des bibliothèques et des dépendances pour chaque projet. Cela garantit la reproductibilité des expériences, un point crucial dans tout projet scientifique. Chaque environnement virtuel contient une version spécifique de

Python et un ensemble de packages sélectionnés, évitant ainsi les interférences entre différents projets ou versions de bibliothèques.

3.2.2. Bibliothèques Python Utilisées

Le cœur du projet repose sur un ensemble cohérent de bibliothèques Python, organisées par fonction : traitement des données, apprentissage automatique et visualisation. Ce socle technologique permet la manipulation efficace de données volumineuses, la construction de modèles performants et l'analyse visuelle des résultats. [83] [84] [85] [86]

a. Traitement et analyse des données

- **Pandas** :
Bibliothèque incontournable pour la manipulation de données tabulaires. Elle permet de charger, filtrer, transformer et agréger des données sous forme de DataFrames. Pandas est utilisée à toutes les étapes du projet : de l'ingestion des données météorologiques et géospatiales à la préparation des jeux de données pour l'apprentissage automatique.
- **NumPy** :
Fondement du calcul numérique en Python, NumPy offre des structures de données (notamment les tableaux multidimensionnels ndarray) et des opérations vectorisées efficaces. Utilisé pour les transformations mathématiques sur les séries temporelles, les normalisations et les calculs matriciels nécessaires à l'entraînement des modèles.
- **Scikit-learn** : Librairie de référence pour le machine learning supervisé et non supervisé. Elle est employée pour :
 - La préparation des données (encodage, standardisation),
 - La sélection de caractéristiques (feature selection),
 - L'évaluation des modèles (métriques de performance telles que RMSE, MAE, R^2),
 - La validation croisée (cross_val_score, GridSearchCV),
 - Et pour l'entraînement initial de modèles linéaires et non linéaires (régression, SVM, forêts aléatoires).
- **XGBoost, LightGBM, CatBoost** : Trois bibliothèques avancées de **Gradient Boosting Machines (GBM)**, reconnues pour leur performance sur des données structurées:

- **XGBoost** : optimise le boosting grâce à une implémentation efficace basée sur les arbres de décision, adaptée aux grandes quantités de données.
- **LightGBM** : version allégée et rapide, particulièrement adaptée aux données volumineuses avec une faible latence d'entraînement.
- **CatBoost** : gère nativement les variables catégorielles et réduit le surapprentissage sur des jeux de données complexes.

L'utilisation combinée de ces bibliothèques permet de tester et comparer différents modèles de prédiction, de sélectionner les hyperparamètres les plus performants et d'améliorer la robustesse des prédictions sur les zones à risque d'incendie.

b. Apprentissage profond

Pour améliorer les performances de prédiction sur les séries temporelles (telles que les températures, l'humidité ou les indices de feu), des modèles d'apprentissage profond ont été intégrés, en particulier les réseaux de neurones récurrents (RNN), et plus précisément les LSTM (Long Short-Term Memory). Ces modèles sont capables de capturer des dépendances temporelles à long terme et conviennent particulièrement aux données chronologiques complexes. [87] [88]

- **TensorFlow / Keras** : *Keras*, intégré à *TensorFlow*, est utilisé comme API haut niveau pour le prototypage, l'entraînement et l'évaluation des modèles de deep learning. Le choix du modèle **LSTM** permet :
 - De tenir compte des dépendances temporelles dans les séries (ex. : séquences de température, vitesse du vent, humidité),
 - D'améliorer la précision des prévisions par rapport aux modèles classiques linéaires ou à base d'arbres,
 - D'intégrer des mécanismes de régularisation (dropout, early stopping) pour éviter le surapprentissage.

Le framework TensorFlow/Keras offre également une compatibilité avec le GPU (via CUDA), ce qui permet une accélération significative des temps d'entraînement, notamment sur de grands volumes de données.

- **Matplotlib & Seaborn** : Ces bibliothèques sont utilisées pour l'analyse statistique et l'inspection visuelle des résultats du modèle :

- Tracés des courbes de perte (loss), d'évolution de la précision (accuracy),
- Visualisation des prédictions vs les valeurs réelles sous forme de courbes ou de nuages de points,
- Création de **heatmaps** pour analyser les matrices de corrélation et les zones d'erreur.

L'apprentissage profond vient en complément des modèles traditionnels, notamment lorsque la dynamique temporelle joue un rôle majeur dans l'évolution des phénomènes prédits (comme les feux de forêt).

L'objectif final de cette étape est de produire des cartes dynamiques permettant de localiser les zones à risque, d'identifier les facteurs déclencheurs et d'expliquer visuellement les prédictions des modèles. [89] [90] [91] [92] [93]

3.2.3. Ressources matérielles

- **Machine locale :**
 - Processeur : Intel Core i5
 - RAM : 16 Go
 - Disque : SSD
 - Système d'exploitation : Windows 10

3.2.4. Intégration SIG

Les résultats issus des modèles prédictifs pourront être intégrés à une plateforme SIG pour la visualisation géographique :

- Exportation des résultats prédictifs sous forme de fichiers CSV ou GeoJSON.
- Importation dans **QGIS** ou **ArcGIS Pro** pour la cartographie statique.
- Déploiement possible de cartes interactives via **Dash**, **Streamlit** ou **WebGIS** (avec Folium, Leaflet.js). [94] [95] [96]

3.3. Description des Données

La base de données utilisée contient 517 enregistrements d'incendies ayant eu lieu dans la région du Parc Naturel de Montesinho. Chaque entrée est caractérisée par :

- **Coordonnées spatiales** (X, Y), représentées sous forme de grille 9x9 ;
- **Facteurs temporels** : mois, jour de la semaine ;
- **Conditions climatiques** : température, humidité relative, vitesse du vent, précipitations ;
- **Indices de risque d'incendie** du FWI (Fire Weather Index) : FPMC, DMC, DC, ISI.
- **Surface brûlée** : Étendue de la zone affectée par l'incendie, exprimée en hectares.

La base de données utilisée dans cette étude a été obtenue à partir de la plateforme Kaggle, à la suite d'un travail de recherche approfondi sur la zone d'étude. Le tableau suivant présente un aperçu de son contenu. [97] [98] [99]

Tableau 6 : Description des variables utilisée pour les modèles de prédiction des incendies de forêt

Abréviation	Variable	Description
X, Y	Localisation spatiale	Grille 9x9 de la zone étudiée
Mois, Jour	Temporalité	Mois de l'année et jour de la semaine
Temp	Température (°C)	2.2 à 33.3
RH	Humidité relative (%)	15 à 100
Wind	Vitesse du vent (km/h)	0.4 à 9.4
Rain	Précipitations (mm/m ²)	0.0 à 6.4
FFMC, DMC, DC, ISI	Indices de combustion	Indicateurs du FWI
Surfaces Brulées	Surface brûlée (ha)	Étendue de la zone affectée par l'incendie, exprimée en hectares. Cette variable constitue la cible (variable à prédire) dans la modélisation.

3.4. Développement des Modèles Prédicatifs

La modélisation prédictive constitue une étape centrale du projet, visant à anticiper les risques d'incendie dans la zone d'étude à partir des variables météorologiques, spatiales et des indices de danger de feu. Plusieurs approches ont été explorées, allant des modèles d'apprentissage automatique classiques aux modèles plus avancés d'apprentissage profond, afin de comparer leurs performances et leurs capacités à capturer des relations complexes entre les données. Les modèles ont été choisis en fonction de leur pertinence pour la tâche, de leur robustesse face à la variabilité des données, ainsi que de leur capacité à intégrer la dimension temporelle et spatiale inhérente aux phénomènes de feu de forêt. La sélection finale repose sur des critères objectifs de performance, mesurés à l'aide de métriques adaptées à la classification et à la régression. Les sous-sections suivantes présentent les différentes familles de modèles testés, leur mise en œuvre technique, ainsi que les résultats obtenus lors des phases d'entraînement et de validation. [100] [101]

3.4.1. Modèles de Machine Learning pour la Prévision des Incendies

3.4.1.1. Modèles classiques supervisés

Les modèles suivants ont été implémentés à l'aide de scikit-learn :

- **Random Forest** : ensembliste robuste pour la prédiction d'occurrence, avec des résultats stables sur l'ensemble des variables.
- **Support Vector Machine (SVM)** : testé pour la détection des feux via les données spatiales et climatiques, avec un bon compromis biais/variance.
- **XGBoost** : modèle de boosting puissant qui permet de gérer des interactions complexes entre les indices FWI et les variables météorologiques. [102] [103]

3.4.1.2. Modèles profonds pour la prévision et la propagation des feux

- **Réseaux Récurrents (LSTM)** Les LSTM ont été employés pour capturer les dynamiques temporelles sur les séries de température, humidité et indices FWI. Le notebook montre :
 - Un prétraitement séquentiel des données : création de fenêtres temporelles glissantes sur 10 jours ;
 - Une structure LSTM à deux couches avec régularisation Dropout et fonction tanh ;

3.4.2. Évaluation de la Performance

L'ensemble des modèles est évalué selon un protocole commun :

- Séparation des données en deux ensembles : 80 % pour l'entraînement, 20 % pour le test ;
- Validation croisée 5-fold pour éviter le surapprentissage ;
- Utilisation de métriques standards : Accuracy, F1-Score, AUC-ROC ;
- Représentation graphique des performances via des courbes ROC et des matrices de confusion. [104] [105]

3.5. Pipeline de Traitement des Données

La mise en œuvre d'un modèle de prédiction des incendies de forêt nécessite un pipeline de traitement rigoureux, structuré en plusieurs phases successives allant de la collecte initiale des données à leur intégration finale dans un environnement cartographique. Ce pipeline garantit non seulement la qualité des données utilisées, mais aussi la reproductibilité et la validité des résultats obtenus. [106] [107]

3.5.1. Collecte des Données

La première étape du processus consiste à définir la zone d'étude, qui constitue le périmètre géographique d'analyse. Cette sélection repose sur une étude préalable identifiant une région sujette aux feux de forêt récurrents, en tenant compte de facteurs climatiques, topographiques et historiques. Ce choix permet de circonscrire l'acquisition des données à une zone pertinente, tant sur le plan spatial que temporel. [108] [109]

3.5.2. Acquisition des Données

Une fois la zone d'étude déterminée, plusieurs sources de données sont explorées pour alimenter le modèle : [110] [111]

- **Données météorologiques** : Elles incluent les relevés journaliers de la température, de l'humidité relative (HR), de la vitesse et direction du vent, ainsi que les précipitations. Ces paramètres sont essentiels pour l'estimation du niveau de risque de départ et de propagation des feux.

