



Université d'Oran 2
Institut de Maintenance et de sécurité Industrielle

THESE

Pour l'obtention du diplôme de Doctorat « L.M.D »
En Sécurité Industrielle et Environnement

**Développement d'une méthode de détection d'incendie par des techniques
de traitement numérique des images**

Présentée et soutenue publiquement par :
Melle BELARBI Farah

Devant le jury composé de :

LOUNIS Zoubida	Professeur	IMSI, université d'Oran 2	Présidente
HASSINI Abdelatif	Professeur	IMSI, université d'Oran 2	Directeur
LOUNIS Zakia	Professeur	ENPO d'Oran	Examinatrice
AISSANI Nassima	Professeur	IMSI, université d'Oran 2	Examinatrice
BENZIANE Sarah	MCA	Université d'Usto	Examinatrice

Année Universitaire : 2025/2026

Développement d'une méthode de détection d'incendie par des techniques de traitement numérique des images

Résumé :

Au cours de la dernière décennie le nombre d'incendies a augmenté dans les industries, les bâtiments, les zones urbaines et les forêts entraînant des conséquences graves, notamment des pertes humaines, des dégâts matériels, ainsi que des impacts environnementaux, sociaux et économiques. Dans ce contexte, la prévention et la détection rapide des incendies représentent des enjeux majeurs pour la protection des vies humaines et des infrastructures. Une solution efficace pour lutter contre les incendies repose sur l'utilisation de systèmes d'alerte précoce permettant une détection rapide des zones affectées, ce qui limite la propagation du feu et réduit les risques. Avec le développement rapide des caméras numériques et de l'Internet des objets (IoT), les caméras de surveillance sont désormais largement déployées, ce qui a encouragé les chercheurs à développer des systèmes intelligents de détection d'incendie. Ces systèmes visent à détecter les incendies dès leur apparition, pour déclencher une alarme et d'envoyer des alertes aux responsables de la sécurité. L'apprentissage profond représente aujourd'hui une méthode performante pour la classification d'images et la détection d'objets. Les réseaux de neurones convolutifs (CNN), en particulier, se distinguent comme l'une des approches les plus efficaces pour la détection d'incendie permettant d'améliorer considérablement la précision de détection. Cependant, la plupart des recherches existantes s'appuient sur des architectures CNN très profondes, coûteuses en calculs, nécessitant une grande capacité de mémoire et du matériel puissant. Pour combler ces lacunes, Cette thèse propose quatre nouveaux réseaux CNN simples et légers capables de classer et détecter un incendie dans un stade précoce : CNN_A, CNN_B, CNN_C et CNN_D. De plus, afin d'améliorer la performance de l'algorithme et de réduire le taux d'erreur, une nouvelle approche d'assemblage est appliquée, combinant les prédictions des quatre architectures unique. Les résultats sont évalués selon plusieurs métriques : l'exactitude, la sensibilité, la précision, le score F1, ainsi que les taux de faux positifs (FP %) et de faux négatifs (FN %). Par ailleurs, la complexité computationnelle des modèles est analysée, notamment la taille du modèle (en Mo), la vitesse de détection (en images par seconde – FPS) et le nombre d'opérations en virgule flottante (MFLOP). Une comparaison des algorithmes proposés avec les travaux récents de détection d'incendie montre l'efficacité de l'approche proposée. Parmi les modèles évalués, le modèle d'ensemble CNN_BC est celui qui a obtenu les meilleurs résultats, avec une excellente précision de 99,69 % et 96,01 % sur deux ensembles de test difficiles, tout en présentant un nombre réduit d'opérations en virgule flottante et une taille plus petite. Par conséquent, le modèle CNN_BC se distingue par sa robustesse et sa capacité à détecter efficacement un incendie à un stade précoce.

Mots clés : Détection d'incendie, Classification d'images, Réseaux de neurones convolutifs, Système de surveillance, Vision par ordinateur, Apprentissage d'ensemble .

Development of a Fire Detection Method Using Image Processing Techniques

Abstract:

Over the last decade, the number of fires has increased in industries, buildings, urban areas, and forests, leading to serious consequences, including human losses, material damage, as well as environmental, social, and economic impacts. In this context, fire prevention and early detection represent major challenges for the protection of human lives and infrastructure. An effective solution to fight fires relies on the use of early warning systems that enable rapid detection of the affected areas before the fire becomes uncontrollable, thereby reducing its spread and minimizing risks. With the rapid development of the Internet of Things (IoT), surveillance cameras are now widely deployed, which has encouraged researchers to develop intelligent fire detection systems. These systems aim to detect fires as soon as they appear, to trigger an alarm and send alerts to safety officials. Deep learning has become

an effective method for image classification and object detection. Convolutional neural networks (CNNs), in particular, are one of the most advanced approaches for fire detection, by improving detection accuracy. However, most existing research relies on very deep CNN architectures that are computationally expensive, require large memory capacity, and demand powerful hardware. To address these gaps, this thesis proposes four new simple and lightweight CNN networks to classify and detect fires at an early stage: CNN_A, CNN_B, CNN_C, and CNN_D. Furthermore, in order to improve the algorithm's performance and reduce the error rate, a new ensemble approach is applied, combining the predictions of the four unique architectures. The results are evaluated using several metrics: accuracy, sensitivity, precision, F1-score, false positive rate (FP%) and false negative rate (FN%). In addition, the computational complexity of the models is analyzed, according to model size (in MB), detection speed (in frames per second – FPS), and the number of floating-point operations (MFLOPs). A comparison of the proposed algorithms with recent fire detection approaches shows the effectiveness of the proposed approach. Among the evaluated models, the proposed ensemble model CNN_BC achieved the best results, with excellent accuracy of 99.69% and 96.01% on two challenging testsets, while presenting a reduced number of floating-point operations and a smaller size. Therefore, the CNN_BC model stands out for its robustness and its ability to detect fires at an early stage.

Key words: Fire detection, Image classification, CNN, Surveillance system, Computer vision, Ensemble learning

تطوير طريقة للكشف عن الحرائق باستخدام تقنيات المعالجة الرقمية للصور

الملخص

خلال الازمنة الأخيرة، ازداد عدد الحرائق في الصناعات والمباني والمناطق الحضرية والغابات، مما أدى إلى عواقب خطيرة، من بينها خسائر بشرية وأضرار مادية، بالإضافة إلى التأثيرات البيئية والاجتماعية والاقتصادية. في هذا السياق، تمثل الوقاية والكشف السريع عن الحرائق تحديات رئيسية لحماية الأرواح البشرية والبنى التحتية. وتعتمد إحدى الحلول الفعالة لمكافحة الحرائق على استخدام أنظمة الإنذار المبكر التي تمكن من الكشف السريع عن المناطق المتضررة قبل أن يصبح الحريق خارج السيطرة، مما يقلل من انتشاره ويحد من المخاطر. ومع التطور السريع للكاميرات الرقمية وإنترنت الأشياء (IoT)، أصبحت كاميرات المراقبة منتشرة على نطاق واسع، وهو ما شجع الباحثين على تطوير أنظمة ذكية للكشف عن الحرائق. وتهدف هذه الأنظمة إلى اكتشاف الحرائق فور ظهورها، لإطلاق الإنذار وإرسال التنبيهات إلى مسؤولي السلامة. ويُعتبر التعلم العميق اليوم طريقة فعالة لتصنيف الصور واكتشاف الأجسام. وتُعد الشبكات العصبية الالتفافية (CNN) على وجه الخصوص من أكثر الأساليب كفاءة للكشف عن الحرائق، حيث تسمح بتحسين كبير في دقة الكشف. ومع ذلك، فإن معظم الأبحاث القائمة تعتمد على هياكل CNN عميقة جداً، مكلفة حسابياً، وتتطلب سعة ذاكرة كبيرة ومعدات قوية. ويظل نشرها في شبكات المراقبة الفعلية صعباً بسبب الموارد الكبيرة المطلوبة أثناء الاستدلال. ولمعالجة هذه الثغرات، تقترح هذه الأطروحة أربعة شبكات CNN جديدة بسيطة وخفيفة قادرة على تصنيف واكتشاف الحرائق في مرحلتها المبكرة: CNN_A و CNN_B و CNN_C و CNN_D. بالإضافة إلى ذلك، ولتحسين أداء الخوارزمية وتقليل معدل الخطأ، يتم تطبيق نهج تجميعي جديد يجمع بين تنبؤات الهياكل الأربعة. وتُقيم النتائج وفقاً لعدة مقاييس: الدقة، والحساسية، والانضباط (Precision)، ودرجة F1، إضافة إلى معدلات الإيجابيات الكاذبة (FP%) والسلبيات الكاذبة (FN%). كما يتم تحليل التعقيد الحسابي للنماذج، لا سيما حجم النموذج (بالميغابايت)، وسرعة الكشف وعدد (MFLOP) وتُظهر مقارنة الخوارزميات المقترحة مع الأعمال الحديثة في كشف الحرائق فعالية النهج المقترح. ومن بين النماذج المُقيمة، حصل النموذج التجميعي CNN_BC على أفضل النتائج، بدقة ممتازة بلغت 99.69% و 96.01% على مجموعتي اختبار صعبتين. وبالتالي، يتميز نموذج CNN_BC بقدرته على الكشف الفعال عن الحرائق في مرحلة مبكرة.

الكلمات المفتاحية: الكشف عن الحرائق، تصنيف الصور، الشبكات العصبية الالتفافية، نظام المراقبة، الرؤية الحاسوبية، التعلم التجميعي.

Remerciements

Alḥamdulillāh, ce travail est mené à bien par la grâce d'Allah, le tout-puissant et le miséricordieux, qui m'a donné la force et la patience pour accomplir ce modeste travail.

Le présent travail de recherche a été réalisé au sein du Laboratoire de l'Ingénierie de la Sécurité Industrielle et du Développement Durable (LISIDD) de l'Institut de Maintenance et de Sécurité Industrielle (IMSI) de l'Université Mohamed Ben Ahmed Oran 2. Je suis très reconnaissante d'avoir eu l'opportunité de pouvoir travailler au sein de ce laboratoire.

Je tiens à remercier tous ceux qui m'ont apporté leur aide dans la réalisation de cette thèse. Tout d'abord, je remercie également mon encadrant, Monsieur HASSINI Abdelatif, pour son accompagnement, ses précieux conseils, sa disponibilité et son soutien qui ont grandement contribué à l'aboutissement de ce travail.

Mes remerciements les plus vifs vont à Madame LOUNIS Zoubida, responsable du laboratoire, pour son aide précieuse, ses conseils et son soutien qui ont grandement contribué à la réalisation de ce travail.

Je remercie chaleureusement les membres du jury de thèse pour le temps consacré à l'évaluation de ce travail, ainsi que pour leurs commentaires constructifs et leurs précieux conseils qui ont contribué à améliorer la qualité scientifique de cette recherche.

Je tiens à remercier sincèrement ma chère collègue Mlle NEHAL Naïma pour l'aide inestimable qu'elle m'a apportée dans la révision de ma thèse, pour ses précieux conseils, sa disponibilité et le temps qu'elle m'a consacré durant la réalisation de mon travail.

J'adresse également mes vifs remerciements à ma chère collègue AMIRI Nesrine, qui a toujours été à mes côtés et m'a soutenue tout au long de ce travail.

Je tiens à exprimer ma profonde gratitude à Nadir Kamal BE NAMARA pour son aide précieuse dans la réalisation de la partie du code, ainsi qu'à Okba BEKHELIFI. Leur expertise et leur disponibilité ont grandement contribué à la réussite de cette thèse.

Je remercie Monsieur BOUCHAALA Abdelghani, professeur à l'université d'Oran2, pour son aide précieuse et son accompagnement lors de la révision de mon article, son soutien et ses conseils tout au long de ce travail.

Je suis profondément reconnaissante de l'immense support apporté par mes aimables collègues, je vous remercie d'être toujours là pour moi.

Je tiens à adresser un véritable remerciement à mes chères parents et mon frère Nadjib qui compte beaucoup pour moi. Tout au long de ce parcours, leur grand amour, leur support inconditionnel et leur omniprésence ont été pour moi une réelle source d'inspiration et de motivation. Je suis vraiment reconnaissante d'avoir à mes côtés une telle famille bienveillante et encourageante.

Enfin, un grand merci à toutes les personnes qui ont contribué de près ou de loin à la réalisation de ce travail.