- **Données géospatiales** : Elles comprennent les coordonnées géographiques (latitude, longitude) des points d'observation, et parfois des variables topographiques (altitude, pente) si disponibles.
- **Extraction d'indicateurs de danger d'incendie** : À partir des données climatiques, des indices de type FWI (Fire Weather Index) sont calculés, notamment : [112]
 - FPMC (Fine Fuel Moisture Code)
 - DMC (Duff Moisture Code)
 - DC (Drought Code)
 - ISI (Initial Spread Index)

Ces indices traduisent les conditions de sécheresse de la végétation et la facilité de propagation d'un éventuel incendie.

- **Données historiques des feux** : Elles recensent les événements d'incendie passés (dates, emplacements, superficies brûlées), permettant d'entraîner les modèles à partir d'exemples réels.

3.5.3. Prétraitement des Données

Avant d'entamer toute analyse ou modélisation, les jeux de données bruts doivent être soigneusement préparés :

- **Nettoyage des données** : Cette phase vise à corriger ou éliminer les valeurs manquantes, les doublons, les incohérences et les anomalies. Elle garantit la fiabilité des traitements ultérieurs.
- **Fusion et jointure des datasets** : Les différentes sources de données (météo, indices, incendies, géospatiales) sont intégrées dans un unique DataFrame. Cela permet d'associer, pour chaque point spatio-temporel, l'ensemble des variables explicatives et la variable cible (feu ou non).
- **Transformation des variables** :
 - **Encodage** : Les variables qualitatives (catégorielles) sont converties en représentations numériques exploitables par les modèles.

- **Normalisation / standardisation** : Les variables numériques sont mises à l'échelle pour éviter que certaines ne dominent l'apprentissage à cause de leur amplitude.

3.5.4. Analyse et Visualisation Exploratoire

Une analyse exploratoire est menée afin de mieux comprendre la structure des données, détecter des tendances ou des anomalies et orienter le choix des modèles :

- **Analyse statistique descriptive** : Moyennes, écarts-types, distributions, boxplots permettent de résumer les caractéristiques fondamentales des variables.
- **Corrélation entre variables** : Des matrices de corrélation (ex. : Pearson) sont générées afin de détecter les relations linéaires ou non linéaires entre les variables explicatives et la variable cible.
- **Cartographie des incendies et des zones sensibles** : L'utilisation de bibliothèques comme folium ou geopandas permet de visualiser spatialement la répartition des feux, en lien avec les indices climatiques et les données topographiques.
- **Visualisations temporelles et spatiales** : Des heatmaps, histogrammes et séries temporelles sont produits pour analyser l'évolution saisonnière et spatiale des facteurs de risque.

3.5.5. Modélisation Prédictive

Cette phase constitue le cœur de l'étude. Elle repose sur l'entraînement de plusieurs algorithmes pour prédire la probabilité de survenue d'un incendie : [113]

- **Séparation des données** : Le jeu de données est divisé en ensembles d'entraînement et de test selon des proportions adaptées pour évaluer objectivement les performances.
- **Sélection des modèles** :
 - **Modèles classiques de Machine Learning** : Random Forest (RF), Support Vector Machine (SVM), XGBoost.
 - **Modèles d'Apprentissage Profond** : réseaux de neurones tels que CNN pour l'imagerie ou LSTM pour les séries temporelles.

- **Entraînement des modèles** : Chaque modèle est entraîné sur l'ensemble de données, en utilisant des techniques d'optimisation des hyperparamètres (GridSearch, Cross-Validation) pour maximiser les performances.
- **Évaluation des performances** : Plusieurs métriques sont utilisées selon la nature de la variable cible :
 - Pour les régressions : RMSE, MAE, R^2
 - Pour la classification : Accuracy, F1-Score, Matrice de confusion, AUC-ROC
- **Sélection du meilleur modèle** : Celui qui présente le meilleur compromis entre performance, robustesse et capacité de généralisation est retenu pour l'étape suivante.

3.5.6. Intégration et Visualisation Finale

Les prédictions générées par le modèle sélectionné pourront être exportées et visualisées dans un environnement cartographique pour faciliter leur exploitation :

- **Export des prédictions** : Les résultats seront enregistrés au format CSV, GeoJSON ou Shapefile, permettant leur import dans des plateformes SIG.
- **Visualisation dans des systèmes SIG** :
 - **Bureautiques** : QGIS, ArcGIS Pro
 - **Web interactif** : Folium, Leaflet, Streamlit, Dash
 Des cartes thématiques interactives peuvent alors être générées pour visualiser les zones à risque et appuyer les décisions stratégiques.




Figure 2 : Pipeline de traitement et de modélisation pour la prévision des risques d'incendies de forêt

3.6. Conclusion

Ce chapitre a exposé les étapes méthodologiques ayant conduit à la conception d'un modèle prédictif des incendies de forêt, en combinant données spatiales, indicateurs météorologiques et algorithmes d'intelligence artificielle. L'intégration progressive des outils SIG et d'IA permet de mieux anticiper les zones à risque et d'outiller les décideurs dans une logique préventive.

Le chapitre suivant présente la phase d'implémentation du pipeline développé, ainsi que les résultats obtenus à travers différents scénarios de modélisation.

CHAPITRE 4 : Implémentation et Analyse des Résultats.

4.1. Présentation de la Zone d'Étude et des Données

La zone d'étude, située dans le Parc Naturel de Montesinho au nord-est du Portugal, est caractérisée par un climat méditerranéen avec des influences continentales, marqué par des étés chauds et secs et des hivers froids et humides. Ce contexte climatique, combiné à une végétation dense composée de forêts de chênes, de pins et de broussailles, rend la région particulièrement vulnérable aux incendies de forêt. Le relief y est varié, alternant entre zones vallonnées et montagnes, ce qui complique l'accès aux zones sinistrées et rend les opérations de lutte contre les feux plus difficiles. La combinaison de conditions météorologiques extrêmes, de topographie accidentée et de matières combustibles naturelles favorise la survenue et la propagation rapide des incendies dans cette région protégée.

4.2. Description des jeux de données utilisés

L'étude repose sur un ensemble de données réelles collectées dans la région du Parc Naturel de Montesinho (Portugal). Ces données comprennent des données météorologiques journalières telles que la température de l'air (°C), l'humidité relative (%), la vitesse du vent (km/h) et les précipitations (mm), qui sont des facteurs déterminants dans le déclenchement et la propagation des incendies de forêt. Le jeu de données intègre également les indices du système canadien FWI (Fire Weather Index) : FFMFC (Fine Fuel Moisture Code), DMC (Duff Moisture Code), DC (Drought Code) et ISI (Initial Spread Index), qui permettent d'évaluer les conditions de sécheresse et la probabilité de propagation du feu.

En complément, des données sur les incendies sont fournies, incluant la date de survenue, la localisation géographique (coordonnées X et Y) et la surface brûlée (en hectares). L'ensemble des données couvre une période temporelle allant de janvier 2000 à décembre 2003. Ce jeu de données provient de la base de données du projet de recherche forestière de l'Université de Porto, et a été largement utilisé dans la littérature scientifique pour des études sur la prédiction des feux de forêt.

Le jeu de données contient **517 enregistrements** et **13 variables** couvrant des informations spatiales (X, Y), temporelles (month, day), météorologiques (temp, RH, wind, rain), des indices FWI (FFMFC, DMC, DC, ISI) et la **surface brûlée** (area). Aucune valeur manquante n'est présente, ce qui facilite le traitement.

Les coordonnées spatiales (X, Y) varient de 1 à 9, suggérant une répartition assez homogène des incendies. Les indices FWI montrent des conditions de sécheresse élevées et variables :

- **FFMC** est élevé (moyenne : 90.6),
- **DMC** (110.8) et **DC** (547.9) indiquent une forte variabilité d'humidité,
- **ISI** (moyenne : 9) traduit parfois une propagation rapide du feu.

Tableau 7 : Statistiques descriptives des variables météorologiques, topographiques et de localisation utilisée pour la modélisation des incendies de forêt.

Variable	Min	Max	Moyenne	Écart-type	Valeurs manquantes
X	1	9	4.67	2.31	0
Y	2	9	4.30	1.23	0
month	-	-	-	-	0
day	-	-	-	-	0
FFMC	18.70	96.20	90.64	5.52	0
DMC	1.10	291.30	110.87	64.05	0
DC	7.90	860.60	547.94	248.07	0
ISI	0.00	56.10	9.02	4.56	0
temp	2.20	33.30	18.89	5.81	0
RH	15	100	44.29	16.32	0
wind	0.40	9.40	4.02	1.79	0
rain	0.00	6.40	0.022	0.296	0
area	0.00	1090.84	12.85	63.66	0

Les données météorologiques indiquent une température moyenne de 18.9°C, une humidité relative modérée (44 %), un vent moyen de 4 km/h et peu de pluie (0.02 mm en

moyenne). La surface brûlée (area) est très variable (0 à plus de 1 090 ha), avec une moyenne de 12.85 ha, ce qui révèle la présence de quelques incendies extrêmes.

Une normalisation des variables continues et un encodage des variables temporelles sont nécessaires pour l'apprentissage automatique et profond.

La figure ci-dessous montre la distribution de quatre indices issus du Système Canadien des indices de feu (Canadian Forest Fire Weather Index – FWI) : FFMC (Fine Fuel Moisture Code), ISI (Initial Spread Index), DMC (Duff Moisture Code) et DC (Drought Code).




Figure 3 : Distributions des indices d'inflammabilité du système FWI (FFMC, ISI, DMC, DC)

Le FFMC, indicateur de l'humidité des combustibles fins, présente une distribution très concentrée autour de valeurs élevées (entre 85 et 95), traduisant une grande inflammabilité de la litière de surface. Le ISI, qui reflète la vitesse initiale de propagation du feu, suit une distribution asymétrique droite avec une majorité de valeurs faibles, mais quelques pics extrêmes pouvant indiquer un danger potentiel élevé.

Le DMC, indicateur de l'humidité des couches intermédiaires du sol, montre une distribution étalée, suggérant une grande variabilité des conditions de sécheresse à mi-

profondeur. Enfin, le DC, qui mesure la sécheresse du sol profond, révèle une distribution bimodale avec des valeurs très élevées pour un grand nombre d'observations, témoignant d'un assèchement prolongé, facteur aggravant pour les incendies à combustion lente et de longue durée.

Ces distributions soulignent la complexité et la diversité des conditions environnementales propices au déclenchement et à la propagation des incendies dans cette région.

La figure ci-dessus présente la distribution de quatre variables climatiques majeures utilisées dans l'analyse du risque d'incendie : la température (temp), la vitesse du vent (wind), l'humidité relative (RH) et les précipitations (rain). La température suit une distribution proche de la normale, centrée autour de 20 °C, ce qui est typique d'un climat méditerranéen chaud en été. La vitesse du vent est modérément répartie entre 2 et 6 km/h, avec quelques valeurs extrêmes pouvant favoriser la propagation rapide des feux.




Figure 4 : Analyse de la distribution des variables climatiques influençant les incendies dans le Parc Naturel de Montesinho

L'humidité relative est majoritairement comprise entre 20 % et 60 %, reflétant un air souvent sec, propice à l'inflammabilité. Quant aux précipitations, leur distribution est

fortement asymétrique avec une concentration très élevée autour de 0, indiquant des périodes prolongées sans pluie, ce qui accentue les conditions de sécheresse. Ces observations confirment le caractère à haut risque de la zone étudiée en matière d'incendies de forêt.

4.3. Prétraitement et Intégration des Données

4.3.1. Préparation des Données Catégorielles

Afin d'adapter le jeu de données aux différents algorithmes d'apprentissage automatique et profond, deux types d'encodage ont été appliqués aux variables catégorielles month et day. Pour les modèles basés sur les arbres de décision (Decision Tree, Random Forest, XGBoost), un encodage ordinal a été réalisé à l'aide de LabelEncoder, transformant les mois et jours en entiers. En parallèle, pour les modèles sensibles à l'ordre des catégories comme le SVM et le LSTM, un encodage One-Hot a été effectué via pd.get_dummies, créant ainsi des variables binaires pour chaque modalité. Cette double stratégie d'encodage permet une flexibilité optimale dans l'entraînement des différents modèles.

4.3.2. Normalisation des Variables Numériques

La normalisation des variables numériques est une étape essentielle dans le pipeline de traitement des données, notamment pour les modèles sensibles à l'échelle des variables tels que les SVM et LSTM. Dans cette étude, les variables continues comme les indices FWI (FFMC, DMC, DC, ISI), les paramètres météorologiques (température, humidité relative, vent, pluie) ainsi que la surface brûlée ont été standardisées à l'aide du StandardScaler. Cette méthode permet de centrer les données autour de zéro avec un écart-type de un, garantissant ainsi une meilleure convergence des modèles d'apprentissage et une comparaison équitable des variables lors de l'entraînement.

4.3.3. Visualisation des Valeurs Aberrantes

Dans cette étape, nous avons effectué une visualisation exploratoire des variables quantitatives afin d'identifier d'éventuelles valeurs aberrantes (outliers). Pour cela, des boxplots ont été générés pour chaque variable issue des indices FWI (FFMC, DMC, DC, ISI), des paramètres météorologiques (température, humidité relative, vent, pluie) ainsi que pour la variable cible représentant la surface brûlée (area). Cette visualisation permet de repérer facilement les valeurs extrêmes sans les supprimer, ce qui est essentiel pour comprendre la distribution des données et prendre des décisions éclairées lors du prétraitement, notamment avant l'entraînement des modèles.




Figure 5 : Analyse des valeurs aberrantes des variables météorologiques et des indices du comportement du feu via des boxplots

4.3.4. Transformation de la Variable Cible

Afin d'atténuer l'effet des valeurs extrêmes et d'améliorer la distribution de la variable cible area, une transformation logarithmique a été appliquée sous la forme $\log(1 + \text{area})$. Cette transformation permet de stabiliser la variance, de réduire la sensibilité des modèles aux outliers, et d'obtenir une meilleure performance prédictive. Elle est particulièrement bénéfique pour les réseaux de neurones (LSTM).




Figure 6 : Distribution de la variable cible surface brûlée avant et après transformation

4.3.5. Création de Variables Temporelles

Dans le cadre de cette étude, les variables temporelles ont été préparées pour une meilleure prise en compte de la dimension cyclique des incendies. Les colonnes month (mois) et day (jour de la semaine), initialement sous forme textuelle (ex. "aug", "fri"), ont été converties en valeurs numériques afin d'être compatibles avec les algorithmes d'apprentissage automatique. Cette étape permet aux modèles d'apprentissage d'exploiter les effets potentiels du temps sur l'occurrence ou la gravité des feux de forêt.

4.4. Analyse Exploratoire et Visualisation des Données

4.4.1. Analyse de corrélation

La figure ci-dessous présente deux matrices de corrélation illustrant les relations linéaires entre la surface brûlée (variable area) et, d'une part, les indices du système FWI (à gauche), et d'autre part, les variables météorologiques (à droite). On observe que parmi les indices FWI, l'indice DMC (Duff Moisture Code) et DC (Drought Code) présentent une corrélation modérée avec la surface brûlée, tandis que l'ISI (Initial Spread Index) et le FFMC (Fine Fuel Moisture Code) ont une corrélation plus faible. Du côté des paramètres météorologiques, les corrélations sont globalement faibles, la température et l'humidité relative présentant des valeurs opposées, reflétant leur influence antagoniste sur l'inflammabilité. Ces résultats suggèrent que les indices FWI, notamment DMC et DC, sont de meilleurs prédicteurs de la surface brûlée que les variables météorologiques brutes.




Figure 7 : Matrices de corrélation entre les variables météorologiques et la surface brûlée et les indices FWI et la surface brûlée

Le Figure ci-dessous représente une matrice de corrélation entre toutes les variables numériques du jeu de données sur les incendies de forêt. Cette matrice permet d'identifier la relation linéaire entre chaque paire de variables, avec des coefficients compris entre -1 (corrélation parfaitement négative) et +1 (corrélation parfaitement positive). Visuellement, les corrélations sont illustrées à l'aide d'une palette de couleurs allant du bleu (relation négative) au rouge (relation positive).

L'analyse montre que certaines variables sont fortement liées entre elles. Par exemple, une corrélation positive notable est observée entre DMC (Duff Moisture Code) et DC (Drought Code), deux indices qui mesurent la sécheresse du sol, indiquant qu'ils évoluent souvent ensemble. De même, le FPMC (Fine Fuel Moisture Code), qui représente la facilité d'inflammation de la végétation fine, est bien corrélé à l'indice d'intensité de l'incendie (ISI), ce qui est logique puisque plus le combustible est sec, plus le feu peut s'intensifier.

La température (temp) montre également une corrélation modérée avec ISI, confirmant que la chaleur favorise l'intensité des feux. À l'inverse, l'humidité relative (RH) est négativement corrélée à la température, ce qui reflète le fait qu'un air chaud est souvent plus sec. Cependant, un point important à souligner est que la variable area (surface brûlée) présente des corrélations très faibles avec les autres variables, ce qui ne signifie qu'aucune d'elles, prise seule, n'explique bien la quantité de surface affectée par un incendie.

Cette analyse révèle que certaines conditions météorologiques sont liées entre elles et influencent potentiellement l'intensité d'un incendie, mais que la prédiction de la surface brûlée (area) nécessite des modèles plus complexes que la simple corrélation linéaire. Cela suggère l'utilisation de modèles non linéaires et multivariés, comme les forêts aléatoires ou les réseaux de neurones, pour obtenir de meilleurs résultats dans la prédiction de l'impact des feux de forêt.




Figure 8 : Matrice de corrélation entre toutes les variables numériques du jeu de données sur les incendies de forêt

4.4.2. Analyse temporelle

La Figure ci-dessous visualise la répartition des incendies selon les mois de l'année et les jours de la semaine. Le graphique mensuel montre que les incendies sont plus fréquents pendant les mois d'été, notamment entre juillet et septembre, ce qui coïncide avec les fortes chaleurs et la sécheresse. Le graphique par jour de la semaine permet d'identifier si certains jours, comme le week-end, sont plus sensibles aux départs de feu, possiblement à cause des activités humaines. Ces analyses temporelles sont utiles pour mieux planifier la prévention et la surveillance des incendies.




Figure 9 : Histogrammes mensuels et hebdomadaires des incendies

4.4.3. Analyse spatiale

Le graphique présente deux cartes thermiques (heatmaps). À gauche, la carte thermique représente la fréquence des incendies. Elle visualise le nombre d'incendies survenus dans chaque cellule géographique (définie par les coordonnées X, Y du jeu de données). Chaque case de la carte correspond à une zone spécifique de la forêt, et sa couleur indique la fréquence des incendies : plus la couleur est foncée, plus la zone a été touchée par des feux. Cette visualisation est cruciale pour identifier les points chauds ou zones à risque élevé, ce qui s'avère extrêmement utile pour la prévention, la surveillance et la gestion des incendies de forêt.