Liste des abréviations

AE	Autoencodeurs
ANN	Réseaux de neurones artificiels (Artificial Neural Networks)
CFD	Technologies de Détection d'incendie Conventionnelle (Conventional Fire Detection Technologies)
CM	Matrice de confusion (Confusion Matrix)
CNN	Réseaux de neurones convolutifs (Convolutional Neural Networks)
Colab	Google Colaboratory
CV	Vision par ordinateur (computer vision)
DBN	Réseaux de croyance profonde (Deep Belief Networks)
DL	Apprentissage profond (Deep Learning)
E	L'exactitude (Accuracy)
F	Le F1 score
FN	Faux négatifs (False Negatives)
FP	Faux positifs (False Positives)
GAN	réseaux génératifs adversariaux (Generative Adversarial Networks)
GMHI	Gradient Motion History Image
HSI	Teinte, Saturation, Intensité (Hue, Saturation, Intensity)
IA	Intelligence Artificielle (Artificial Intelligence)
KNN	K plus proches voisins (K-Nearest Neighbors)
LED	Diode émettant la lumière (Light Emitting Diode)

LSTM	Mémoire à Long et Court Terme (Long Short-Term Memory)
ML	L'apprentissage automatique (Machine Learning)
P	La precision
RCNN	Réseau de neurones convolutifs basé sur les régions (Region based Convolutional Neural Network)
RNN	Réseaux de neurones récurrents (Recurrent Neural Network)
RVB	Rouge – Vert – Bleu
S	la sensibilité
SSD	Détecteur MultiBoîtes à Coup Unique (Single Shot Multibox Detector)
SVM	Machine à vecteurs de support (Support Vector Machine)
TN	les vrais négatifs (True Negatives)
TP	les vrais positifs (True Positives)
YOLO	You Only Look Once

Remerciement	
Liste des abréviations	
Table des Matières	
Table des Figures	
Table des Tableaux	

Introduction Générale.....	1
Contexte	1
Problématique de recherche	3
Intérêt et objective de la thèse	4
Chapitre I. Notions générales sur l’incendie et les approches d’analyse d’images	
I.1. Introduction.....	8
I.2. Notions Générales sur l’Incendie.....	8
I.2.1. Définition de l’Incendie	8
I.2.2. Caractéristiques de l’incendie	8
I.2.2.1. Forme	8
I.2.2.2. Couleur.....	9
I.2.2.3. Luminosité	9
I.2.2.4. Fumée.....	9
I.2.3. Types d’Incendie	10
I.2.3.1. Incendies forestiers	10
I.2.3.2. Incendies Industriels	10
I.2.3.3. Incendies Domestiques et Urbains.....	10
I.2.3.4. Incendies de Véhicules.....	10
I.3. Notions de Base en Traitement d’Images et Intelligence Artificielle	11
I.3.1. Traitement d’Images Numérique	11
I.3.2. Classification d’images.....	12
I.3.3. Intelligence Artificielle	14
I.3.4. Apprentissage Automatique (Machine Learning)	15

I.3.4.1. Types d'Apprentissage Automatique	16
I.3.5. Apprentissage Profond (Deep Learning)	16
I.3.5.1. Réseau de Neurones Artificiels (RNA).....	17
I.3.5.2. Réseau de Neurones Convolutif (CNN).....	19
I.4. Conclusion	21

Chapitre II . Fondements Théoriques et Revue de la Littérature

II.1. Introduction	23
II.2. Systèmes de Détection d'Incendies Conventionnelle.....	24
II.2.1. Capteurs de Chaleur.....	24
II.2.1.1. Capteurs de Chaleur Fixes	24
II.2.1.2. Capteurs de Chaleur Différentielle	24
II.2.2. Capteurs de Fumée	25
II.2.3. Capteurs de Gaz.....	25
II.3. Systèmes de Détection d'Incendie basés sur la Vision par Ordinateur	26
II.3.1. Approches Basées sur les Caractéristiques Spectrales.....	27
II.3.2. Techniques de Détection de Mouvement.....	32
II.3.2.1 Différenciation Temporelle.....	32
II.3.2.2 Soustraction de Fond	33
II.3.2.3 Flux Optique	34
II.3.3. Autres Approches utilisés pour la Détection de Flamme	34
II.4. Méthodes de Détection d'Incendie basées sur la Vision par Ordinateur traitées dans la Littérature	35
II.5. Systèmes de Détection d'Incendie basés sur l'Apprentissage Profond	40
II.5.1. Réseaux de Neurones Convolutifs (CNNs)	40
II.5.2. Modèles de Détection d'Objets	40
II.6. Méthodes de Détection d'Incendie basées sur l'Apprentissage Profond traitées dans la Littérature	41

II.7. Lacunes de la recherche.....	43
II.8. Conclusion	44
Chapitre III. Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies	
III.1. Introduction	47
III.2. Collecte et Préparation des Ensembles de Données	47
III.2.1. Collecte et Extraction à Partir de Vidéos Publiques	47
III.2.2. Collecte à Partir de Bases de Données d'Images Publiques	48
III.2.2.1. Ensemble de donnée A : Forestry Images	48
III.2.2.2. Ensemble de donnée B : PyImageSearch	48
III.2.2.3. Ensemble de donnée C : Fismo	51
III.2.2.4. Ensemble de donnée D : Base de données des incendies de GitHub	51
III.2.2.5. Ensemble de donnée E : Google Image	52
III.2.2.6. Ensemble de donnée F : Base de données d'Oliva et de Torralba	52
III.2.3. Augmentation des Données	54
III.2.4. Fractionnement de l'Ensemble de Données	55
III.3. Environnement de Développement des Modèles CNN.....	57
III.4. Approche Proposée.....	58
III.4.1. Détection d'incendie basée sur les CNN	59
III.4.2. Détails de l'architecture proposée pour la détection d'incendie	61
III.4.2.1. CNN_A.....	61
III.4.2.2. CNN_B.....	62
III.4.2.3. CNN_C.....	64
III.4.2.4. CNN_D.....	65
III.4.3. Apprentissage d'Ensemble.....	66

III.5. Conclusion.....	67
------------------------	----

Chapitre IV. Résultats et discussion

IV.1. Introduction	69
IV.2. Résultats et Discussion	69
IV.2.1. Détails des ensembles de tests	69
IV.2.1.1. L'ensemble de test 1 (T-1)	69
IV.2.1.2. L'ensemble de test 2 (T-2).....	70
IV.2.2. Métriques d'évaluation.....	71
IV.2.3. Évaluation des Modèles.....	73
IV.2.4. Comparaison des Résultats et Analyse des Performances.....	80
IV.2.4.1. Comparaison des approches de détection d'incendie existantes sur T-1	81
IV.2.4.2. Comparaison des approches de détection d'incendie existantes sur T-2	81
IV.2.4.3. Analyse de la complexité computationnelle	83
IV.3. Conclusion	87
Conclusion générale	88

Table des Figures

Figure I.1. Représentation des trois éléments constitutifs du triangle du feu ^[1]	9
Figure I.2. Illustration de la structure d'une image numérique : À gauche, une image d'un feu ; à droite, sa version pixelisée.....	12
Figure I.3. Représentation d'une image numérique en niveaux de gris et en couleur (modèle RVB) ..	12
Figure I.4. Classification d'images de feu : (a) méthode d'apprentissage profond, (b)méthode de classification traditionnelle ^[2]	14
Figure I.5. Organisation hiérarchique de l'Intelligence Artificielle et de ses sous-domaines ^[3]	15
Figure I.6. Comparaison entre un neurone biologique (a) et un neurone artificiel (b) ^[4]	18
Figure I.7. Illustration d'un réseau de neurones artificiels comprenant deux couches cachées ^[5]	18
Figure I.8. Illustration d'un exemple de convolution appliqué a une matrice d'entrée ^[6]	20
Figure I.9. Illustration d'un exemple de Max pooling avec un filtre de (2×2) et un pas de 2	20
Figure II.1. Image numérique en niveaux de gris.....	27
Figure II.2. Illustration du modèle de couleur RVB.....	29
Figure II.3. Représentation du Modèle de Couleur HSV. Les lettres R, Y, G, C, B, M font référence respectivement à Rouge (Red), Jaune (Yellow), Vert (Green), Cyan, Bleu (Blue) et Magenta ^[7]	31
Figure II.4. Exemple d'Image Décomposée en ses Composants Y, Cb et Cr	32
Figure III.1. Exemples d'images de feu et de non-feu extraites à partir de vidéos d'incendie.....	49
Figure III.2. Quelques exemples d'images extraites de l'ensemble de données A. (Haut) : Images de feu ; (Bas) : Images sans feu.....	50
Figure III.3. Quelques exemples d'images extraites de l'ensemble de données B. (Haut) : Images de feu ; (Bas) : Images sans feu.....	50
Figure III.4. Quelques exemples d'images extraites de l'ensemble de données C. (Haut) : Images de feu ; (Bas) : Images sans feu.....	51
Figure III.5. Quelques exemples d'images extraites de l'ensemble de données D. (Haut) : Images de feu ; (Bas) : Images sans feu.....	52
Figure III.6. Quelques exemples d'images d'incendie extraites de l'ensemble de données E.	53
Figure III.7. Quelques exemples d'images sans feu extraites de l'ensemble de données F.....	54
Figure III.8. Exemple d'augmentations d'image appliquées à une image d'incendie industrielle.....	55
Figure III.9. Exemple d'augmentations d'image appliquées à une image sans feu.....	55
Figure III.10. Répartition de l'ensemble de Données d'images en sous-ensembles d'entraînement, de Validation et de Test.....	57
Figure III.11. Spécifications du GPU utilisé pour la Formation des Modèles	58
Figure III.12. Détection précoce des Incendies dans les Vidéos de Surveillance à l'aide de CNN	59

Figure III.13. Exemple d'une architecture convnet pour la détection des incendies. Partie convolutionnelle et partie de classification	60
Figure III.14. Représentation matricielle de l'entrée d'un CNN pour une image RVB.....	60
Figure III.15. Description de l'architecture CNN-A pour la Classification des Incendies.....	62
Figure III.16. Description de la structure du modèle CNN_B pour la classification des incendies	63
Figure III.17. Description de la structure du modèle CNN_C pour la classification des incendies	64
Figure III.18. Description de la structure du modèle CNN_D pour la classification des incendies.....	65
Figure IV.1. Exemples d'images illustrant les incendies et les scénarios non-feu de l'ensemble de test 1	70
Figure IV.2. Exemples d'images illustrant les incendies et les scénarios non-feu de.....	71
Figure IV.3. Matrice de confusion des modèles CNN uniques proposés pour la classification des incendies sur T-1. (a) CNN_A, (b) CNN_B, (c) CNN_C, (d) CNN_D	75
Figure IV.4. Matrice de confusion des CNN d'ensemble proposés pour la classification des incendies sur T-1. (a) CNN_AB, (b) CNN_ABC, (c) CNN_ABCD, (d) CNN_ABD, (e) CNN_AC, (f) CNN_ACD, (g) CNN_AD, (h) CNN_BC, (i) CNN_BCD, (j) CNN_BD, (k) CNN_CD	76
Figure IV.5. Matrice de confusion des modèles CNN uniques proposés pour la classification des incendies sur T-2. (a) CNN_A, (b) CNN_B, (c) CNN_C, (d) CNN_D	77
Figure IV.6. Matrice de confusion des CNN d'ensemble proposés pour la classification des incendies sur T-2. (a) CNN_AB, (b) CNN_ABC, (c) CNN_ABCD, (d) CNN_ABD, (e) CNN_AC, (f) CNN_ACD, (g) CNN_AD, (h) CNN_BC, (i) CNN_BCD, (j) CNN_BD, (k) CNN_CD	78
Figure IV.7. Scores de prédiction des algorithmes proposés les plus performants, CNN_C et CNN_BC, sur les images d'incendie difficiles	79
Figure IV.8. Scores de prédiction des algorithmes proposés les plus performants, CNN_C et CNN_BC, sur les images normales difficiles.....	80
Figure IV.9. Comparaison de la complexité computationnelle (MFLOPs).....	86
Figure IV.10. Comparaison de la vitesse de détection sur CPU (FPS)	86
Figure IV.11. Comparaison de la taille des modèles (en mégaoctets).....	87

Table des Tableaux

Tableau I.1. Principaux réseaux profonds ^[8]	17
Tableau II.1. Approches de vision par ordinateur pour la détection d'incendie. Innovations et limites.....	39
Tableau II.2. Approches d'apprentissage en profondeur pour la détection des incendies. Innovations et limites	42
Tableau III.1. Description détaillée de l'architecture du modèle de base (CNN-A), où w = largeur, h = hauteur et n = nombre de canaux	63
Tableau III.2. Description détaillée de l'architecture du modèle CNN-B, où w = largeur, h = hauteur et n = nombre de canaux	64
Tableau III.3. Description détaillée de l'architecture du modèle CNN-C, où w = largeur, h = hauteur et n = nombre de canaux	65
Tableau III.4. Description détaillée de l'architecture du modèle CNN-D, où w = largeur, h = hauteur et n = nombre de canaux	66
Tableau IV.1. Performances de classification obtenues pour les modèles CNN uniques et d'ensemble sur T-1 et T-2. Les meilleurs et deuxièmes meilleurs résultats sont indiqués en rouge gras et deuxièmes meilleurs résultats sont indiqués en noir gras.....	74
Tableau IV.2. Comparaison des performances des modèles proposés CNN_C et CNN_BC avec diverses méthodes de détection d'incendie sur le T-1. Les meilleurs résultats sont indiqués en rouge gras et deuxièmes meilleurs résultats sont indiqués en noir gras.....	82
Tableau IV.3. Comparaison des performances des modèles proposés CNN_C et CNN_BC avec diverses méthodes de détection d'incendie sur le T-2. Les meilleurs résultats sont indiqués en rouge gras et deuxièmes meilleurs résultats sont indiqués en noir gras.....	83
Tableau IV.4. Analyse comparative de la complexité des algorithmes proposés CNN_C et CNN_BC avec la littérature : Mflops, FPS et taille du modèle. Les meilleurs résultats sont indiqués en rouge gras et deuxièmes meilleurs résultats sont indiqués en noir gras.....	85

Introduction Générale

Contexte

L'incendie est une catastrophe grave qui cause chaque année des millions de décès dans le monde ainsi que des milliards de dollars de pertes financières et environnementales. Les industries chimiques utilisent des matières combustibles dans leurs procédés, les vapeurs émises par les combustibles liquides peuvent former avec l'air des mélanges explosifs qui s'enflamme facilement en présence d'une source d'inflammation (étincelle, flamme, surface brûlante...etc). Ces industries peuvent être des sources de risques majeurs pouvant conduire à des incendies. Par exemple, l'incendie qui s'est produit à la raffinerie de Téhéran, la capitale de l'Iran, en 2021, a blessé onze personnes, dont neuf pompiers, après plus de vingt heures de lutte contre le feu^[9]. Durant la même année, des incendies de forêt ont éclaté dans plusieurs pays du monde, y compris les pays africains, les États-Unis et l'Union européenne, entraînant des pertes humaines et la destruction de l'environnement écologique ^[10]. L'Algérie a été fortement touchée par les incendies de forêts, en particulier durant l'été 2021, où de vastes superficies forestières du nord du pays ont été ravagées. Selon la Direction Générale des Forêts, plus de 100 000 hectares de couvert végétal ont été détruits à travers 21 wilayas, principalement dans celle de Tizi Ouzou et de Béjaïa. Ces incendies ont eu des conséquences néfastes sur la biodiversité, l'économie locale et la sécurité des populations^[11]. D'autre part, entre 2016 et 2018, plus de 129 000 incendies ont éclaté dans la région sud-coréenne, causant 1 020 décès et plus de 2 milliards de dollars de dommages financiers^[12]. En outre, selon le Système national de données sur les incendies, entre janvier 2023 et 2024, les incendies ont détruit 25 044 bâtiments à travers le monde, entraînant 232 décès, 1 765 blessés, et environ 483 millions de dollars de pertes matérielles.