À droite, la carte thermique illustre la surface totale brûlée. Elle montre la surface en hectares détruite par les incendies sur une grille de 9x9, toujours en utilisant les coordonnées X et Y. Chaque case représente une zone géographique, et l'intensité de sa couleur reflète l'étendue des dégâts : une couleur plus foncée signifie une surface brûlée plus importante au cours de l'année. Ce graphique aide à cibler les zones les plus impactées, facilitant ainsi la prévention et la gestion des risques d'incendie.




Figure 10 : Nombre d'incendies et Surfaces totales brûlées par cellule

4.4.4. Analyse spatio-temporelle

La figure ci-dessous présente deux séries de cartes thermiques (heatmaps) qui détaillent la répartition spatio-temporelle des incendies de forêt sur une grille géographique de 9x9 cellules (X, Y).

À gauche, des cartes thermiques sont générées pour chaque mois de l'année, visualisant le nombre d'incendies survenus dans chaque cellule. Chaque carte indique la fréquence des feux par zone géographique pour un mois donné. Les variations de couleurs et les chiffres affichés facilitent l'identification des zones les plus fréquemment touchées par les incendies chaque mois. Cette visualisation est essentielle pour comprendre les dynamiques temporelles et spatiales des feux, offrant des informations précieuses pour la prévention et la gestion des risques.

À droite, la figure visualise la répartition spatio-temporelle des surfaces brûlées. Pour chaque mois présent dans les données, une carte thermique est affichée, représentant la somme des surfaces brûlées (en hectares) dans chaque cellule de la grille. La couleur de chaque case indique l'intensité des dégâts causés par les incendies, avec des valeurs numériques permettant de quantifier précisément les pertes. Plus la cellule est d'un rouge foncé, plus la surface brûlée y est importante. Cette visualisation met en évidence les zones les plus vulnérables et les mois les plus destructeurs, offrant une vision claire de l'impact spatial et temporel des feux. Elle est très utile pour orienter les politiques de prévention, organiser les interventions ciblées et alimenter les modèles prédictifs de risque d'incendie.




Figure 11 : Cartes mensuelles (9x9) de fréquence et de surface brûlée

4.4.5. Analyse des indices FWI

La figure ci-dessous présente quatre cartes thermiques (heatmaps) cruciales, offrant une perspective détaillée sur le risque d'incendie de forêt à travers une grille géographique de 9x9 cellules, basée sur des moyennes annuelles.

En haut à gauche, la carte "FFMC" (Fine Fuel Moisture Code) identifie le risque général d'incendie en fonction de l'humidité des combustibles fins, les zones rouges indiquant un danger élevé. En haut à droite, la carte "ISI" (Initial Spread Index) évalue le risque de propagation initiale, avec le rouge signalant une vitesse de propagation très rapide, essentielle pour anticiper la dynamique des feux. En bas à gauche, la carte "DMC" (Duff Moisture Code) met en lumière le risque lié à la sécheresse des couches de matière organique moyennes, les zones plus foncées indiquant des combustibles particulièrement secs. Enfin, en bas à droite, la carte "DC" (Drought Code) visualise le risque de sécheresse des couches profondes, le rouge foncé signalant une sécheresse extrême et un potentiel de feux majeurs.

L'intégration de ces quatre indicateurs météorologiques offre une compréhension exhaustive et nuancée des facteurs de risque d'incendie, ce qui est fondamental pour une prise de décision éclairée en matière de prévention, de surveillance et de gestion des incendies de forêt.



Figure 12 : Visualisation des Facteurs de Risque d'Incendie (FFMC, ISI, DMC, DC) sur une Grille Géographique 9x9

La figure ci-dessous présente quatre séries de cartes thermiques (heatmaps) par mois, détaillant l'évolution des risques d'incendie sur une grille de 9x9 cellules. Elles visualisent le risque général d'incendie (FFMC, en haut à gauche), la vitesse de propagation initiale (ISI, en haut à droite), la sécheresse des combustibles moyens (DMC, en bas à gauche), et la sécheresse des combustibles profonds (DC, en bas à droite). Ces cartes révèlent les tendances spatio-temporelles des conditions favorables aux incendies, essentielles pour une gestion proactive des risques.




Figure 13 : Dynamique Mensuelle des Facteurs de Risque d'Incendie (FFMC, ISI, DMC, DC) sur Grille 9x9

4.4.6. Analyse Spatiale des Facteurs Météorologiques

Cette figure est composée de quatre cartes thermiques (heatmaps) qui illustrent la distribution spatiale annuelle moyenne de facteurs météorologiques essentiels à l'évaluation du risque d'incendie sur une grille géographique de 9x9 cellules.

En haut à gauche, la carte présente la température moyenne annuelle, soulignant les zones où des températures élevées (en rouge) accroissent la sécheresse des combustibles et donc le risque d'incendie. En haut à droite, la carte de la vitesse moyenne annuelle du vent identifie les secteurs où des vents forts (en rouge) peuvent accélérer la propagation des feux. En bas à gauche, le cumul pluviométrique annuel visualise les zones recevant moins de précipitations (en jaune/vert clair), synonyme de sécheresse accrue. Enfin, en bas à droite, la carte de l'humidité relative moyenne annuelle met en évidence les zones à faible humidité (en rouge), propices à l'inflammation et à une propagation intense des incendies.

Collectivement, ces visualisations offrent une compréhension spatiale approfondie des conditions météorologiques qui influencent directement le risque d'incendie, permettant d'identifier les zones géographiques les plus vulnérables et de cibler efficacement les mesures de prévention et de gestion.




Figure 14 : Analyse Spatiale des Facteurs Météorologiques Clés du Risque d'Incendie (Grille 9x9)

Cette figure présente quatre séries de cartes thermiques mensuelles sur une grille 9x9, détaillant les facteurs météorologiques clés influençant le risque d'incendie. Elles visualisent la température, la vitesse du vent, les précipitations et l'humidité relative mois par mois. Cette analyse spatio-temporelle permet d'identifier précisément quand et où les conditions météorologiques favorisent les incendies, guidant ainsi la prévention et la gestion des risques.



Figure 15 : Dynamique Spatio-Temporelle mensuelle des Facteurs Météorologiques du Risque d'Incendie (Grille 9x9)

4.4.7. Classification des Zones Inflammables

La figure ci-dessous illustre deux méthodes clés pour déterminer le nombre optimal de clusters dans le cadre de la classification des zones inflammables. Le graphique de gauche, la "Méthode du Coude", représente le WCSS (somme des carrés intra-cluster) en fonction du nombre de clusters ; le point d'inflexion ("le coude") indique un compromis optimal. Le graphique de droite, le "Score de Silhouette", évalue la qualité de la séparation des clusters, un score plus élevé signifiant des clusters mieux définis. L'analyse combinée de ces deux métriques est essentielle pour sélectionner le nombre de clusters le plus pertinent pour cette segmentation spécifique.

L'analyse combinée de ces deux métriques suggère que le nombre optimal de clusters trouvé est 2. Le Score de Silhouette, en particulier, affiche sa valeur la plus élevée pour 2

clusters, indiquant une séparation nette et pertinente des données en deux groupes distincts pour cette segmentation spécifique.




Figure 16 : Détermination du Nombre Optimal de Clusters pour la Classification des Zones Inflammables (Méthode du Coude et Score de Silhouette)

Cette figure représente une carte de classification des zones inflammables et non-inflammables sur une grille géographique de 9x9 cellules, obtenue grâce à l'algorithme de clustering K-Means++. Chaque cellule est clairement catégorisée pour identifier son niveau de vulnérabilité aux incendies.




Figure 17 : Classification des Zones à Risque d'Incendie par K-Means++ (Grille 9x9)

Les Zones Rouges (marquées '1') correspondent aux zones inflammables. Elles sont caractérisées par une combinaison critique de facteurs météorologiques défavorables : faible humidité (selon le FFMC et l'humidité relative), températures élevées, vents forts et faibles précipitations. Ces conditions rendent ces zones particulièrement propices aux départs et à la propagation rapide des incendies. À l'inverse, les Zones Vertes (marquées '0') sont considérées comme non-inflammables, indiquant des conditions météorologiques moins propices aux incendies.

Cette classification visuelle est un outil précieux pour la gestion des risques d'incendie, permettant d'identifier rapidement les points chauds et de cibler efficacement les efforts de prévention, de surveillance et d'intervention sur le terrain.

4.5. Modélisation Prédictive : Feux de Forêt

4.5.1. Objectif de modélisation

L'objectif de cette phase est de mettre en place des modèles de Machine Learning et de Deep Learning capables d'anticiper le risque d'incendie de forêt à partir de données environnementales et météorologiques. Deux types de modélisation étaient envisageables selon la variable cible :

- Une modélisation de type classification, visant à prédire la survenue ou non d'un incendie (variable binaire : feu / pas feu).
- Une modélisation de type régression, permettant d'estimer la surface susceptible d'être brûlée lors d'un incendie (variable continue).

Bien que la régression ait été envisagée comme une possibilité pertinente, notamment pour quantifier l'intensité d'un feu, notre étude s'est concentrée sur la problématique de classification. Ce choix s'explique par le besoin opérationnel d'identifier rapidement les zones à risque, afin d'optimiser les actions de prévention et d'intervention.

4.5.2. Constitution du jeu de données pour le Machine learning

Pour entraîner et évaluer les modèles de classification, un jeu de données structuré a été constitué à partir de variables pertinentes, à la fois explicatives et cibles.

- **Variable cible** : Une étiquette binaire a été générée pour indiquer la survenue d'un incendie (*feu / pas feu*). Cette étiquette a été construite à partir de la surface brûlée : si la surface est supérieure à 0, l'étiquette est *feu*, sinon, elle n'est pas *feu*.
- **Variables explicatives (features)** :
 - **Conditions météorologiques** : température, humidité relative, vitesse du vent, précipitations.
 - **Indices du comportement du feu** : *FFMC* (Fine Fuel Moisture Code), *DMC* (Duff Moisture Code), *DC* (Drought Code), *ISI* (Initial Spread Index).
 - **Informations spatio-temporelles** : mois, jour, coordonnées spatiales (X, Y).