Par conséquent, Il est nécessaire de maîtriser des systèmes de détection d'incendies à des stades précoces avec une précision élevée, afin de réduire les risques de cette catastrophe. Dans ce contexte, les chercheurs ont développé diverses approches de détection d'incendie afin de contrôler le feu et réduire les dommages liés aux incendies. Ces approches peuvent être classées en trois grandes catégories : les technologies de détection d'incendie conventionnelle (CFD), les systèmes de détection d'incendie basés sur la vision par ordinateur (CV) et les systèmes de détection basés sur l'apprentissage profond (DL).

Concernant les méthodes de détection d'incendie conventionnel, plusieurs chercheurs ont étudié ces systèmes. Ils utilisent des capteurs physiques populaires tels que les capteurs de fumée et de chaleur. Ces types de capteurs sont largement utilisés dans le domaine de détection d'incendies et de fumée, mais ils présentent plusieurs inconvénients :

(1) dans les zones urbaines telles que les bâtiments, les détecteurs de fumée sont généralement placés dans les plafonds^[12] ce qui nécessite un temps pour que la fumée atteigne le capteur pour émettre un signal sonore^[13]. Ce déclenchement tardif de l'alarme entraîne des pertes importantes. Par exemple, Parmi les décès d'incendies à domicile, 50% des victimes sont handicapées, hospitalisées ou dans un état grave, Ces personnes ont besoin d'une alerte précoce pour la fuite avant la propagation de l'incendie^[14].

(2) Ces types de capteurs sont incapables de détecter l'emplacement de l'incendie sans intervention humaine^[13].

(3) les capteurs conventionnels sont limités dans les grands espaces^[12] et incapables de faire la différence entre un feu réel et la fumée ce qui a augmenté le taux des fausses alarmes^[15].

La limitation de ces types de dispositifs annule l'intérêt d'une détection précoce et efficace d'incendie. Par conséquent, des efforts importants ont été déployés par les chercheurs afin de trouver des solutions aux problèmes cités ci-dessus et d'améliorer la précision de détection.

La vidéosurveillance intelligente a connu une croissance plus rapide cette dernière décennie en utilisant des vidéos issues de caméras de surveillance pour la détection, la surveillance, la reconnaissance et le suivi automatiques. Elle possède une grande variété d'applications, intérieur et extérieur, telles que : la sécurité domestique, le contrôle du trafic, la détection des accidents, la détection des catastrophes.. etc.^[16]. Ceci a encouragé les chercheurs à développer des systèmes de détection d'incendie par vision par ordinateur en développant des algorithmes qui permettent d'identifier le feu par analyse des données acquises par les caméras de surveillance dans divers endroits, tels que les zones urbaines, les industries, les voitures et les forêts en utilisant des techniques de traitement d'images^[15].

Les premières technologies de détection d'incendie par les capteurs visuels utilisent des informations de couleur (par exemple les espaces RGB ou HSV), et de mouvements (par exemple variations temporelles ou Soustraction de Fond) afin d'identifier les régions candidates

au feu. Ces caractéristiques sont ensuite converties en vecteurs numériques et utilisées comme entrées dans un classificateur (SVM, k-NN, etc.) qui permet de décider la présence ou l'absence du feu dans l'image/vidéo. Bien que ces approches ont permis d'améliorer la précision par rapport aux capteurs conventionnels, mais le taux de fausses alarmes restes toujours élevé car la majorité de ces systèmes sont basé sur des systèmes chromatiques qui sont sensible aux variations de luminosité et d'éclairage notamment pour les scènes complexe tel que : le coucher du soleil, et des objets en mouvement de couleur rouge, qui peuvent être confondus avec des flammes. De plus, la mise en œuvre de ces méthodes nécessite des experts pour sélectionner les caractéristiques pertinentes, définir les paramètres adaptés et ajuster le classificateur.

Après le succès des architectures d'apprentissage profond, en particulier les réseaux de neurones convolutif (CNN), dans le domaine de la classification d'images et la détection d'objets, les scientifiques utilisent ces algorithmes pour des tâches de détection d'incendie. Les approches basées sur les CNN sont capables d'apprendre automatiquement les représentations de caractéristiques directement à partir des données d'entrée contrairement aux algorithmes traditionnels qui nécessitent le besoin de méthodes manuelles pour l'extraction des caractéristiques. Plusieurs chercheurs ont utilisé des modèles CNN préentraînés tels qu'Alex Net^[17], Google Net^[18] et VGG16^[19] pour la détection d'incendie. Les couches profondes de ces réseaux sont déjà entraînées à extraire les caractéristiques d'image, ce qui facilite la tâche de détection du feu même en utilisant de petits ensembles de données pour l'entraînement. D'autres recherches dans ce domaine sont basées sur des approches de détection d'incendie en deux étapes telles que RCNN et YOLO. Cependant, malgré leurs performances, ces modèles avec des architectures très profonds restent confrontés à plusieurs contraintes ce qui limite leur déploiement dans des environnements réels. Ceci ouvre la voie à de nouvelles recherches visant à concevoir des modèles plus efficaces, capables de garantir un équilibre entre la précision, la rapidité de détection et la simplicité de calcul.

Problématique de recherche

La majorité des approches récentes de détection d'incendie reposent sur des architectures extrêmement profondes. Bien que ces modèles offrent de bonnes performances de classification, ils présentent plusieurs limites majeures :

- * une complexité computationnelle élevée, nécessitant des ressources matérielles puissantes pour l'entraînement des algorithmes.

* une taille de mémoire importante, ce qui limite leur déploiement sur des dispositifs embarqués et des systèmes IoT,

* Les incendies se propagent généralement rapidement lorsqu'il y a des matériaux inflammables, par exemple, dans les bâtiments ou les forêts. Par conséquent, une détection rapide des incendies réduira efficacement les pertes humaines et matérielles. Cependant, les modèles coûteux en calcul nécessitent un temps de traitement prolongé qui n'est pas adapté à une détection rapide

Par conséquent, le principal problème de cette recherche consiste à trouver un équilibre entre la précision, le temps de traitement et la taille des modèles, afin de concevoir des systèmes de détection d'incendie fiables et exploitables dans des environnements réels disposant de ressources limitées.

Objectifs et contributions

L'objectif principal de cette thèse est de développer un système de détection d'incendie performant et léger, capable d'être déployé dans des environnements contraints, en comblant les lacunes de recherche identifiées. Pour atteindre cet objectif, ce travail vise à :

(1) Premièrement, contrairement aux travaux récents qui utilisent des architectures très profondes, les auteurs proposent quatre CNN efficaces, légers et économes en énergie, avec un nombre limité de paramètres d'entraînement (pas plus de 2,83 M), pour classer et détecter les incendies dès leurs premiers stades. De plus, une nouvelle approche d'assemblage de CNN est introduite dans cette thèse, qui combine les prédictions de ces quatre réseaux afin d'optimiser la précision de la détection d'incendie et de réduire les taux d'erreurs.

(2) Deuxièmement, comme les réseaux profonds nécessitent un grand ensemble de données pour l'entraînement, afin de créer un ensemble diversifié donnant de meilleures performances de détection d'incendie, les auteurs ont collecté des images/vidéos d'incendies à partir de bases de données publiques, de travaux précédents ainsi que de vidéos d'incendie sur YouTube et Facebook.

(3) Troisièmement, la méthodologie proposée a été testée sur deux bases de données de référence difficiles^[20,21]. Les résultats montrent l'efficacité de l'approche introduite en termes de précision et de réduction du taux de fausses alarmes. De plus, une comparaison de l'approche avec les meilleurs modèles existants, en termes de complexité computationnelle, montre que

les CNN proposés mettent en évidence un meilleur compromis entre l'intensité de calcul, la vitesse de détection et la taille du modèle, et qu'ils peuvent également être déployés efficacement dans des environnements disposant de ressources limitées.

Cette thèse est structurée autour de quatre chapitres principaux :

Chapitre I - le premier chapitre, décrit les bases théoriques liées à l'incendie ainsi qu'aux approches d'analyse d'images. Il commence par présenter les notions fondamentales liées à l'incendie, notamment sa définition, ses principales caractéristiques, ainsi que les différents types d'incendies tels que les feux de forêts, les incendies industriels, domestiques et de véhicules. Ensuite, une partie est consacrée aux notions de base en traitement d'images et en intelligence artificielle. Les concepts essentiels du traitement d'images numériques, de la classification d'images et des approches d'intelligence artificielle sont introduits. Cette section met également en évidence les méthodes d'apprentissage automatique et d'apprentissage profond, en décrivant plus particulièrement les réseaux de neurones artificiels et les réseaux de neurones convolutifs (CNN), qui constituent la base des approches modernes de détection d'incendie.

Chapitre II – le deuxième chapitre présente le cadre théorique et la revue de la littérature liée à la détection d'incendies. Dans un premier temps, les systèmes de détection conventionnels, tels que les capteurs de chaleur, de fumée et de gaz sont présentés. Ensuite, il expose les approches basées sur la vision par ordinateur, en détaillant les méthodes fondées sur les caractéristiques spectrales, l'analyse du mouvement utilisées pour la détection des flammes. Par la suite, une attention particulière est accordée aux méthodes récentes basées sur l'apprentissage profond. Enfin, ce chapitre met en évidence les travaux existants dans la littérature, identifie les limites des approches actuelles et souligne les lacunes de recherche qui motivent les contributions proposées dans cette thèse.

Chapitre III - le troisième chapitre présente la méthodologie adoptée pour le développement d'un ensemble de CNN légers destinés à la détection d'incendies. Il commence par la présentation des ensembles de données utilisés, incluant les étapes de collecte, d'augmentation et de préparation des données pour l'entraînement et le test. Ensuite, l'environnement de développement est détaillé, suivi de la description de l'approche proposée. Quatre architectures CNN (CNN_A, CNN_B, CNN_C et CNN_D) sont conçues et présentées, chacune avec ses caractéristiques propres. Enfin, la stratégie d'apprentissage d'ensemble est présentée, afin d'optimiser les performances du système de détection.

Chapitre IV - le quatrième chapitre est consacré à l'évaluation expérimentale des modèles CNN développés. Les ensembles de tests utilisés et les métriques d'évaluation choisies sont d'abord décrits. Ensuite, les résultats obtenus par chaque modèle sont présentés et analysés en détail. Une comparaison des performances avec d'autres approches existantes est effectuée, en mettant l'accent sur la précision, la robustesse et la complexité computationnelle. Ce chapitre montre la capacité des modèles proposés à répondre efficacement au problème de détection d'incendie

Enfin, une conclusion est proposée à la fin du travail.

Chapitre I

Notions générales sur l'incendie et les approches d'analyse d'images

Sommaire du chapitre :

I.1. Introduction.....	8
I.2. Notions Générales sur l'Incendie.....	8
I.2.1. Définition de l'Incendie	8
I.2.2. Caractéristiques de l'incendie	8
I.2.2.1. Forme	8
I.2.2.2. Couleur.....	9
I.2.2.3. Luminosité	9
I.2.2.4. Fumée.....	9
I.2.3. Types d'Incendie	10
I.2.3.1. Incendies forestiers	10
I.2.3.2. Incendies Industriels	10
I.2.3.3. Incendies Domestiques et Urbains.....	10
I.2.3.4. Incendies de Véhicules.....	10
I.3. Notions de Base en Traitement d'Images et Intelligence Artificielle	11
I.3.1. Traitement d'Images Numérique	11
I.3.2. Classification d'images.....	12
I.3.3. Intelligence Artificielle	14
I.3.4. Apprentissage Automatique (Machine Learning)	15
I.3.4.1. Types d'Apprentissage Automatique	16
I.3.5. Apprentissage Profond (Deep Learning)	16
I.3.5.1. Réseau de Neurones Artificiels (RNA).....	17
I.3.5.2. Réseau de Neurones Convolutif (CNN).....	19
I.4. Conclusion	21

I.1. Introduction

Dans ce chapitre, nous présentons les notions de base nécessaires à la compréhension de ce travail. Nous abordons d'une part les généralités sur l'incendie et ses principales caractéristiques, et d'autre part les concepts fondamentaux liés au traitement d'images, et à l'intelligence artificielle.

I.2. Notions Générales sur l'Incendie

I.2.1. Définition de l'Incendie

Un incendie peut être défini comme une combustion violente et non maîtrisée, se propageant dans le temps et dans l'espace, susceptible de provoquer des dommages considérables aux personnes, aux biens et ainsi qu'à l'environnement. Sur le plan scientifique, il s'agit d'une réaction chimique exothermique qui nécessite la présence simultanée de trois éléments fondamentaux pour être initié et maintenu : un combustible, un comburant (généralement l'oxygène présent dans l'air) et une source de chaleur (ou énergie d'activation). Ces trois composantes sont généralement connues sous le nom de « triangle du feu »^[22] comme illustré dans la Figure I.1. En effet, la réaction de combustion ne peut déclencher et se poursuivre que si ces trois éléments interagissent dans des conditions favorables. L'élimination ou l'absence de l'un d'entre eux empêche l'apparition de l'incendie ou entraîne son extinction lorsqu'il est déjà déclaré.

I.2.2. Caractéristiques de l'incendie

L'incendie présente un ensemble de caractéristiques physiques et visuelles qui peuvent être exploitées pour sa détection. Parmi elles, certains sont particulièrement pertinents dans l'analyse d'images, car ils constituent des indices discriminants permettant de différencier le feu d'autres phénomènes visuels. Une analyse plus détaillée des mécanismes physiques de la combustion, ainsi que les caractéristiques dynamiques de la flamme, sont présentée en Annexe A.

I.2.2.1. Forme




Figure I.1. Représentation des trois éléments constitutifs du triangle du feu ^[1]

La flamme ne possède pas une forme fixe, mais se caractérise par une évolution rapide et instable. Ses contours sont généralement irréguliers et oscillants, ce qui traduit la nature dynamique du phénomène. On observe généralement une morphologie triangulaire, avec une base large qui s'amincit vers la pointe. Cette géométrie est fortement influencée par divers facteurs tels que la vitesse et la direction du vent ainsi que les conditions environnementales ^[3].

I.2.2.2. Couleur

Le feu présente généralement des couleurs situées dans les régions rouge, orange et jaune du spectre visible. Ces teintes proviennent de la combustion incomplète de la matière organique. En revanche, lors d'une combustion complète, une couleur bleue peut apparaître. Ces variations chromatiques constituent des indicateurs essentiels pour l'identification du feu dans les images^[3].

I.2.2.3. Luminosité

Le feu est une source de lumière intense qui se caractérise par des variations rapides d'intensité dues à la combustion. Ces changements lumineux constituent ainsi un indicateur pertinent pour différencier le feu d'autres phénomènes visuels^[23].

I.2.2.4. Fumée

En plus des flammes, l'incendie produit souvent de la fumée, qui se caractérise par une couleur allant du gris clair au noir, et une dynamique ascendante. La présence de flammes et de fumée renforce la fiabilité de la détection^[23].

I.2.3. Types d'Incendie

Les incendies peuvent se manifester dans divers environnements et présentent des caractéristiques particulières selon le milieu dans lequel ils se produisent. On peut notamment distinguer :

I.2.3.1. Incendies forestiers

Ils constituent l'une des catastrophes naturelles les plus destructrices, avec des impacts majeurs sur l'environnement, l'économie et la santé humaine. Ils peuvent être déclenchés par des causes naturelles (foudre, vagues de chaleur prolongées) ou, plus fréquemment, par des activités humaines (imprudences, actes criminels), leur propagation est fortement influencée par les conditions météorologiques (température, vent, humidité) et la disponibilité du combustible végétal. Ces incendies entraînent des pertes économiques considérables, la dégradation des sols et une pollution atmosphérique importante ^[24,25].

I.2.3.2. Incendies Industriels

Ils surviennent dans les usines, raffineries ou sites pétrochimiques, où la présence de liquides inflammables, de gaz et de produits chimiques accroît leur intensité et leur dangerosité. Les conséquences peuvent être graves, allant des pertes matérielles aux risques majeurs pour les habitants des zones adjacentes ainsi que pour les travailleurs de l'industrie ^[26].

I.2.3.3. Incendies Domestiques et Urbains

Ils concernent les habitations et les infrastructures urbaines, et sont souvent liés à des défaillances électriques, à l'usage d'appareils de chauffage, à la négligence humaine ou à des comportements imprudents ^[27].

I.2.3.4. Incendies de Véhicules

Les incendies de véhicules constituent une catégorie particulière d'incendies qui concernent les automobiles, camions, bus ou autres moyens de transport. Ils sont généralement déclenchés par des courts-circuits électriques, des fuites de carburant, des surchauffes mécaniques ou à la suite d'accidents de circulation. La présence de réservoirs de carburant, de batteries, de plastiques et de matériaux synthétiques rend ces incendies particulièrement dangereux, car ils peuvent entraîner des explosions et dégager des fumées toxiques. Leur fréquence en milieu urbain et routier en fait un enjeu majeur de sécurité publique et de prévention ^[28].

I.3. Notions de Base en Traitement d'Images et Intelligence Artificielle

I.3.1. Traitement d'Images Numérique

Le traitement d'images numérique désigne l'ensemble des techniques appliquées à une image numérique, dans le but de l'améliorer, de réduire sa taille, ou d'extraire des informations pertinentes. Il s'agit d'analyse visuelle assistée par ordinateur s'effectuant sur les pixels de l'image, en utilisant des algorithmes mathématiques adaptés aux objectifs visés. Le traitement d'images numériques peut être divisé en plusieurs domaines. Le premier concerne la restauration d'image, dont l'objectif est de corriger les défauts visuels tels que le bruit et le flou, ou d'améliorer la qualité de l'image en jouant sur le contraste et la netteté. La deuxième catégorie est l'analyse d'image, qui vise à extraire des informations à partir de l'image, telles que les formes, les textures, ou les régions d'intérêt, pour les systèmes de reconnaissance, de classification ou de détection automatique. Enfin, une troisième catégorie est le codage et la compression, qui visent à réduire la taille des fichiers image tout en maintenant une qualité visuelle acceptable. Cela permet d'optimiser le stockage et la transmission des images, notamment dans les systèmes temps réel ^[29].

Une image numérique est une représentation visuelle stockée sous forme de données numériques. Elle est composée d'un ensemble d'éléments appelés pixels comme illustré dans la Figure I.2. Mathématiquement, les images numériques sont dites matricielles, car elles sont représentées sous forme de matrices de nombres. Ces nombres traduisent des informations telles que l'intensité lumineuse pour les images en niveaux de gris. Pour les images en couleur, plusieurs couches rouge, vert et bleu (système RVB) sont combinées, dont l'ensemble, forment une image en couleur. La Figure I.3 illustre la structure d'une image numérique. En haut, l'image de feu est représentée en niveaux de gris, avec une matrice indiquant l'intensité lumineuse de chaque pixel (valeurs entre 0 et 255). En bas, la même image est affichée en couleur selon le modèle RVB. Elle est décomposée en trois canaux : Rouge (R), Vert (V) et Bleu (B), chacun est représenté sous forme d'une matrice. La combinaison des valeurs des trois canaux permet de reconstituer la couleur finale de chaque pixel. La définition d'une image

correspond au nombre total de pixels qu'elle contient, exprimé par ses dimensions en largeur $\times$ hauteur (par exemple : 1920 $\times$ 1080 pixels).




Figure I.2. Illustration de la structure d'une image numérique : À gauche, une image d'un feu ; à droite, sa version pixélisée




Figure I.3. Représentation d'une image numérique en niveaux de gris et en couleur (modèle RVB)

Le traitement d'images est utilisé dans de nombreuses applications telles que la médecine, l'astronomie, la télédétection, l'industrie, ou encore la sécurité. Dans le cadre de ce travail, le traitement numérique d'images constitue une phase essentielle à la détection d'incendies. Il permet une analyse visuelle des données par des modèles d'apprentissage profond, notamment les réseaux de neurones convolutifs, qui assurent la classification finale.

I.3.2. Classification d'images

La classification d'images est une tâche fondamentale en traitement d'images et en vision par ordinateur. Elle consiste à affecter à chaque image une étiquette correspondante à une

Chapitre I : Notions générales sur l'incendie et les approches d'analyse d'images

catégorie prédéfinie. Cela implique généralement deux étapes principales : l'extraction de caractéristiques pertinentes à partir de l'image, puis l'utilisation d'un classificateur pour prédire la classe à laquelle elle appartient. Dans une image numérique, chaque pixel est caractérisé par des valeurs numériques représentant des informations comme la couleur, l'intensité, ou la texture. Le processus de classification repose sur l'analyse de ces valeurs afin de distinguer différentes classes visuelles ^[30]

Dans le cadre de la détection d'incendie, la classification d'images joue un rôle clé. L'objectif est d'attribuer une catégorie précise à chaque image analysée : "feu" ou "non feu". Cela permet de déterminer automatiquement si une scène contient un incendie ou non, en se basant uniquement sur son contenu visuel. Une classification correcte permet d'alerter rapidement en cas d'incendie et de réduire les fausses alarmes.

Les méthodes traditionnelles de classification utilisaient des caractéristiques de bas niveau, telles que la couleur (les tons rouge-orangé associés aux flammes), la texture ou la forme. Ces caractéristiques sont extraites manuellement par des experts en utilisant des modèles mathématiques avant d'être introduites dans un classificateur (SVM, KNN, etc.), comme illustré dans la Figure I.4 (b). Ce processus, bien qu'efficace dans certains cas, reste limité car il dépend fortement du choix du modèle utilisé (espaces de couleur tels que RVB ou HSI, méthodes de détection de mouvement comme la différentiation d'arrière-plan, etc.), ce qui peut réduire la robustesse face aux variations réelles des images (luminosité, arrière-plan complexe, etc.). L'introduction des réseaux de neurones convolutifs (CNN) a révolutionné cette tâche en permettant l'extraction automatique de caractéristiques complexes et hiérarchiques directement à partir des images brutes comme illustré dans la Figure I.4 (a). Les couches de convolution apprennent à détecter des motifs simples (bords, couleurs, textures) dans les premières couches, puis des représentations plus abstraites et complexes dans les couches profondes, ce qui améliore considérablement la performance et la fiabilité des systèmes de détection d'incendie.




Figure I.4. Classification d'images de feu : (a) méthode d'apprentissage profond, (b) méthode de classification traditionnelle ^[2]

I.3.3. Intelligence Artificielle

L'intelligence artificielle (IA) est un domaine de l'informatique qui a débutée dans les années 1950, elle vise à concevoir des systèmes capables d'exécuter des tâches nécessitant des capacités humaines, telles que le raisonnement, la prise de décision, la compréhension du langage...etc. Au début, les approches de l'IA reposaient principalement sur des règles programmées manuellement (appelées IA symbolique), où les connaissances étaient représentées sous forme d'un ensemble de règles explicites élaborées par les programmeurs. Mais cette approche avait des limites face à des situations plus complexes, comme la reconnaissance d'images ou de la parole. Grâce à la disponibilité des données numériques et l'augmentation de la puissance de calcul, de nouvelles méthodes comme l'apprentissage automatique et l'apprentissage profond ont permis à l'IA d'apprendre directement à partir des données ^[31]. En ce sens, L'intelligence artificielle constitue un domaine vaste qui englobe l'apprentissage automatique inclut à son tour l'apprentissage profond, mais aussi d'autres approches qui ne reposent pas nécessairement sur l'apprentissage comme illustré dans la Figure I.5 ^[3].




Figure I.5. Organisation hiérarchique de l'Intelligence Artificielle et de ses sous-domaines ^[3]

I.3.4. Apprentissage Automatique (Machine Learning)

L'apprentissage automatique (ML) est un sous-domaine de l'intelligence artificielle. Son objectif est de concevoir des algorithmes capables d'apprendre à partir des données et de l'expérience, sans être programmés explicitement pour chaque tâche. Autrement dit, il s'agit de donner à un système la capacité d'extraire des connaissances de manière autonome et d'adapter son comportement en fonction de nouvelles informations, d'une façon analogue à l'apprentissage humain. ^[3]. Reposant sur des disciplines variées telles que la statistique, la probabilité et l'informatique, plusieurs algorithmes du ML sont particulièrement utilisés dans l'exploration et l'analyse de données, notamment les arbres de décision, les réseaux de neurones, les machines à vecteurs de support (SVM) ainsi que l'algorithme des k plus proches voisins (k-NN). Ces méthodes se distinguent par leur capacité à traiter efficacement de grandes quantités d'informations et à fournir des résultats fiables dans divers contextes ^[32].

Parmi les applications les plus courantes de l'apprentissage automatique, on peut citer, la décision d'acceptation ou de refus d'un prêt bancaire, la reconnaissance d'images, de la parole et du texte, la détection de pannes dans un système, la détection d'anomalies telles que le cancer à partir d'images médicales, ainsi que la détection d'incendie qui constitue une application cruciale dans le champ de la sécurité. Ces applications mettent en évidence la capacité de l'apprentissage automatique à s'adapter à des contextes variés, allant de la santé et de la finance jusqu'à la sécurité^[31].

I.3.4.1. Types d'Apprentissage Automatique

L'apprentissage automatique peut être divisé en plusieurs catégories, parmi lesquelles on distingue principalement l'apprentissage supervisé et l'apprentissage non supervisé.

➤ Apprentissage Supervisé

L'apprentissage supervisé utilise des données d'entrée accompagnées de leurs étiquettes. Chaque exemple de l'ensemble de données possède une classe correcte connue à l'avance. Le modèle apprend à associer les entrées aux sorties en ajustant progressivement ses paramètres pour réduire l'erreur. Ce type d'apprentissage est très utilisé dans les tâches de classification (par exemple feu / non-feu) et de régression.

➤ Apprentissage Non Supervisé

Dans l'apprentissage non supervisé, les données ne possèdent pas d'étiquettes. Le modèle doit découvrir seul des relations entre les données. Ce type d'apprentissage est souvent utilisé pour des tâches telles que le clustering, la réduction de dimensionnalité ou la détection d'anomalies, et permet d'analyser et d'organiser les données sans supervision humaine.

I.3.5. Apprentissage Profond (Deep Learning)

L'apprentissage profond (DL) est une approche avancée de l'apprentissage automatique qui repose sur l'utilisation des réseaux de neurones artificiels, inspirés du fonctionnement des neurones biologiques du cerveau humain pour l'analyse et l'apprentissage. Ces modèles sont composés de plusieurs couches hiérarchiques, chacune correspond à un niveau différent d'abstraction.