Cette structure de données permet aux modèles d'apprendre à identifier les situations propices à l'apparition d'un incendie à partir des conditions observées.

4.5.3. Séparation des données

Le jeu de données est divisé en deux sous-ensembles :

- Jeu d'entraînement (*training set*) : 80 % des données sont utilisées pour l'apprentissage des modèles
- Jeu de test (*test set*) : 20 % des données sont utilisées pour évaluer la performance sur des données non vues

4.5.4. Application des Modèles de Machine Learning (ML)

Dans le cadre de la prédiction des incendies de forêt, plusieurs algorithmes d'apprentissage supervisé ont été appliqués afin de comparer leurs performances. Pour chaque modèle, une phase d'entraînement initial a été suivie d'une phase d'optimisation au cours de laquelle les hyperparamètres ont été ajustés afin d'obtenir les meilleurs résultats possibles.

4.5.4.1. Modèles de Machine Learning utilisés

Les modèles testés sont les suivants :

a. Forêt Aléatoire (Random Forest – RF)

Algorithme d'ensemble reposant sur la combinaison de plusieurs arbres de décision construits sur des sous-ensembles aléatoires du jeu de données. Il est particulièrement robuste face au bruit et performant sur des données complexes et non linéaires.

Une optimisation des hyperparamètres a permis d'améliorer la précision du modèle.

La figure suivante présente les matrices de confusion obtenues avec le modèle Random Forest : à gauche, le modèle après optimisation des hyperparamètres ; à droite, le modèle initial sans optimisation.




Figure 18 : Matrices de confusion du modèle Random Forest avant et après optimisation.

b. SVM (Support Vector Machine)

Méthode efficace pour la classification binaire, surtout lorsque les classes ne sont pas linéairement séparables. Le choix du noyau (linéaire, RBF, etc.) ainsi que des hyperparamètres tels ont été ajustés pour améliorer les performances de séparation. Cette optimisation a permis de renforcer la capacité du SVM à distinguer les situations à risque.

La matrice de confusion du SVM est illustrée ci-dessous, avec à gauche la version optimisée et à droite la version brute du modèle.




Figure 19 : Matrices de confusion du modèle SVM avant et après optimisation.

c. XGBoost

Algorithme de boosting très performant, particulièrement adapté aux données déséquilibrées et aux problèmes de classification complexes. Il offre une grande flexibilité grâce à ses nombreux paramètres de réglage (nombre d'itérations, taux d'apprentissage, profondeur des arbres, régularisation, etc.).

Une recherche des d'hyperparamètres a permis d'exploiter le potentiel de ce modèle. Les matrices de confusion du modèle XGBoost sont présentées dans la figure suivante : à gauche, les résultats après ajustement des hyperparamètres ; à droite, ceux du modèle non optimisé.




Figure 20: Matrices de confusion du modèle XGBoost avant et après optimisation.

4.5.4.2. Résultats Après Optimisation des modèles de machine learning

L'optimisation des hyperparamètres a permis d'améliorer les performances globales des trois modèles de classification : Random Forest, XGBoost et Support Vector Machine.

Tableau 8 : Tableau Comparatif Optimisé

Métrique	RF Optimisé	XGBoost Optimisé	SVM Optimisé	Meilleur Modèle
Accuracy	66% (+4%)	61% (-1%)	65% (+1%)	RF Optimisé
ROC AUC	0.67	0.69 (+0.02)	0.68 (+0.01)	XGBoost Optimisé
Recall (Classe 1 - Feu)	78%	89% (+18%)	85% (+3%)	XGBoost Optimisé
Precision (Classe 0 - Non-feu)	77%	82%	80%	XGBoost Optimisé
F1-Score (Classe 1)	67%	67%	69%	SVM Optimisé
Faux Positifs (FP)	25 (-3)	35 (+7)	26 (-3)	SVM Optimisé
Faux Négatifs (FN)	10 (-3)	5 (-8)	7 (-1)	XGBoost Optimisé

La Figure 21 présente un tableau comparatif détaillé des principales métriques obtenues après cette phase d'ajustement.

4.5.4.3. Analyse des Résultats :

- Random Forest a obtenu la meilleure précision globale (accuracy) avec 66%, soit un gain de 4 points par rapport à la version non optimisée. Ce modèle reste robuste et équilibré, bien qu'il soit légèrement en retrait sur certaines métriques spécifiques.
- XGBoost se distingue clairement sur les indicateurs critiques de détection du feu :
 - Le Recall (89%), soit la capacité à détecter correctement les incendies, est nettement supérieur (+18%), ce qui en fait le modèle le plus sensible.
 - Il affiche également les meilleurs scores en ROC AUC (0.69), en précision pour la classe "non-feu" (82%) et en faux négatifs réduits (FN = 5), ce qui est crucial dans un contexte de prévention.
- SVM quant à lui, présente le meilleur F1-score pour la classe incendie (69%), ce qui reflète un bon compromis entre précision et rappel. Il réduit également efficacement les faux positifs, ce qui limite les fausses alertes.

En conséquence, aucune méthode ne domine sur tous les critères, mais XGBoost apparaît comme le plus performant pour la détection des incendies, grâce à sa forte capacité à minimiser les faux négatifs et maximiser le rappel. En revanche, Random Forest reste une solution équilibrée avec la meilleure précision globale, et SVM est utile pour obtenir un bon compromis sur la classe positive tout en évitant les alertes erronées.

Ainsi, le choix du modèle peut dépendre de la priorité :

- Minimiser les faux négatifs (XGBoost),
- Maximiser la précision globale (RF),
- Ou équilibrer rappel et précision (SVM).

4.5.5. Application des Modèles de Deep Learning (DL)

4.5.5.1. Le modèle LSTM (Long Short-Term Memory)

Dans cette phase, un modèle de type LSTM (Long Short-Term Memory) a été mis en œuvre pour exploiter la dimension temporelle des données liées aux incendies de forêt. L'approche s'appuie sur la capacité des réseaux LSTM à capturer les dépendances à long terme dans des séries temporelles, en l'occurrence celles relatives aux conditions environnementales sur plusieurs jours consécutifs.

4.5.5.2 Construction des Séquences Temporelles

Les données ont été réorganisées sous forme de séquences temporelles glissantes, afin de modéliser l'évolution des conditions favorisant l'apparition d'un feu. Chaque séquence contient des valeurs des variables clés telles que :

- Les **indices météorologiques** : température, humidité relative, vent, précipitations ;
- Les **indices du comportement du feu** : FFMC, DMC, DC, ISI ;
- La **variable cible** : probabilité d'occurrence d'un feu (classification) ou surface estimée (régression, utilisée de façon auxiliaire pour discrétiser l'occurrence du feu).

4.5.5.3. Architecture du Modèle

Le modèle LSTM développé est composé des éléments suivants :

- **Deux couches LSTM empilées**, avec un total de 50 epochs d'entraînement par couche, conçues pour capter les dépendances temporelles dans les séquences ;
- **Un Dropout de 0.2** entre les couches, utilisé pour éviter le surapprentissage ;
- **Une couche de sortie Dense**, avec fonction d'activation adaptée à la nature de la tâche (sigmoïde pour classification binaire) ;
- **Fonction de perte** : l'erreur absolue moyenne (MAE) a été utilisée pour évaluer les performances durant l'entraînement ;
- Le modèle comprend **36 251 paramètres entraînables**, reflétant une architecture relativement légère mais suffisamment expressive.

Cette architecture a été entraînée sur des données séquentielles temporellement ordonnées, dans le but de capturer les dynamiques environnementales précédant l'apparition d'un feu.

4.5.5.4. Analyse des Résultats et Interprétation

L'analyse des courbes d'apprentissage permet d'évaluer le comportement du modèle au cours des itérations :

- **Perte d'entraînement (training loss)** : elle diminue progressivement, passant de 3.25 à 0.58, témoignant de la capacité du modèle à apprendre les patterns présents dans les données ;
- **Erreur absolue moyenne (MAE)** sur les données d'entraînement : elle s'améliore également, passant de 1.16 à 0.55 ;

- **Validation loss** : elle tend à se stabiliser entre 1.7 et 2.0 à partir de l'époch 30, indiquant que le modèle atteint un plateau de généralisation ;
- Un **léger surapprentissage (overfitting)** est observé à partir de l'époch 50 : la perte d'entraînement continue de baisser, tandis que la validation loss cesse de s'améliorer de manière significative.

Les résultats obtenus à partir de l'entraînement du modèle LSTM sont présentés dans les deux figures ci-dessous. La première illustre l'évolution de la fonction de perte (loss) pour les ensembles d'entraînement et de test, tandis que la seconde représente un nuage de points comparant les valeurs réelles de surface brûlée aux prédictions du modèle.

a. Courbes d'apprentissage – Perte entraînement vs test

La courbe d'apprentissage montre une diminution progressive de la perte d'entraînement, passant de 3,25 à environ 0,58 au fil des 100 époques. Cela indique que le modèle apprend efficacement à partir des données séquentielles fournies. Cependant, la perte sur l'ensemble de test (validation) stagne autour de 1,7 à 2,0 dès l'époque 30, avec des oscillations marquées à partir de l'époque 50. Cette divergence entre les courbes traduit un phénomène de surapprentissage (overfitting) : le modèle continue de s'ajuster aux données d'entraînement sans améliorer sa capacité de généralisation. Ce comportement pourrait être atténué par des techniques telles que l'early stopping, l'augmentation du dropout ou la régularisation.




Figure 21 : Courbes d'apprentissage du modèle LSTM : perte sur l'ensemble d'entraînement et de validation

b. Prédictions vs Valeurs réelles

Le graphique de dispersion met en évidence un comportement de sous-estimation généralisée des valeurs prédites par rapport aux valeurs réelles, en particulier pour les cas de surface brûlée importante. La majorité des prédictions restent concentrées dans l'intervalle [0–20 ha], même lorsque les valeurs réelles atteignent plus de 100 ha. Cela s'explique par la nature déséquilibrée des données, où les grands incendies sont rares. Ce déséquilibre rend difficile l'apprentissage de ces cas extrêmes, et conduit le modèle à privilégier des sorties faibles.




Figure 22: Dispersion des prédictions du modèle LSTM par rapport aux valeurs réelles de surface brûlée

c. Performances quantitatives du modèle LSTM

À l'issue de l'entraînement, les performances quantitatives du modèle LSTM sont les suivantes :

Tableau 9 : Performances quantitatives du modèle LSTM

Indicateur	Valeur
MAE (train)	0.55
MAE (validation)	1.03
Nombre d'epochs	100
Temps d'entraînement	Élevé

Ces résultats indiquent que le modèle parvient à apprendre efficacement la structure temporelle des données, mais que ses performances en validation restent modérément satisfaisantes, probablement limitées par la taille réduite du dataset.

d. Limites Observées

Le LSTM, bien qu'adapté à la nature temporelle des données, présente plusieurs contraintes à ce stade :

- Temps de calcul important par rapport aux modèles classiques ;
- Interprétabilité faible : difficile de comprendre les décisions internes du réseau ;
- Performances dépendantes de la qualité et quantité des données : nécessite des jeux de données volumineux pour atteindre son plein potentiel ;
- Pas encore adapté à la classification binaire directe dans cette version : le modèle retourne une valeur continue (erreur MAE) plutôt qu'une évaluation précise par classe (accuracy, recall, etc.).

e. Perspectives d'Amélioration

Plusieurs pistes d'amélioration pourraient être envisagées pour tirer un meilleur parti du LSTM :

- Incorporation d'une couche Attention pour focaliser l'apprentissage sur les moments critiques ;
- Augmentation de la base de données et enrichissement par des données externes (Facteurs humains, topographie, images satellite) ;
- Utilisation de techniques de régularisation supplémentaires : early stopping, réduction adaptative du taux d'apprentissage ;
- Formulation du problème en classification binaire avec une fonction de perte adaptée (comme `binary_crossentropy`) et une activation de type sigmoid.

4.6. Discussion et Interprétation des Résultats

4.6.1. Rappel des Performances des Modèles Classiques

Les algorithmes classiques de machine learning ; à savoir Random Forest, XGBoost et SVM ont été entraînés sur les mêmes données, sans prise en compte explicite de la dimension temporelle. Ces modèles utilisent un ensemble de variables explicatives incluant des paramètres météorologiques et des indices liés au comportement du feu. Le tableau ci-dessous

récapitule leurs performances comparées, en les confrontant au modèle LSTM utilisé pour l'analyse séquentielle :

Tableau 10 : Tableau récapitulatif des performances des modèles de ML : Random Forest Optimisé, XGBoost Optimisé, SVM Optimisé et du modèle de DL : LSTM

Métrique	Random Forest Optimisé	XGBoost Optimisé	SVM Optimisé	LSTM
Accuracy	66 %	61 %	65 %	-
Recall (Feu)	78 %	89 %	85 %	-
Precision (Feu)	58 %	53 %	56 %	-
MAE	-	-	-	0.55 (train) / 1.03 (val)
Temps d'entraînement	Rapide	Rapide	Modéré	Long (100 epochs)

Ces résultats montrent que XGBoost offre la meilleure sensibilité (recall) pour la détection des feux, tandis que Random Forest obtient la meilleure précision globale (accuracy). Le modèle LSTM, bien que plus coûteux en temps d'entraînement, permet d'exploiter les relations temporelles, ce qui ouvre la voie à des prédictions plus fines et contextuelles dans des scénarios séquentiels.

4.6.2. Bilan des Modèles et Recommandations

L'évaluation comparative des modèles classiques (Random Forest, XGBoost, SVM) et du modèle séquentiel LSTM met en lumière les atouts spécifiques de chaque approche.

- Le LSTM se distingue par sa capacité à capturer les relations temporelles complexes sans nécessiter d'ingénierie manuelle des variables temporelles, ce qui en fait une option prometteuse pour les séries continues. Toutefois, son temps d'entraînement long, sa moindre interprétabilité et sa dépendance à un grand volume de données constituent des limitations.
- Le XGBoost montre un excellent rappel sur la classe "feu" (89 %), ce qui le rend adapté aux systèmes de prévention où il est préférable de détecter des faux positifs que de rater un vrai feu. En revanche, sa précision reste limitée.
- Le Random Forest offre un bon compromis entre précision et rappel, avec une robustesse intéressante même en conditions de données limitées, et une interprétabilité précieuse.

- Le SVM, quant à lui, reste performant dans les cas à faible dimensionnalité mais moins compétitif globalement.

En fonction du contexte d'utilisation, plusieurs recommandations émergent : pour des systèmes légers et fiables, Random Forest est approprié ; pour maximiser la détection préventive, XGBoost est préférable ; pour les analyses temporelles approfondies, LSTM ou une version améliorée de celui-ci (intégrant la classification) est recommandée ; enfin, des approches hybrides telles que RF + LSTM ou XGBoost + LSTM pourraient combiner les avantages de la structure des arbres et de la mémoire séquentielle des réseaux récurrents.

4.7. Conclusion

Ce chapitre a comparé plusieurs modèles de machine learning et de deep learning pour la prédiction des feux de forêt. Les modèles classiques (RF, XGBoost, SVM) se sont révélés efficaces, notamment XGBoost pour la détection des feux grâce à un fort taux de rappel. Le modèle LSTM, bien que plus complexe et exigeant en données, a montré un bon potentiel pour capturer les dynamiques temporelles.

Chaque modèle présente des avantages selon le contexte : RF pour sa stabilité, XGBoost pour la prévention, et LSTM pour l'analyse séquentielle. Des approches hybrides pourraient permettre de tirer parti des forces de chacun.

Conclusion générale

Ce projet de fin d'étude a mis en évidence l'importance d'une approche intégrée alliant Intelligence Artificielle (IA) et Systèmes d'Information Géographique (SIG) dans la prédiction et la gestion des incendies de forêt. Face à l'accroissement du risque incendiaire dû aux changements climatiques et à la complexité des facteurs environnementaux, il devient impératif de développer des outils intelligents, capables d'analyser de grandes quantités de données hétérogènes.

L'intégration des indices de combustion, des données météorologiques, topographiques et géospatiales dans un système unifié a permis de construire une plateforme de détection et de prédiction à la fois fiable, réactive et évolutive. Les modèles d'apprentissage automatique tels que les réseaux de neurones profonds, les algorithmes de classification et les modèles de séries temporelles se sont révélés performants pour anticiper les zones à haut risque et fournir des alertes précoces.

L'expérimentation a démontré la performance des modèles d'apprentissage automatique pour anticiper les zones à haut risque et fournir des alertes précoces. En effet, l'évaluation comparative a révélé que des modèles tels que les réseaux de neurones profonds (LSTM), les algorithmes de classification comme XGBoost et Random Forest, se sont avérés particulièrement efficaces. Le XGBoost s'est distingué par un excellent rappel de 89% sur la classe "feu", ce qui le rend idéal pour la détection préventive, même s'il peut générer quelques faux positifs. Le Random Forest, quant à lui, a offert un bon compromis entre précision et rappel, avec une robustesse appréciable même avec des données limitées et une interprétabilité précieuse pour la prise de décision. Le LSTM a démontré une capacité unique à capturer les relations temporelles complexes, ce qui est fondamental pour l'analyse des séries continues de données, bien que son temps d'entraînement soit plus long. Le SVM, bien que performant en basse dimensionnalité, s'est montré moins compétitif dans le cadre global de notre étude.

Ce système, bien qu'intéressant, ouvre la voie à des améliorations et des déploiements opérationnels à plus grande échelle. Voici quelques perspectives d'évolution :

- Intégration de données temps réel et sources hétérogènes : Enrichir le système avec des données issues de capteurs IoT, de drones, d'images satellites à très haute résolution et de réseaux sociaux pour une réactivité accrue et une granularité d'information plus fine.

- Développement de modèles hybrides avancés : Explorer des architectures hybrides comme RF + LSTM ou XGBoost + LSTM pour capitaliser sur les atouts de chaque approche, en combinant la robustesse et l'interprétabilité des arbres de décision avec la capacité des réseaux récurrents à gérer les dépendances temporelles.
- Optimisation des performances et de l'interprétabilité des modèles : Réduire les temps d'entraînement des modèles complexes comme LSTM et améliorer leur interprétabilité grâce à des techniques d'IA explicable (XAI), afin de fournir aux utilisateurs des justifications claires pour les prédictions.
- Déploiement opérationnel et validation sur le terrain : Collaborer avec les organismes de gestion des risques d'incendie pour tester le système en conditions réelles, affiner les algorithmes et valider son efficacité opérationnelle.
- Extension à d'autres risques naturels : Adapter la méthodologie développée pour la gestion d'autres risques naturels tels que les inondations, les glissements de terrain ou les sécheresses, dans une logique de résilience environnementale globale.
- Interface utilisateur interactive et outils d'aide à la décision : Développer une interface utilisateur plus intuitive et des outils d'aide à la décision basés sur le SIG, permettant aux décideurs de simuler différents scénarios d'incendie et d'évaluer l'impact des mesures préventives.

En conclusion, cette synergie IA–SIG constitue une avancée prometteuse pour renforcer les stratégies de prévention, de surveillance et d'intervention rapide face aux feux de forêt. Ce système, encore perfectible, ouvre la voie à des déploiements opérationnels à grande échelle, et peut également être adapté à d'autres risques naturels dans une logique de résilience environnementale.