Contrairement aux approches classiques de l'apprentissage automatique, où l'extraction des caractéristiques est réalisée manuellement avant la phase de classification, le Deep Learning intègre ces étapes dans un seul réseau, ce qui améliore la précision et réduit la dépendance aux techniques manuelles de prétraitement. Grâce à sa capacité à traiter de grandes quantités de données et à en extraire des représentations pertinentes, le DL a permis des avancées majeures dans de nombreux domaines, produisant souvent des résultats supérieurs, à ceux des approches traditionnelles ^[3,31].

Les méthodes d'apprentissage profond peuvent être regroupées en plusieurs catégories, comme indiqué dans le Tableau I.1. Parmi elles, les plus utilisées sont les approches supervisées, comme les réseaux de neurones convolutifs (CNN), les réseaux récurrents (RNN)

Chapitre I : Notions générales sur l'incendie et les approches d'analyse d'images

ou encore les réseaux génératifs adversariaux (GAN) ; les approches non supervisées, comme les autoencodeurs (AE) et les réseaux de croyance profonde (DBN)^[33]. Cependant, pour le traitement des données visuelles, les réseaux de neurones convolutifs (CNN) se distinguent par leurs performances remarquables. Grâce à leur capacité à extraire automatiquement des caractéristiques hiérarchiques et discriminantes à partir des images. Dans ce qui suit, nous nous intéressons plus particulièrement aux CNN, qui constituent le cœur de notre approche pour la détection d'incendies

Tableau I.1. Principaux réseaux profonds ^[8]

Catégorie	Réseaux /Techniques	Utilisation
Supervisé	CNN (AlexNet, VGG, GoogLeNet, Unet, ResNet , etc.) , RNN (LSTM,), GAN	✓ Classification d'images ✓ Génération de données ✓ Reconnaissance de formes
Non Supervisé	Autoencodeurs (AE), Réseaux de croyance profonde (DBN).	✓ Extraction automatique de caractéristiques ✓ Réduction de dimension ✓ Détection d'anomalies

I.3.5.1. Réseau de Neurones Artificiels (RNA)

Le cerveau humain peut analyser rapidement une image et en extraire une multitude d'informations (scène, identité des personnes, leurs actions, etc.). Cette capacité repose sur le système nerveux, composé d'unités élémentaires appelées neurones, selon la doctrine du neurone de Cajal ^[34]. Un neurone est constitué de « dendrites » (voies d'entrée), d'un « corps cellulaire », d'un « axone » (voie de sortie) ainsi que de « synapses » (zones de contact entre les neurones) ^[35].

Pour s'inspirer de ce modèle biologique, les chercheurs ont conçu le « neurone artificiel », qui constitue l'unité de base des réseaux de neurones. Celui-ci reçoit plusieurs entrées « X_n », chacune multipliée par un poids « W_n ». Ces valeurs sont additionnées pour former une somme, laquelle est ensuite transmise à une fonction d'activation afin de générer une sortie. L'équation fondamentale d'un réseau de neurones artificiels est présentée en Annexe B. Les fonctions de transfert les plus utilisées sont « Sigmoid », « Tanh », « ReLU » et « Softmax », selon la nature du problème et le type de données traitées. En connectant un grand nombre de neurones artificiels entre eux, on obtient un modèle mathématique appelé « réseau

Chapitre I : Notions générales sur l'incendie et les approches d'analyse d'images

de neurones artificiels », capable d'analyser des données et d'identifier des motifs complexes ^[33].

La Figure I.6 illustre, à gauche, un neurone biologique et, à droite, un neurone artificiel, permettant de mettre en évidence l'analogie entre leurs structures et leurs fonctions.

Un réseau de neurones artificiels est une architecture constituée d'un grand nombre de neurones artificiels interconnectés, ou chaque neurone d'une couche est relié à tous les neurones de la couche précédente. Un RNA comprend généralement une couche d'entrée, plusieurs couches cachées et une couche de sortie, comme illustré dans la Figure I.7. La couche d'entrée reçoit les données brutes, ensuite chaque couche intermédiaire traite et transmet les informations issues de la couche précédente. Enfin, la couche de sortie produit le résultat final du système ^[5]




Figure I.6. Comparaison entre un neurone biologique (a) et un neurone artificiel (b) ^[4]




Figure I.7. Illustration d'un réseau de neurones artificiels comprenant deux couches cachées ^[5]

I.3.5.2. Réseau de Neurones Convolutif (CNN)

Les réseaux de neurones convolutifs (CNN) représentent une évolution des réseaux de neurones artificiels, conçue spécifiquement pour le traitement et l'analyse des images. Ils sont constitués de plusieurs couches organisées de manière hiérarchique, où chaque couche extrait progressivement des caractéristiques de plus en plus abstraites. La structure d'un CNN peut être divisée en deux parties principales : partie extraction des caractéristiques, assurée par les couches de convolution et de pooling, et partie classification, réalisée par les couches entièrement connectées [36].

Lors d'une tâche de classification d'images, une image d'entrée du réseau, traverse successivement plusieurs étapes de convolution et de pooling. Les représentations obtenues sont ensuite transmises à des couches entièrement connectées, qui produisent l'étiquette de la classe correspondante [37].

➤ Couche de Convolution

Dans les réseaux de neurones convolutifs (CNN), la convolution est une opération fondamentale qui permet d'extraire des caractéristiques visuelles d'une image, telles que les bords, les textures ou les formes, en faisant glisser un filtre (ou noyau de convolution) sur l'image [37]. Une image d'un feu, par exemple, est reconnue par l'œil humain grâce à des éléments perceptibles comme la luminosité, la taille et les contours. En revanche, pour un ordinateur, cette image n'est qu'une matrice de nombres. Ainsi, la convolution est nécessaire pour transformer cette représentation numérique en informations pertinentes [38].

Prenons l'exemple d'une image de taille (5×5) et d'un filtre de dimension (3×3) se déplaçant sur l'image avec un pas (stride) de 1. À chaque déplacement, les valeurs du noyau sont multipliées élément par élément avec celles de la portion correspondante de l'image, puis additionnées. Après le passage du filtre sur l'ensemble de l'image, on obtient une nouvelle représentation appelée carte de caractéristiques (feature map) de taille (3×3) comme illustré dans la Figure I.8. Chaque valeur de cette nouvelle matrice traduit la correspondance entre le filtre et la portion de l'image analysée. L'utilisation de plusieurs filtres de convolution génère différentes cartes de caractéristiques. Cela offre une représentation plus riche et hiérarchique de l'image, tout en réduisant la complexité des données, ce qui facilite les tâches de reconnaissance et de classification [39].




Figure I.8. Illustration d'un exemple de convolution appliquée à une matrice d'entrée [6]

➤ Couche de Pooling

Dans les CNN, une couche de pooling est souvent ajoutée entre les couches de convolution. Cette couche, a pour rôle de réduire la dimension des cartes de caractéristiques tout en conservant les informations essentielles. Elle permet de limiter la complexité du modèle et d'éviter le surapprentissage. L'opération la plus utilisée est le « max-pooling », le filtre glisse le long de la matrice. À chaque déplacement, la valeur maximale dans la région couverte par le filtre est utilisée comme élément de la matrice résultante. Cette opération conserve les caractéristiques les plus représentatives, comme les contours ou les zones lumineuses dans une image d'incendie, tout en réduisant le volume des données à traiter. Par exemple, nous effectuons un max pooling sur une matrice (4×4). La taille du filtre est de (2×2), la taille du pas est fixée à 2, et répétez ce processus jusqu'à ce que le filtre parcoure toute la matrice. Le processus de pooling est illustré dans la Figure I.9




Figure I.9. Illustration d'un exemple de Max pooling avec un filtre de (2×2) et un pas de 2

➤ Couche Entièrement Connectée (Fully Connected Layer)

Après les couches de convolution et de pooling, les cartes de caractéristiques obtenues sont aplaties en un vecteur. Ce vecteur est ensuite transmis à une ou plusieurs couches entièrement connectées. Chaque neurone de ces couches est relié à tous les neurones de la couche précédente, ce qui permet d'effectuer la classification finale. Dans le cas de la détection d'incendie, ces couches servent à déterminer si une image donnée correspond à une scène contenant un feu ou non.

I.4. Conclusion

Après avoir présenté les bases du phénomène d'incendie ainsi que les principes fondamentaux de l'intelligence artificielle et de la classification automatique, le chapitre suivant présente les différentes méthodes de détection d'incendie proposées dans la littérature, depuis les approches traditionnelles jusqu'aux solutions récentes basées sur l'apprentissage profond

Chapitre II

Fondements Théoriques et Revue de la Littérature

Sommaire du chapitre

II.1. Introduction	23
II.2. Systèmes de Détection d'Incendies Conventionnelle.....	24
II.2.1. Capteurs de Chaleur.....	24
II.2.1.1. Capteurs de Chaleur Fixes	24
II.2.1.2. Capteurs de Chaleur Différentielle	24
II.2.2. Capteurs de Fumée	25
II.2.3. Capteurs de Gaz.....	25
II.3. Systèmes de Détection d'Incendie basés sur la Vision par Ordinateur	26
II.3.1. Approches Basées sur les Caractéristiques Spectrales.....	27
II.3.2. Techniques de Détection de Mouvement.....	32
II.3.2.1 Différenciation Temporelle.....	32
II.3.2.2 Soustraction de Fond	33
II.3.2.3 Flux Optique	34
II.3.3. Classificateurs utilisés pour la Détection de Flamme	34
II.4. Méthodes de Détection d'Incendie basées sur la Vision par Ordinateur traitées dans la Littérature	35
II.5. Systèmes de Détection d'Incendie basés sur l'Apprentissage Profond	40
II.5.1. Réseaux de Neurones Convolutifs (CNNs)	40
II.5.2. Modèles de Détection d'Objets	40
II.6. Méthodes de Détection d'Incendie basées sur l'Apprentissage Profond traitées dans la Littérature	41
II.7. Lacunes de la recherche.....	43
II.8. Conclusion	44

II.1. Introduction

Au fil du temps, de nombreuses technologies de détection d'incendie ont évolué grâce aux progrès des capteurs, de l'informatique et à l'utilisation de différents algorithmes d'apprentissage profond. Certaines de ces méthodes sont encore utilisées aujourd'hui, tandis que d'autres deviennent obsolètes. Ce chapitre explore une chronologie du développement des différents systèmes de détection d'incendie, classées en trois grandes catégories : les technologies de détection d'incendie conventionnelle (CFD), Les systèmes de détection d'incendie basés sur la vision par ordinateur (CV) et les systèmes de détection basés sur l'apprentissage profond (DL). Les avantages de ces technologies, ainsi que leurs limites et lacunes sont expliqués.

La détection conventionnelle d'incendie repose sur la mesure des propriétés physiques des différents éléments caractéristiques du feu, tels que la fumée, la chaleur ou le monoxyde de carbone, détectés par divers capteurs. Cependant, ces derniers ne fournissent ni une analyse complète, ni une localisation précise de l'incendie, générant souvent des fausses alarmes. Les technologies de détection d'incendies basés sur la vision par ordinateur s'appuient principalement sur l'analyse d'images à l'aide de modèles de couleurs et de mouvement. Ces approches consistent à identifier les régions de flammes dans une image en fonction de leurs caractéristiques de couleur et de mouvement. Bien que ces méthodes ont prouvé leur efficacité dans certaines conditions, elles restent sensibles aux variations d'éclairage surtout dans des environnements complexes, ce qui peut conduire à un taux élevé de fausses alarmes. Avec les avancées récentes en apprentissage profond, de nouveaux systèmes basés sur des réseaux de neurones convolutifs (CNN) et d'autres architectures DL sont utilisés pour surmonter ces limites. Ces modèles permettent de capturer des caractéristiques plus complexes et de traiter de grands volumes de données visuelles, ce qui améliore la précision de la détection des incendies et réduit les fausses alarmes.

Ce chapitre examine d'abord les approches conventionnelles de détection d'incendie, en mettant l'accent sur l'utilisation des différents capteurs conventionnels, avant de passer en revue les méthodologies plus récentes basées sur les techniques de détection visuelles et l'apprentissage profond, qui offrent une meilleure performance dans la reconnaissance et la détection des flammes et de la fumée.

II.2. Systèmes de Détection d'Incendies Conventionnelle

La détection d'incendie conventionnelle repose principalement sur l'utilisation de capteurs conventionnels tels que les capteurs de fumée, les capteurs de chaleur et les capteurs de gaz. Ces dispositifs physiques sont conçus pour identifier les caractéristiques d'un incendie, notamment l'élévation de température, la présence de particules de fumée ou l'émission de gaz spécifiques tels que le monoxyde de carbone. Intégrés dans les systèmes de sécurité incendie, ces capteurs jouent un rôle essentiel dans la prévention des incendies en déclenchant des alarmes précoces, ce qui permet d'initier des actions rapides pour limiter les dommages. Leur efficacité est particulièrement reconnue dans les environnements intérieurs, où ils détectent rapidement les conditions anormales. Les sous-sections suivantes présentent les différents types de capteurs utilisés pour la détection d'incendie conventionnels, en s'appuyant sur des exemples issus de la littérature, ainsi que leurs avantages et limites.

II.2.1. Capteurs de Chaleur

Les capteurs de chaleur conventionnels sont des dispositifs couramment utilisés pour la détection d'incendie. Ils se déclenchent lorsque la température dépasse un seuil prédéfini. Les capteurs de chaleur les plus populaires se répartissent en deux catégories ^[40] :

II.2.1.1. Capteurs de Chaleur Fixes

Ce type de capteur est conçu pour fonctionner à une température précise, déclenchant une alarme lorsque la température atteint un seuil spécifique (par exemple : $T = 60^{\circ}C$), tel que les détecteurs basé sur un élément fusible, détecteurs thermiques à fibre optique et détecteurs biméalliques ^[41].