Bibliography

- [1] «Fire: A Brief History. University of Washington Press.,» *Pyne, S.J.*, 2015.
- [2] «"The Interaction of Fire and Mankind". Philosophical Transactions of the Royal Society B, 371(1696).,» *Scott, A.C., et al.*, 2014.
- [3] «Fire: A Brief History (op. cit.).,» *Pyne, S.J.* , 2015.
- [4] «Philosophical Transactions (op. cit.).,» *Scott, A.C.*, 2014.
- [5] «Human-started wildfires expand the fire niche across the United States". PNAS, 114(11), 2946–2951.,» *Balch, J.K., et al.*, 2017.
- [6] «Wildfires as an Ecosystem Service". Frontiers in Ecology and the Environment, 17(5), 289–295.,» *Pausas, J.G., & Keeley, J.E.*, 2019.
- [7] «Global trends in wildfire and its impacts". Philosophical Transactions of the Royal Society B, 371(1696).,» *Doerr, S.H., & Santín, C.*, 2016.
- [8] «Global fire emissions estimates during 1997–2016". Earth System Science Data, 9(2), 697–720.,» *Van der Werf, G.R., et al.*, 2017.
- [9] «Earth Observing System Data and Information System (EOSDIS).,» *NASA.*, 2020.
- [10] «Forest Fire Detection Systems Using Wireless Sensor Networks". IEEE Sensors Journal, 19(19), 9011–9018.,» *Yu, L., et al.*, 2019.
- [11] «A review of prescribed burning effectiveness in fire hazard reduction". International Journal of Wildland Fire, 12(2), 117–128.,» *Fernandes, P.M., & Botelho, H.S.*, 2003.

- [12] «Community Wildfire Preparedness: a Global State-of-the-Knowledge Summary". USDA Forest Service General Technical Report.,» *McCaffrey, S.*, 2015.
- [13] «Effectiveness of aerial firefighting foams". Bushfire and Natural Hazards CRC Report.,» *Plucinski, M.P.*, 2017.
- [14] «Applications of UAVs in Forest Fire Management". *Drones*, 5(4), 133.,» *Yuan, C., et al.*, 2021.
- [15] «FARSITE: Fire Area Simulator. USDA Forest Service RMRS-GTR-4.,» *Finney, M.A.*, 1998.
- [16] «Wildland surface fire spread modelling". *Progress in Physical Geography*, 33(2), 189–203.,» *Sullivan, A.L.*, 2009.
- [17] «Generation and Analysis of a New Global Burned Area Product". *Remote Sensing of Environment*, 217, 129–140.,» *Chuvieco, E., et al.*, 2019.
- [18] «Climate-induced variations in global wildfire danger". *Climatic Change*, 133(4), 535–548.,» *Jolly, W.M., et al.*, 2015.
- [19] «Remote Sensing of Large Wildfires. Springer,» *Chuvieco, E.*, 2012.
- [20] ««Comprehensive monitoring of wildfires in Europe: The European Forest Fire Information System (EFFIS). Springer,»,» *San-Miguel-Ayanz, J., et al.*, 2012.
- [21] «EFFIS Technical Report. JRC Publications.,»,» *European Commission*, 2021. .
- [22] ««Development and Structure of the Canadian Forest Fire Weather Index System. Canadian Forestry Service,»1987.,» *Van Wagner, C.E.*, 1987.

- [23] ««Australian Fire Weather as Represented by the AFDRS. Journal of Southern Hemisphere Earth Systems Science, 69(1).»,» *Dowdy, A.J., et al.*, 2019..
- [24] ««Australian Fire Danger Rating System: Science Background. Commonwealth Scientific and Industrial Research Organisation.»,» *CSIRO.*, 2021.
- [25] ««Integration of ecological and socio-economic factors to assess global vulnerability to wildfire. Global Ecology and Biogeography, 23(2), 245-258.»,» *Chuvieco, E., et al.*, , 2014.
- [26] «FireFamily Plus User's Guide. USDA Forest Service.»,» *Bradshaw, L.S., & McCormick, E.*, 2000.
- [27] ««Rethinking the Wildland Fire Management System". Journal of Forestry, 115(4), 343–353.»,» *Thompson, M.P., et al.*, 2017.
- [28] ««Development and Structure of the Canadian Forest Fire Weather Index System. Service canadien des forêts.»,» *Van Wagner, C.E.*, , 1987..
- [29] «What causes large fires in Southern France. Forest Ecology and Management, 294, 76-85.»,» *Ganteaume, A., & Jappiot, M.*, 2013.
- [30] «Fire deficit increases wildfire risk for many communities in the Canadian boreal forest". Nature Communications, 11(1), 1–9.»,» *Parisien, M.A., et al.*, 2020.
- [31] «op. cit.»,» *Pyne,Scott*, 2015,2014.
- [32] «Wildland Fire Danger Estimation and Mapping. World Scientific.»,» *Chuvieco, E.*, 2003.
- [33] «A review of machine learning applications in wildfire science". Environmental Modelling & Software, 131, 104798.»,» *Jain, P., et al.*, 2020.

- [34] ««Integration of ecological and socio-economic factors to assess global vulnerability to wildfire. *Global Ecology and Biogeography*, 23(2), 245-258.,»» *Chuvieco, E., et al.*, 2014.
- [35] ««A review of machine learning applications in wildfire science. *Environmental Modelling & Software*, 131, 104798.,»» *Jain, P., et al.*, 2020.
- [36] «<https://www.fao.org/forest-resources-assessment/past-assessments/fra-2020/forest-fire-management/en/>,» [En ligne].
- [37] «Global Forest Fire Report 2021. Organisation des Nations Unies pour l'alimentation et l'agriculture.,» *FAO*, 2022.
- [38] «Generation and Analysis of a New Global Burned Area Product. *Remote Sensing of Environment*, 217, 129–140.,» *Chuvieco, E., et al*, 2019.
- [39] «A review of machine learning applications in wildfire science. *Environmental Modelling & Software*, 131, 104798.,» *Jain, P., et al.*, 2020.
- [40] «Machine Learning for Real-Time Wildfire Behavior Prediction. *Frontiers in Forests and Global Change*, 2, 77.,» *Radke, D., et al.*, 2019.
- [41] «Geographic Information Science & Systems (4th ed.). Wiley.,» *Longley, P.A., et al*, 2015.
- [42] «Real-time wildfire monitoring using GIS and remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 205–216.,» *Chen, G., et al.*, 2021.
- [43] «Sentinel-2 User Handbook*. European Space Agency.,» *ESA*, 2021.
- [44] «MODIS Collection 6.1 User Guide,» *NASA*, 2020.
- [45] «Forest Fire Detection Systems Using Wireless Sensor Networks. *IEEE Sensors Journal*, 19(19), 9011–9018.,» *Yu, L., et al*, 2019.

- [46] «Climate-induced variations in global wildfire danger. Climatic Change, 133(4), 535–548.,» *Jolly, W.M., et al*, 2015.
- [47] «GIS-based fire response system optimization. International Journal of Geographical Information Science, 33(2), 353–372.,» *Rodríguez-Veiga, P., et al*, 2019.
- [48] «The Esri Guide to GIS Analysis, Volume 1 (2nd ed.). Esri Press.,» *Mitchell, A*, 2020.
- [49] «Google Earth Engine: Planetary-scale geospatial analysis for everyone. Remote Sensing of Environment, 202, 18–27.,» *Gorelick, N., et al.*, 2017.
- [50] «DeepSmoke: Deep Learning Model for Smoke Detection. Remote Sensing, 13(18), 3667.,» *Zhang, Q., et al*, 2021.
- [51] «Wildfire susceptibility mapping using machine learning. Environmental Modelling & Software, 145, 105227.,» *Abid, F.*, 2021.
- [52] «Transformer-based wildfire spread forecasting. IEEE Transactions on Geoscience and Remote Sensing, 60, 1–15.,» *Prapas, I., et al*, 2022.
- [53] «Reinforcement Learning for Wildfire Containment. Fire Technology, 59(2), 543–572.,» *Islam, M.M., et al*, 2023.
- [54] «Deep learning. Nature, 521(7553), 436–444.,» *LeCun, Y., et al.*, 2015.
- [55] «Stop explaining black box machine learning models. Nature Machine Intelligence, 1(5), 206–215.,» *Rudin, C.*, 2019.
- [56] «Fuzzy GIS-based MCDM for wildfire risk assessment. Science of The Total Environment, 726, 138343.,» *Pourghasemi, H.R., et al*, 2020.
- [57] «Rethinking the Wildland Fire Management System". Journal of Forestry, 115(4), 343–353.,» *Thompson, M.P., et al*, , 2017.

- [58] «Development and Structure of the Canadian Forest Fire Weather Index System. Service canadien des forêts.,»,» *Van Wagner, C.E.*, 1987.
- [59] ««Probability based models for estimation of wildfire risk". International Journal of Wildland Fire, 13(2), 133–142.,»,» *Preisler, H.K., et al*, 2004.
- [60] «Machine Learning for Real-Time Wildfire Behavior Prediction". Frontiers in Forests and Global Change, 2, 77.,»,» *Radke, D., et al* , 2019.
- [61] «lobal Forest Fire Report 2021. Organisation des Nations Unies pour l'alimentation et l'agriculture.,»,» *FAO. [En ligne].*, 2022.
- [62] «Impact of anthropogenic climate change on wildfire across western US forests. PNAS, 113(42), 11770-11775.,»A.P., 2016.,» *Abatzoglou, J.T., & Williams, ,* 2016.
- [63] «Global Fire Management Strategy. Organisation des Nations Unies pour l'alimentation et l'agriculture.,»,» *FAO.*, 2020.
- [64] ««Comprehensive monitoring of wildfires in Europe: The European Forest Fire Information System (EFFIS). Springer.,»,» *San-Miguel-Ayanz, J., et al*, 2012.
- [65] ««Probability based models for estimation of wildfire risk". International Journal of Wildland Fire, 13(2), 133–142.,»,» *Preisler, H.K., et al.*, 2004. .
- [66] ««Machine Learning for Real-Time Wildfire Behavior Prediction". Frontiers in Forests and Global Change, 2, 77.,»,» *Radke, D., et al* , 2019. .
- [67] ««lobal Forest Fire Report 2021. Organisation des Nations Unies pour l'alimentation et l'agriculture.,»,» *FAO. [En ligne].*, 2022.
- [68] «« Impact of anthropogenic climate change on wildfire across western US forests. PNAS, 113(42), 11770-11775.,»,» *Abatzoglou, J.T., & Williams, A.P.,* 2016..

- [69] ««Global Fire Management Strategy. Organisation des Nations Unies pour l'alimentation et l'agriculture.,»,» *FAO.*, , 2020. .
- [70] ««Comprehensive monitoring of wildfires in Europe: The European Forest Fire Information System (EFFIS). Springer.,»,» *San-Miguel-Ayanz, J., et al.*, , 2012.
- [71] «« EFFIS Technical Report. JRC Publications.,»,» *European Commission*, 2021. .
- [72] ««Development and Structure of the Canadian Forest Fire Weather Index System. Canadian Forestry Service.,»,» *Van Wagner, C.E.*, , 1987.
- [73] ««FireFamily Plus User's Guide. USDA Forest Service.,»,» *Bradshaw, L.S., & McCormick, E.*, 2000. .
- [74] ««The Rothermel Surface Fire Spread Model and Associated Developments. Fire, 1(1), 8.,»,» *Andrews, P.L.*, , 2018.
- [75] ««The Canadian Forest Fire Danger Rating System: An Overview. Natural Resources Canada.,»,» *Wotton, B.M., et al.*, , 2009.
- [76] ««Development and Structure of the Canadian Forest Fire Behavior Prediction System. Technical Report ST-X-3.,»,» *Forestry Canada.*, , 1992.
- [77] ««Machine Learning for Real-Time Wildfire Behavior Prediction. Frontiers in Forests and Global Change, 2, 77.,»,» *Radke, D., et al.*, 2019.
- [78] «Fire: A Brief History. University of Washington Press.,»,» *Pyne, S.J.*, 2015.
- [79] «An integrated IoT-GIS-Deep Learning framework. Computers, Environment and Urban Systems, 95, 101803.,»,» *Li, Z., et al.*, 2022.

- [80] ««Wildfire Risk Analysis with Deep Learning. Case Study.,»» *Esri*, , 2022.
- [81] ««Applications of UAVs in Forest Fire Management. *Drones*, 5(4), 133.,»» *Yuan, C., et al*, , 2021.
- [82] ««Remote Sensing of Large Wildfires (Chap. 7). Springer.,»» *Chuvieco, E*, , 2020.
- [83] ««The Emergence of Edge Computing. *Computer*, 50(1), 30–39.,»» *Satyanarayanan, M*, , 2017.
- [84] ««Deep learning and process understanding for data-driven Earth system science. *Nature*, 566(7743), 195–204.,»» *Reichstein, M., et al*, , 2019.
- [85] ««The Shuttle Radar Topography Mission. *Reviews of Geophysics*, 45(2).,»» *Farr, T.G., et al*, , 2007.
- [86] ««FIRMS Data User Guide,» .,» *NASA*, , 2021.
- [87] «« Forest Fire Detection Using Wireless Sensor Networks. *IEEE Sensors Journal*, 19(19), 9011–9018.,»» *Yu, L., et al*, , 2019. .
- [88] ««PostGIS in Action (2nd ed.). Manning Publications.,»» *Obe, R.O., & Hsu, L.S.*, 2015. .
- [89] ««Multiple Imputation for Nonresponse in Surveys. Wiley.,»» *Rubin, D.B.*, 2004. .
- [90] ««Attention Is All You Need. NIPS.,»» *Vaswani, A., et al*, , 2017. .
- [91] ««Generative Adversarial Nets. NIPS.,»» *Goodfellow, I., et al*, , 2014. .
- [92] ««Deep Learning with Python. Manning Publications.,»» *Chollet, F.*, , 2017. .

- [93] ««« A survey on Image Data Augmentation. *Journal of Big Data*, 6(1), 60.,»» Shorten, C., & Khoshgoftaar, T.M., 2019. .
- [94] «««QGIS User Guide.,»» *QGIS.org* ,, 2021..
- [95] «««Information Dashboard Design. O'Reilly.,»» Few, S, , 2013. .
- [96] «««Python Reference Manual. Python Software Foundation.,»» Rossum, G., 2020. .
- [97] «««TensorFlow: Large-Scale Machine Learning. OSDI'16.,»» Abadi, M., et al., 2016. .
- [98] «««PostGIS in Action (2nd ed.). Manning.,»» Obe, R.O., & Hsu, L.S., 2015. .
- [99] «««Google Earth Engine. Remote Sensing of Environment, 202.,»» Gorelick, N., et al, , 2017. .
- [100] «««The Python Language Reference. docs.python.org.,»» Van Rossum, G., & Drake, F.L., 2023. .
- [101] «TensorFlow: Large-Scale Machine Learning. OSDI'16.,»» Abadi, M., et al, , 2016. .
- [102] «««Deep Learning with Python. Manning.,»» Chollet, F., 2017.
- [103] «««PyTorch: An Imperative Style High-Performance DL Library. NeurIPS.,»» Paszke, A., et al., 2019. .
- [104] «Apache Spark: Unified Engine for Big Data Processing. *Communications of the ACM*, 59(11).,»» Zaharia, M., et al, , 2016. .
- [105] «««Citizens as Sensors: Web 2.0 and Volunteered Geographic Information. *GeoJournal*, 72(3).,»» Goodchild, M.F., 2007. .

- [106] «Forest Fires in Algeria: Drivers and Impacts. Journal of Environmental Management, 128.,»,» *Meddour-Sahar, O., et al* , 2013. .
- [107] «Validation of Fire Spread Simulation Models. Fire, 3(3).»,» *Chuvieco, E., et al* , 2020. .
- [108] «Scikit-learn: Machine Learning in Python. JMLR, 12.,»,» *Pedregosa, F., et al* , 2011. .
- [109] «Space, Time and Visual Analytics. IEEE VAST.,»,» *Andrienko, G., et al* , 2010.
- [110] ««Stop Explaining Black Box Models. Nature Machine Intelligence, 1(5).»,» *Rudin, C* , 2019. .
- [111] ««Edge Computing. Computer, 50(1).»,» *Satyanarayanan, M* , 2017. .
- [112] «A Unified Approach to Interpreting Model Predictions. NIPS.,»,» *Lundberg, S.M., & Lee, S.I.* , 2017..
- [113] «Sentinel-5P TROPOMI*. ESA Living Planet Symposium.,»,» *Guanter, L., et al*., 2015. .
- [114] «Rethinking the Wildland Fire Management System". Journal of Forestry, 115(4), 343–353.,» *Thompson, M.P., et al*, 2017.
- [115] «Development and Structure of the Canadian Forest Fire Weather Index System. Service canadien des forêts.,» *Van Wagner, C.E*, 1987.
- [116] «Probability based models for estimation of wildfire risk". International Journal of Wildland Fire, 13(2), 133–142.,» *Preisler, H.K., et al*, 2004.
- [117] «Machine Learning for Real-Time Wildfire Behavior Prediction". Frontiers in Forests and Global Change, 2, 77.,» *Radke, D., et al*, 2019.

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي والبحث العلمي

جامعة عبد الحميد بن باديس-مستغانم-
كلية العلوم الدقيقة والإعلام الآلي

تصريح شرفي خاص بالالتزام بقواعد النزاهة العلمية
لإنجاز البحث

أنا الممضي أدناه،

الطالب (ة): رقم التسجيل الجامعي: 2025.3703.2633
الحامل لبطاقة التعريف الوطنية رقم: 11002099200311 والصادرة بتاريخ: 2025.01.30
عن: مستغانم.

المسجل بـ: كلية العلوم الدقيقة والإعلام الآلي / قسم: وإعلام آلي
شعبة: إعلام آلي / التخصص: وأنشئت

والمكلف بإنجاز مذكرة ماستر بعنوان:

الدمج بين الذكاء الاصطناعي ونظم المعلومات الجغرافية
المتنوعة بحوثات

أصرح بشرفي أنني ألتزم بمراعاة المعايير العلمية والمنهجية ومعايير الأخلاقيات العلمية والنزاهة الأكاديمية
المطلوبة في إنجاز البحث ، وأتحمل المسؤولية الشخصية عن كل المحتوى المتضمن في البحث المذكور أعلاه .

التاريخ: 2025.06.18

نقرأ للتصديق على الإمضاء
لـ
موان في 12 جويلية 2025

إمضاء المعني





* ملحق القرار رقم 933 المؤرخ في 28 جويلية 2016 الذي يحدد القواعد المتعلقة بالوقاية من السرقة العلمية ومكافحتها.

الجمهورية الجزائرية الديمقراطية الشعبية
وزارة التعليم العالي والبحث العلمي

جامعة عبد الحميد بن باديس-مستغانم-
كلية العلوم الدقيقة والإعلام الآلي

تصريح شرقي خاص بالالتزام بقواعد النزاهة العلمية
لإنجاز البحث

أنا الممضي أدناه،
الطالب(ة): لعوج امينة رقم التسجيل الجامعي: 202037034541
الحامل لبطاقة التعريف الوطنية رقم: 110021536007610004 والصادرة بتاريخ: 02.09.2020
عن بلدية يبل - غليزان
المسجل ب: كلية العلوم الدقيقة والإعلام الآلي / قسم: الرياضيات والإعلام الآلي
شعبة: الإعلام الآلي / التخصص: الذكاء الاصطناعي
والمكلف بإنجاز مذكرة ماستر بعنوان: Synergie entre Intelligence Artificielle et
Systèmes d'Information Géographique pour la Modélisation Prédictive des Incendies de
.Forêt

أصرح بشرقي أنني ألتزم بمراعاة المعايير العلمية والمنهجية ومعايير الأخلاقيات العلمية والنزاهة الأكاديمية
المطلوبة في إنجاز البحث ، وأتحمّل المسؤولية الشخصية عن كل المحتوى المتضمن في البحث المذكور أعلاه .

التاريخ: 14.06.2025

إمضاء المعني



* ملحق القرار الوزاري رقم 933 المؤرخ في 28 جويلية 2016 الذي يحدد القواعد المتعلقة بالوقاية من السرقة العلمية ومكافحتها.