II.2.1.2. Capteurs de Chaleur Différentielle

Ce type de capteur détecte une augmentation de température trop rapide sur une courte période (par exemple, une hausse de $7^{\circ}C$ à $10^{\circ}C$ par minute). Ils disposent également d'un dispositif de sécurité de température fixe, qui garantit que même des augmentations de température extrêmement modestes déclencheront finalement une alarme si elles persistent longtemps.

Plusieurs chercheurs ont développé des techniques de détection d'incendie par différents capteurs. Wang et al ^[42] ont proposé une méthode de localisation du feu en utilisant un ensemble de capteurs thermiques qui servent à localiser le feu dans des conditions spécifiques (plafond plat, gaz constants). Chiang et al ^[43] , ont conçu un capteur de différence de température calibré

Chapitre II : Fondements Théoriques et Revue de la Littérature

et miniaturisé à faible coût. Ce capteur permet une transmission numérique facile à traiter via un réseau de capteurs sans fil, offrant ainsi un moyen pratique pour les pompiers à surveiller la température dans différents environnements.

II.2.2. Capteurs de Fumée

La fumée se forme bien avant d'autres signes d'incendie. Détecter la fumée à un stade précoce peut améliorer les chances de maîtriser l'incendie et de sauver des vies. La technique disponible pour la détection de fumée est basée sur des détecteurs optiques utilisant la lumière électromagnétique pour détecter les particules de fumée. Ces détecteurs optiques sont sensibles aux flammes et fonctionnent sur une large plage de températures. Ils peuvent détecter des particules de fumée dont la taille varie de 1,0 à 10 μm . Cependant, ils sont moins efficaces pour détecter les particules de taille inférieure à cette plage et peuvent déclencher de fausses alarmes dues à la poussière et aux aérosols ^[44]. Dans ^[45], les auteurs ont conçu un système qui détecte la fumées et fournit des données sur la substance en combustion on utilisant une LED polychromatique blanche, une fibre optique et des photodiodes. La méthode analyse les spectres de transmission polychromatiques pour identifier les effets de diffusion et d'absorption liés à la taille et à la distribution des particules. L'approche est moins sensible à l'humidité comparée aux capteurs basés sur l'intensité. Une autre étude ^[46] analyse les performances des détecteurs de fumée optiques pour réduire les fausses alarmes en collectant et en comparant les signaux chronologiques générés par les détecteurs. Une distance euclidienne a été utilisée pour classifier les signaux en catégories incendie ou non-incendie, améliorant ainsi le système d'alarme. Les résultats montrent une précision de plus de 80 % pour les détecteurs de fumée seuls, et de plus de 90 % pour les détecteurs multi-capteurs.

II.2.3. Capteurs de Gaz

Les principales causes d'incendie sont généralement liées à la combustion de composants organiques. Dans ce contexte, certains gaz tels que le monoxyde de carbone (CO) et le dioxyde de carbone (CO₂) peuvent être prévus avec une précision raisonnable. Même lorsqu'un incendie est initié par des composants non organiques, il peut rapidement se propager aux matériaux organiques environnants. De nombreuses recherches ont mis en évidence l'importance des gaz produits par les flammes, révélant que le CO est présente dans tous les types de combustion. Ce gaz est ainsi considéré comme un indicateur fiable. Par ailleurs, il a été observé que les incendies à combustion lente produisent une concentration plus élevée de CO, tandis que ceux à combustion rapide en génèrent moins. En conséquence, les capteurs de gaz ne se limitent pas

à la détection des incendies, mais permettent également de déterminer si l'incendie est flamboyant, fumant ou intermédiaire ^[47]. Dans ce contexte, plusieurs études ont mis en lumière l'efficacité des capteurs de gaz pour la détection précoce des incendies, par exemple, Kosterev et al ^[48] ont développé un système de détection d'incendie en utilisant des capteurs de gaz multi-espèces basé sur la spectroscopie photo acoustique à quartz. Ce capteur détecte l'ammoniac (NH_3), le cyanure d'hydrogène (HCN) et l'acétylène (C_2H_2), qui sont des gaz susceptibles d'être libérés en cas d'incendie ou lors de la surchauffe d'équipements. Soulignant que ces gaz sont choisis pour leur pertinence dans la détection des premiers signes d'incendie, comme la combustion de matériaux ou l'échauffement de fils électriques. Le capteur est conçu pour offrir une détection rapide et précise. De même, l'étude de Reimann et al ^[49] utilise un système à capteur à gaz semi-conducteur pour la détection précoce des incendies sous terre, notamment dans les mines de charbon. Exploité en mode de cyclage thermique, ce capteur permet d'améliorer la sélectivité et d'identifier les gaz caractéristiques d'un incendie.

Cependant, malgré leur utilité, les capteurs conventionnels présentent certaines limites. Dans les espaces urbains, par exemple, les détecteurs de fumée, souvent installés au plafond, nécessitent un certain temps pour que les rayons infrarouges atteignent le capteur et déclenchent l'alarme ^[50]. Ce délai peut avoir des conséquences graves, par exemple 50 % des victimes d'incendies domestiques en France sont gravement blessées ou dans un état grave qui nécessitent du temps pour leur évacuation ^[14]. En outre, Ces capteurs ne sont pas bien adaptés aux environnements complexes et nécessitent une intervention humaine pour confirmer un incendie en cas d'alarme. De plus, ces systèmes ne peuvent généralement pas fournir d'informations sur la taille, et l'emplacement du feu ^[15]. Pour surmonter ces limites, de nombreuses méthodes basées sur des capteurs de vision par ordinateurs ont été explorées par les chercheurs dans ce domaine.

II.3. Systèmes de Détection d'Incendie basés sur la Vision par Ordinateur

La détection d'incendie par vision par ordinateur repose sur l'analyse d'images ou de vidéos afin d'identifier le départ de feu. Contrairement aux capteurs physiques traditionnels, cette approche exploite des indices visuels tels que la couleur, le mouvement, le scintillement et la forme des flammes. Ces caractéristiques visuelles sont extraites puis introduites dans des algorithmes d'apprentissage automatique, comme les machines à vecteurs de support (SVM) et la régression logistique, permettant d'améliorer la précision de la détection. Les sous-sections

suivantes présentent les différentes techniques de détection basées sur l'analyse visuelle, en s'appuyant sur des exemples issus de la littérature, ainsi que leurs avantages et limites.

II.3.1. Approches Basées sur les Caractéristiques Spectrales

Les flammes, en raison de leur température élevée et de leur composition chimique, émettent une lumière qui présente des variations spécifiques en termes de luminance (intensité lumineuse) et de chrominance (couleur). Ces variations sont exploitées pour identifier la présence d'un incendie. Cette section présente les principales techniques basées sur les Caractéristiques Spectrales pour la détection d'incendie.

Une image numérique peut être représentée sous la forme d'un tableau bidimensionnel de dimensions $H \times L$, où H correspond à la hauteur de l'image (le nombre de lignes de la matrice) et L à sa largeur (le nombre de colonnes de la matrice), comme illustré dans la Figure II.1. Chaque élément de cette matrice, appelé pixel, représente une unité de base de l'image. Dans une image en niveaux de gris, chaque pixel est associé à une valeur numérique. Cette valeur représente l'intensité lumineuse à cet endroit. Dans un système de codage en niveaux de gris, l'intensité d'un pixel peut varier sur une échelle de 256 niveaux (de 2^8), allant de 0, correspondant au noir, à 255, correspondant au blanc.




Figure II.1. Image numérique en niveaux de gris

Une image numérique en couleurs, contrairement à une image en niveaux de gris, associe à chaque pixel trois valeurs de couleur, généralement représentées dans l'espace colorimétrique Rouge, Vert, Bleu (RVB). Chaque composante de couleur est numérisée sur une échelle de 256 niveaux (2^8), allant du noir $(R, G, B) = (0, 0, 0)$ au blanc $(R, G, B) = (255, 255, 255)$. Par

exemple, la couleur bleu pur est exprimée par $(R, G, B) = (0, 0, 255)$ ^[51]. Dans les applications de détection d'incendies basées sur la vision par ordinateur, la couleur, caractéristique dominante du feu, est l'une des premières propriétés utilisées pour le développement des techniques de détection ^[52]. Les algorithmes développés exploitent les propriétés discriminantes des espaces colorimétriques pour segmenter ces régions dans les images. Ces techniques reposent sur l'établissement de règles de décision spécifiques à un espace colorimétrique, suivies d'une segmentation par seuillage en fonction de ces règles. Les méthodes basées sur des règles identifient les pixels de flamme en comparant leurs valeurs entre elles ou avec des seuils déduits d'observations expérimentales. Ces méthodes sont généralement efficaces et produisent un taux élevé de détection. Cependant, elles présentent souvent un taux élevé de fausses alarmes dans certaines conditions, en raison de leur dépendance aux seuils empiriques. De plus, les variations des conditions d'éclairage demeurent un défi majeur pour ces approches. Les sous-sections suivantes présentent les principaux modèles basés sur des règles issus de la littérature, classés selon les espaces colorimétriques suivants : RGB, YCbCr, et HSV.

➤ **Modèle de Couleur RVB**

Le modèle de couleur RVB (Rouge, Vert, Bleu) est un modèle additif dans lequel trois composantes spectrales (rouge, vert et bleu) sont combinées de différentes manières pour produire une large gamme de couleurs. Ce modèle est principalement utilisé pour la représentation et l'affichage d'images dans des systèmes électroniques, tels que les ordinateurs, les téléviseurs et les téléphones mobiles. Le modèle RVB repose sur un système de coordonnées cartésien, représenté sous la forme d'un cube comme illustré dans la Figure II.2. Dans ce modèle cubique, les axes des coordonnées représentent les composantes R (rouge), G (vert) et B (bleu), avec des valeurs normalisées dans l'intervalle $[0, 1]$. Les couleurs primaires rouge, vert et bleu se situent respectivement aux coins $(1, 0, 0)$, $(0, 1, 0)$ et $(0, 0, 1)$. Les couleurs secondaires cyan, magenta et jaune sont représentés par les coins $(0, 1, 1)$, $(1, 0, 1)$ et $(1, 1, 0)$.

Chen et al ^[53] ont introduit trois règles basées sur les composantes de couleur RGB et les valeurs de saturation pour identifier les pixels de flamme dans l'espace RGB.

➤ **Première règle : Hiérarchie des couleurs**

Les composantes des pixels de flamme suivent généralement cet ordre :

$$I(X)R > I(X)G > I(X)B \quad (1)$$

Où :

$I(X)R$, $I(X)G$ et $I(X)B$: Représentent respectivement les composantes rouge, verte et bleue d'un pixel X .

➤ Deuxième règle : Seuil du rouge

Un pixel est considéré comme feu si sa composante rouge est supérieure à un seuil prédéfini TR (par exemple, $TR = 135$) :

$$I(X)R \geq TR \quad (2)$$

➤ Troisième règle : Saturation

Pour éviter les erreurs dues à des réflexions lumineuses, on vérifie également la saturation ($I(x)s$), selon la formule :

$$I(X)S \geq (255 - I(X)R) \frac{TS}{TR} \quad (3)$$

Où :

TS : Est un seuil de saturation (par exemple, $TS = 53$)

D'autres chercheurs, comme Celik ^[54] et Toulouse ^[55], ont enrichi ces règles avec des ratios de couleurs pour mieux discriminer les flammes des autres sources lumineuses. Par exemple :

$$I(x)R + \min I_c(x) \geq Tm \quad (4)$$

Où : Tm est un seuil optimisé, fixé à 72.

c représente les composantes de couleur (R, G, B)




Figure II.2. Illustration du modèle de couleur RVB

➤ Modèle de Couleur HSV

Chapitre II : Fondements Théoriques et Revue de la Littérature

Le modèle de couleurs HSV est une représentation intuitive des couleurs, fondée sur la manière dont les humains perçoivent les couleurs, à travers trois éléments : teinte (H), saturation (S) et valeur (V) ^[56].

Teinte (H) : Représente la couleur elle-même sous forme d'un angle allant de 0° à 360°. Les couleurs primaires (rouge, vert, bleu) sont respectivement à 0°, 120° et 240°. Les couleurs secondaires (cyan, magenta, jaune) se trouvent à 60° des couleurs primaires : cyan à 60°, magenta à 180° et jaune à 300° comme illustré dans la Figure II.3.

Saturation (S) : Indique l'intensité de la couleur. Une saturation de 0 signifie que la couleur est mélangée avec du blanc, tandis qu'une saturation de 1 correspond à une couleur pure, sans ajout de blanc.

Valeur ou intensité (V ou I) : Représente la luminosité de la couleur. Elle varie de 0 (noir) à 1 (blanc).

Dans le contexte de la détection de flammes, les pixels de feu présentent généralement des couleurs proches du blanc au centre de la flamme et des couleurs proches du rouge ou du jaune dans les régions environnantes. Sur cette base, il est possible de conclure que les pixels de flamme occupent des plages spécifiques dans l'espace de couleur HSV. À l'aide d'une analyse des motifs, Munshi ^[56] a établi les règles suivantes pour identifier les pixels de flamme:

Un pixel $I(x)$ est considéré comme appartenant à une flamme si :

$$Pixel = \begin{cases} Feu, si (0 < I(X)H \geq 0.35) et \\ \quad 0.3 \leq I(X)S \leq 1.0 \quad et \\ \quad 0.8 < I(X)V < 1.0 \\ \quad sinon, Non feu \end{cases} \quad (5)$$

Où :

$I(x)H, I(x)s$ et $I(x)V$: représentent respectivement les composantes de teinte, saturation et valeur du modèle HSV.




Figure II.3. Représentation du Modèle de Couleur HSV. Les lettres R, Y, G, C, B, M font référence respectivement à Rouge (Red), Jaune (Yellow), Vert (Green), Cyan, Bleu (Blue) et Magenta ^[7]

➤ Modèle de Couleur YCbCr

Le modèle de couleurs YCbCr est largement utilisé dans les domaines de la vidéo et de l'imagerie numérique, notamment dans les systèmes de compression d'images et de transmission vidéo. Ce modèle sépare les informations de luminance (Y) des informations de chrominance (Cb et Cr), permettant ainsi une compression plus efficace tout en conservant la qualité visuelle. Le composant Y représente la luminance, ou la luminosité de l'image, tandis que les composants Cb et Cr représentent respectivement les différences de couleur avec le bleu et le rouge. Ce découpage est particulièrement utile, car l'œil humain est plus sensible aux variations de luminance qu'aux variations de chrominance, ce qui permet de réduire la quantité de données nécessaires pour coder l'image sans compromettre la qualité perçue. Le modèle YCbCr est couramment utilisé dans des formats comme JPEG, MPEG et dans les normes vidéo comme le TV NTSC et PAL. La Figure II.4 présente un exemple d'image décomposée en ses composants Y, Cb et Cr.

À partir d'une analyse de 50 images de flammes, Munshi ^[56] a observé que les pixels de flamme se regroupent dans une région spécifique de l'espace YCbCr. Cette observation a conduit à définir les règles suivantes :

$$\text{Pixel} = \begin{cases} \text{Feu, si } (0 < I(X)_y \geq 170 \text{ et} \\ \quad 50 \leq I(X)_{cb} \leq 120 \text{ et} \\ \quad 120 < I(X)_{cr} < 220 \\ \text{sinon, Non feu} \end{cases} \quad (6)$$




Figure II.4. Exemple d'Image Décomposée en ses Composants Y, Cb et Cr ^[57]

II.3.2. Techniques de Détection de Mouvement

La première étape de la surveillance automatique basée sur la vision par ordinateur consiste à identifier et segmenter les objets d'intérêt c'est-à-dire les zones en mouvement d'une séquence vidéo, telles que les véhicules, les personnes ou les flammes.

Cette étape de segmentation est cruciale, car toute erreur à ce stade peut compromettre les traitements ultérieurs, tel que le suivi ou la classification des objets. Ainsi, une segmentation précise est essentielle pour garantir détection fiable et efficace. De nombreuses techniques de détection de mouvement ont été développées et étudiées. La majorité de ces méthodes utilisent des informations spatiales ou temporelles extraites des vidéos, celle-ci se classent en trois catégories principales : la différenciation temporelle, la soustraction de fond et le flux optique ^[58].

II.3.2.1 Différenciation Temporelle

La différenciation temporelle est une méthode directe de détection de mouvement qui exploite les différences temporelles entre des images consécutives d'une séquence vidéo. Elle consiste à calculer la différence absolue des pixels entre deux ou trois images successives, puis à appliquer un seuil pour identifier les objets en mouvement. Par exemple, dans les travaux d'Avula et al ^[59], un pixel à la position x est considéré comme en mouvement si :

$$(|I_t(X) - I_{t-1}(X)| > \tau) \text{ et } (|I_t(X) - I_{t-2}(X)| > \tau) \quad (7)$$

Où :

$It(x)$: est l'intensité du pixel à l'image t et τ est un seuil empirique.

Cette méthode est simple à mettre en œuvre, peu coûteuse en calcul et très adaptative dans des environnements dynamiques. Cependant, elle présente certaines limites, notamment une faible capacité à extraire les régions complètes ou les formes entières des objets en mouvement [60]. En particulier, la différenciation temporelle a des difficultés à segmenter les parties internes des objets en déplacement, ce qui peut entraîner une perte d'information importante dans certaines applications. Malgré ces limites, la différenciation temporelle demeure attrayante pour les systèmes de surveillance en temps réel en raison de sa simplicité et de sa rapidité.

II.3.2.2 Soustraction de Fond

La soustraction de fond est une approche couramment utilisée pour la segmentation de mouvement, particulièrement efficace dans les situations où l'arrière-plan est relativement statique. Dans cette méthode, les pixels stationnaires de l'image sont considérés comme appartenant au fond, représentant la partie immobile de la scène. L'arrière-plan est généralement modélisé en observant la scène sur une période donnée. Une estimation de l'arrière-plan peut être obtenue en calculant une moyenne des images initiales consécutives. Une fois le modèle d'arrière-plan établi, les pixels en mouvement sont détectés en calculant la différence pixel par pixel entre les images courante et le fond. Si cette différence dépasse un seuil prédéfini, le pixel est considéré comme faisant partie d'un objet en mouvement. Plusieurs approches, comme celles proposées par [61,62] intègrent la différenciation temporelle dans le schéma de soustraction de l'arrière-plan. Par exemple, dans Qureshi et al [62], un pixel $It(x)$ est considéré comme appartenant au premier plan si les conditions suivantes sont satisfaites :

$$| It(X) - Bt(X) | > Tt(X) \quad (8)$$

$$| It(X) - It - 1(X) | > Tt(X) \quad (9)$$

$$| It(X) - It - 2(X) | > Tt(X) \quad (10)$$

Où :

$It(x)$ est l'intensité du pixel a la position x , $Bt(x)$ est la valeur du pixel dans l'image d'arrière-plan, $Tt(x)$ est un seuil adaptatif qui décrit un changement significatif dans l'intensité du pixel.

Chapitre II : Fondements Théoriques et Revue de la Littérature

Bien que la soustraction de fond soit efficace pour isoler les régions en mouvement, elle demeure sensible aux changements dynamiques (comme les feuilles qui bougent ou les variations soudaines d'éclairage). De plus, cette méthode repose sur l'hypothèse que la caméra est stationnaire. Si l'arrière-plan est lui-même en mouvement, le modèle ne peut pas représenter correctement la scène, ce qui peut compromettre les résultats de segmentation.

II.3.2.3 Flux Optique

Le flux optique représente la distribution bidimensionnelle des vitesses de déplacement apparentes des motifs de luminosité dans le plan d'une image. Cette technique permet d'estimer le mouvement local des pixels dans une image et de déterminer la vitesse de déplacement de chaque pixel entre des images consécutives. Chaque pixel est associé à un vecteur de vitesse, formant ainsi un champ de flux optique. En convertissant les informations d'une image en champs de mouvement estimés, le flux optique facilite des analyses plus avancées. Le principe fondamental repose sur l'hypothèse selon laquelle un objet en mouvement conserve une luminance constante dans une séquence vidéo. De plus, la luminosité de l'image doit être continue et différentiable. Sous ces conditions, il est possible de calculer facilement les vitesses des objets en mouvement sans analyser la scène ^[63]. Cette hypothèse est modélisée par l'équation suivante :

$$\frac{d}{dt}I = \frac{di}{dx}u + \frac{di}{dy}v + \frac{di}{dt} = 0 \quad (11)$$

Où :

$I(x, y, t)$: est l'intensité lumineuse en fonction des coordonnées spatiales (x, y) et du temps t .
Le vecteur de flux (u, v) : représente la direction et la vitesse du mouvement pour un pixel donné.

Cette technique est largement utilisée dans les systèmes de suivi avancés, comme la détection des trajectoires de véhicules ou l'analyse de mouvements humains complexes. Cependant, elle est sensible aux variations d'éclairage et peut être coûteuse en calcul, ce qui limite son utilisation dans des environnements à ressources limitées.

II.3.3. Classificateurs utilisés pour la Détection de Flammes

En complément des méthodes basées sur la couleur et le mouvement, la détection d'incendie fait souvent appel à différents classificateurs permettant de distinguer efficacement les flammes des objets ayant des caractéristiques visuelles similaires. Ces classificateurs

Chapitre II : Fondements Théoriques et Revue de la Littérature

incluent, par exemple, les machines à vecteurs de support (SVM), la régression logistique ou encore les algorithmes KNN largement utilisées pour la classification du feu grâce à leur capacité à apprendre les caractéristiques spécifiques des incendies à partir de données d'entraînement.

L'application de modèles de caractéristiques multiples, permet d'affiner la détection et d'obtenir des résultats plus robustes dans des conditions variées ^[64].

II.4. Méthodes de Détection d'Incendie basées sur la Vision par Ordinateur traitées dans la Littérature

La détection d'incendie basé sur la vision par ordinateur a fait l'objet de nombreuses recherches, mettant en œuvre une variété d'approches basées sur des caractéristiques spectrales, et temporelles qui utilisent divers algorithmes de traitement d'images numériques pour identifier ces caractéristiques distinctives d'incendie telles que la couleur et le mouvement. De nombreuses variantes de ces systèmes ont été introduites au cours des dernières décennies. Le tableau II.1 fournit une comparaison des avantages et des inconvénients de diverses méthodologies de détection d'incendie basé sur la vision par ordinateur.

Certains chercheurs se concentrent sur l'utilisation des espaces de couleur en analysant les variations chromatiques des pixels de l'image afin d'identifier les zones des flammes et de la fumée. Par exemple Chen et al ^[53] ont développés une méthode en utilisant l'analyse chromatique pour détecter les flammes. L'analyse chromatique repose sur trois règles établies à partir des composantes R (Rouge), V (Valeur dans l'espace HSV), B (Bleu) et S (Saturation), avec des seuils définis pour les valeurs de R et S. Ces règles permettent de repérer les régions suspectes où des flammes pourraient être présentes. Parallèlement, l'analyse dynamique vise à distinguer les flammes réelles des objets statiques de couleur similaire en se basant sur deux caractéristiques principales des incendies : le désordre, reflétant le comportement imprévisible et chaotique des flammes, et la croissance, qui traduit leur expansion irrégulière dans le temps. Cette approche intégrée offre une détection plus fiable en exploitant à la fois les propriétés statiques et dynamiques des flammes.

Byoung et al ^[23] ont proposés une méthode avancée de détection des pixels de feu en utilisant un modèle probabiliste RVB basé sur une distribution gaussienne. Le canal Rouge est utilisé pour détecter les flammes, et un seuil probabiliste élimine les faux positifs.

Chapitre II : Fondements Théoriques et Revue de la Littérature

Qi et Ebert ^[65] soulignent que, dans l'espace de couleur RGB, les flammes possèdent des caractéristiques chromatiques marquées dans la bande rouge-jaune. Les composantes rouge (R), verte (G) et bleue (B) sont analysées pour déterminer si un pixel appartient à une région candidate de flamme. Cependant, séparer la luminance de la chrominance dans l'espace RGB reste difficile en raison de la sensibilité des composantes à l'éclairage. Pour surmonter cette limitation, plusieurs chercheurs ont adopté d'autres espaces couleur où les pixels de feu sont mieux représentés. Celik et al. ^[66] ont proposé un détecteur d'incendie robuste aux variations d'éclairage, reposant sur une méthode de détection utilisant la logique floue et l'espace colorimétrique YCbCr. Cet espace chromatique est choisi en raison de sa capacité à séparer la luminance de la chrominance, permettant ainsi une meilleure discrimination des caractéristiques des flammes. Marbach et al. ^[67] ont développé un algorithme de détection d'incendie en temps réel, exploitant les caractéristiques temporelles de l'intensité du feu. L'approche repose sur l'accumulation temporelle de la dérivée temporelle des images, permettant d'identifier les régions candidates susceptibles de correspondre à un incendie. Deux caractéristiques clés sont intégrées dans cet algorithme : la première est la plage de fréquences de scintillement typique des flammes, située entre 1 et 10 Hz, et le second est le niveau élevé de luminance caractéristique des régions contenant des flammes. L'espace colorimétrique YUV est privilégié dans cette méthode en raison de sa capacité à représenter distinctement les niveaux de luminance et de chrominance, ce qui facilite l'analyse des caractéristiques des flammes. L'approche améliore la robustesse et la précision, notamment dans des conditions d'éclairage variables. Wang et coll. ^[68] ont proposé une méthode de détection de flammes d'incendie dans laquelle la probabilité de couleur de la flamme est calculée à l'aide d'une distribution gaussienne modélisée dans l'espace colorimétrique YCbCr. La probabilité de mouvement est calculée par une image d'arrière-plan mise à jour dynamiquement avec une méthode médiane approximative. Ensuite, les probabilités de mouvement et de couleur sont multipliées et des seuils sont utilisés pour créer des masques binaires. Chaque extraction de vecteur de caractéristique de trame est effectuée pour déterminer les régions de flamme candidates. En plus de la détection, des auteurs ont introduit une estimation du degré de combustion des flammes, fournissant des informations supplémentaires sur l'intensité et l'évolution de l'incendie, Horn et coll. ^[69] ont proposé une méthode de détection des flammes en temps réel en exploitant le modèle de couleur HIS (Teinte, Intensité, Saturation). Ce modèle permet de mieux isoler les caractéristiques chromatiques des flammes, facilitant leur distinction des arrière-plans complexes. Horng et Peng ^[70] ont introduit une autre méthode de détection de flamme basée sur l'utilisation de l'espace colorimétrique HSI qui est particulièrement adapté pour la détection de

flammes, car il permet de mieux représenter les variations de teinte et de saturation caractéristiques des régions contenant du feu, tout en séparant ces informations des niveaux d'intensité lumineuse. D'autres études se sont penchées sur l'analyse du comportement dynamique des flammes, comme leur désordre, leur croissance et leur scintillement, en complément des caractéristiques chromatiques, pour améliorer la fiabilité et la précision des systèmes de détection des incendies. Toreyin et al. ^[71] ont proposé une méthode de détection de flamme basée sur une combinaison de caractéristiques spécifiques : la couleur, le mouvement et le scintillement. Les caractéristiques de couleur sont identifiées à l'aide des règles du modèle de couleur RVB, tandis que le mouvement est analysé via une méthode d'estimation d'arrière-plan. Zhang ^[72] ont utilisé des caractéristiques de mouvement pour la détection d'incendie, appropriées pour caractériser le scintillement des flammes lors de la phase de décision finale. Dimitropoulos et coll. ^[73] ont proposé un algorithme de détection de flammes vidéo en temps réel. Ils ont utilisé diverses caractéristiques spatio-temporelles et une analyse de texture dynamique pour l'évolution temporelle des intensités de pixels dans le bloc d'image candidat. Borges et al. ^[74] ont utilisé un nouveau type d'algorithmes de prise de décision ajoutant d'autres facteurs qui permettent de détecter les pixels feu à l'aide d'un classificateur bayésien efficace qui combine les caractéristiques de couleurs avec d'autres facteurs tels que, la taille de la zone du feu, le degré d'asymétrie et la limite de la rugosité des pixels candidates d'incendie. Ces caractéristiques extraites sont utilisées comme entrées dans le classificateur qui permet de prendre une décision de la présence ou l'absence du feu dans les vidéos. DiLascio et al. ^[75] ont proposé une méthode pour détecter l'incendie dans les environnements intérieurs et extérieurs en combinant des caractéristiques de couleur et de mouvement. Ils ont utilisé l'espace colorimétrique YUV car pour séparer la luminance et la chrominance, et le tracker SIFT pour la détection de mouvement. Un classificateur MES multi-expert assure la fusion des informations pour une détection précise. Foggia et al. ^[21] ont proposé une approche de détection des flammes basée sur la variation de forme, combinant analyse de couleur, forme et mouvement via un système multi-experts. Afin d'accroître la robustesse des algorithmes de détection de feu, certaines études utilisent une approche multi-espaces couleur. Par exemple Chen et al ^[76] ont isolé les pixels de couleur de flamme grâce à un modèle hybride YCbCr et un algorithme de clustering K-means dans l'espace couleur LAB. Han et al ^[77] a suggéré une méthode de détection d'incendie utilisant des caractéristiques de mouvement et de couleur. Pour les caractéristiques de mouvement, ils ont utilisé le modèle de mélange gaussien utilisant la soustraction d'arrière-plan et pour la détection des caractéristiques de couleur, ils ont utilisé une

Chapitre II : Fondements Théoriques et Revue de la Littérature

combinaison d'espaces colorimétriques RVB, HSI et YUV. Plus récemment, Munshi ^[56] a utilisé une combinaison des espaces YUV, HSV et RGB pour détecter les flammes.

Contrairement aux approches basées sur des règles heuristiques fixes, la logique floue offre une plus grande flexibilité en intégrant un modèle de chrominance pour distinguer les objets de couleur feu des objets non feu. En s'appuyant sur ce principe, des études innovantes ont été développées par différents chercheurs. Par exemple Ko et coll. ^[78] ont proposé une méthode de détection d'incendie dans laquelle ils ont utilisé une caméra stéréo pour calculer la distance du feu et la reconstruction de la surface 3D du front de feu. Ils ont utilisé des modèles génériques de différence de couleur et d'arrière-plan. Ensuite, des GMF (fonctions d'appartenance gaussiennes) sont générées pour les changements de taille, de forme et de mouvement du feu. Pour vérifier le tir en temps réel, les trois GMF obtenus sont appliqués à la logique floue. Schröder et coll. ^[79] ont proposés une méthode de détection de déflagration utilisant un algorithme en deux étapes. Dans la première étape de l'algorithme, les caractéristiques d'intensité chromatique et dynamique sont utilisées pour identifier les pixels du feu. Dans la deuxième étape de l'algorithme, l'évaluation de l'expansion temporelle des pixels comptés a lieu à l'aide du SEP (paramètre d'expansion spatiale). Ils ont utilisé une classification floue pour chaque étape.

Autres chercheurs ont investi des efforts pour améliorer la précision de détection et cela en utilisant différentes techniques d'apprentissage automatique pour une détection robuste. Rossi et al ^[80] ont introduit une nouvelle méthode efficace pour la détection d'incendies, surpassant plusieurs approches, intégrant une technologie d'apprentissage automatique basée sur la régression logistique. Cette dernière s'est avérée plus performante, offrant une meilleure précision dans la classification des incendies. Rui et coll ^[81] ont présenté une approche multifonctionnalités pour la détection d'incendie. Le GMHI (Gradient Motion History Image) est utilisé pour extraire les régions en mouvement et l'algorithme K-means est utilisé pour vérifier les couleurs des pixels de feu en mouvement. Ensuite, les fonctionnalités extraites sont utilisées pour entraîner le classificateur SVM. Les résultats combinés du SVM et de l'analyse des contours fournissent une meilleure décision concernant l'incendie. Kong et coll ^[82] ont utilisé la régression logistique et le lissage temporel pour la détection des flammes. Le rapport des composantes de couleur est utilisé pour déterminer la région d'incendie candidate, la soustraction de l'arrière-plan est utilisée pour trouver le signal de mouvement des flammes de feu et la régression logistique est utilisée pour les informations relatives à la taille, au

Chapitre II : Fondements Théoriques et Revue de la Littérature

mouvement et à la couleur. Ils ont utilisé la distribution et le rapport chromatique (Cb/Cr) pour différencier les flammes du feu, les objets ressemblant à du feu et l'arrière-plan.

Tableau II.1. Approches de vision par ordinateur pour la détection d'incendie. Innovations et limites

References	Techniques	Innovations	Limites
[23], [53], [65], [66], [67], [68], [69], [70], [75], [68], [72], [75],	Détection basée sur la couleur (Modèles RGB, HSV, YCbCr, YUV, etc.) et L'analyse temporelle (Accumulation temporelle, scintillement)	<ul style="list-style-type: none"> ✓ Faible coût de calcul ✓ Détection en temps réel ✓ Capture des variations dynamiques 	<ul style="list-style-type: none"> ✓ Sensible aux variations de luminosité ✓ Faux positifs causés par des objets de couleur similaire au feu ✓ Difficulté avec des formes similaires dans l'arrière-plan
[71], [73], [21],	Analyse multi-caractéristiques (Combinaison couleur, mouvement, scintillement, texture, etc.)	<ul style="list-style-type: none"> ✓ Réduction du nombre de faux positifs 	<ul style="list-style-type: none"> ✓ Coût computationnel élevé
[76], [77], [56]	Approche multi-espaces couleur	<ul style="list-style-type: none"> ✓ Bonne séparation luminance chrominance 	<ul style="list-style-type: none"> ✓ Faux positifs dus aux ombres et objets rouges similaires
[74], [80], [81], [82]	Modèles d'apprentissage (SVM, réseau bayésien régression logistique, etc.)	<ul style="list-style-type: none"> ✓ Haute précision ✓ Capacité à traiter des données complexes ✓ Adaptation à divers scénarios 	<ul style="list-style-type: none"> ✓ Nécessite de grands ensembles de données pour l'entraînement ✓ Temps d'exécution élevé pour des données volumineuses
[78], [79]	Algorithmes de classification floue	<ul style="list-style-type: none"> ✓ Gère efficacement les incertitudes ✓ Bonne capacité à modéliser des données floues ou incomplètes 	<ul style="list-style-type: none"> ✓ Sensible aux paramètres des fonctions d'appartenance. ✓ Complexité computationnelle modérée à élevée

II.5. Systèmes de Détection d'Incendie basés sur l'Apprentissage Profond

Au cours de la dernière décennie, les algorithmes d'apprentissage profond ont subi une évolution significative dans le domaine de la reconnaissance d'image de feu et la détection d'incendies atteignant une précision de classification élevée par rapport aux méthodes traditionnelles sensibles aux variations de luminosité. L'apprentissage profond joue un rôle important dans l'amélioration des systèmes de détection d'incendie en permettant aux modèles d'apprendre automatiquement des caractéristiques à partir des données ^[83]. Ainsi, l'utilisation de ces architectures a permis de développer des systèmes plus robustes, capables de détecter le feu avec une grande fiabilité même dans des conditions environnementales complexes.

II.5.1. Réseaux de Neurones Convolutifs (CNNs)

Les réseaux de neurones convolutifs (CNNs) sont largement utilisés pour la détection d'incendie basée sur l'apprentissage profond, permettant d'extraire automatiquement les caractéristiques discriminantes des images et facilitant l'identification des zones contenant du feu. Contrairement aux approches classiques nécessitant une extraction manuelle des caractéristiques, les CNNs apprennent directement à partir des données visuelles, ce qui améliore la performance et la robustesse du système.

Des modèles pré-entraînés, tels que Google Net^[84] ou Mobile NetV2^[85] sont souvent utilisés et ajustés pour s'adapter à la détection d'incendie. Par ailleurs, d'autres recherches développent des architectures CNN spécifiques, conçues pour capter précisément les régions du feu et renforcer la fiabilité du processus de détection ^[50].

II.5.2. Modèles de Détection d'Objets

Les modèles de détection d'objets représentent une évolution des réseaux convolutifs classiques, ils permettent d'identifier et de localiser simultanément la position du feu dans une image permettant une analyse plus précise et plus rapide des zones à risque. Les premières approches comme le R-CNN (Region-based Convolutional Neural Network) ^[86] et Faster R-CNN ^[86] ont marqué une étape importante en combinant la détection d'objets et l'apprentissage profond. D'autres modèles plus récents tels que YOLO (You Only Look Once)^[87] et SSD (Single Shot MultiBox Detector)^[88] se distinguent par leur capacité à effectuer une détection en temps réel, ce qui les rend particulièrement adaptés à la surveillance vidéo d'incendies. Par ailleurs, pour les vidéos de feu, certaines études combinent les CNNs avec des RNN (réseaux de neurones récurrents)^[89], notamment les LSTM (Long Short-Term Memory)^[90], afin

d'exploiter les informations temporelles. Cette combinaison permet de mieux distinguer un vrai feu de phénomènes visuels similaires (comme les reflets ou la lumière du soleil), améliorant ainsi la fiabilité du système de détection.

II.6. Méthodes de Détection d'Incendie basées sur l'Apprentissage Profond traitées dans la Littérature

Plusieurs architectures DL ont été utilisées pour la détection des incendies et de la fumée. Le tableau II.2 fournit une comparaison des avantages et des inconvénients de diverses méthodologies de détection du feu basées sur l'apprentissage profond. Frizzi et al.^[91] ont introduit un CNN simple pour détecter le feu et la fumée, le réseau a été formé et testé sur des images de feu et a donné une précision élevée, cependant, les résultats n'ont pas été comparés avec d'autres recherches. D'autre part, d'autres chercheurs ont utilisé des CNN préformés pour la tâche de classification des incendies pour améliorer la reconnaissance du feu. Par exemple, Khan et al.^[92] ont suggéré une étude de détection du feu dans les caméras de surveillance, en utilisant une architecture similaire à Alex net^[93], ils ont incorporé une stratégie de sélection de canaux basée sur la hiérarchisation de la caméra. Les résultats ont été évalués sur deux bases de données de référence, montrant une amélioration de la précision par rapport aux travaux précédents. Khan et al.^[14] ont proposé une autre étude en 2018, ils ont développé un algorithme de détection d'incendie en utilisant une architecture similaire à Google net^[84] avec une certaine modification selon le problème de détection des incendies. Cette architecture est plus précise par rapport à l'étude précédente. De plus, Khan et al.^[94] ont proposé un autre modèle léger pour la détection des incendies similaire à l'architecture de Mobilenetv2^[85], qui a réalisé une meilleure précision avec une réduction du coût de calcul. Une autre approche pour la détection des incendies est proposée par Sharma et al.^[95] en utilisant des modèles préformés et en ajoutant des couches entièrement connectées atteignant une bonne précision. Hongyi Pan et al.^[96] ont proposé un nouvel algorithme pour la détection des incendies de forêt en utilisant l'apprentissage par transfert, ils minces les couches à l'aide du réseau de transformateur Fourier afin d'accélérer l'interface CNN.

Dans une autre étude^[97], divers modèles préformés ont été utilisés pour la détection des incendies de forêt, atteignant une bonne précision. Xu et al.^[98] ont utilisé un modèle de saillance CNN pour prédire les régions du feu et de la fumée dans les vidéos, leurs résultats ont été comparés à six études précédente et ont donné une précision satisfaisante. Dans une autre recherche^[15], une architecture basée sur CNN utilisant des couches convolutionnelles dilatées

Chapitre II : Fondements Théoriques et Revue de la Littérature

a été mise en œuvre pour la détection des flammes et de la fumée. Cette méthode réduit efficacement la complexité du réseau sans compromettre la précision, ce qui est particulièrement bénéfique pour les tâches de détection des flammes et de la fumée. D'autres chercheurs ont utilisé des approches basées sur des modèles de détection d'objets tels que R-CNN et Yolo. Par exemple, Kim B et Lee ^[99], utilisent deux CNN profonds pour détecter le feu. Initialement, le réseau R-CNN a été utilisé comme extracteur de fonctionnalités pour détecter et localiser les incendies dans des vidéos. Ensuite, un autre réseau neuronal LSTM accumule les fonctionnalités extraites. Enfin, les informations extraites des deux réseaux ont été combinées pour déterminer l'existence ou l'absence de feu. Faster R-CNN a été utilisé dans une autre recherche ^[100] en combinant une stratégie de couleur et une stratégie d'information pour une meilleure détection des flammes. Casas et al ^[101] ont comparé YOLOv5 et YOLOv8 en utilisant l'ensemble de données Miviea^[21] pour identifier le meilleur modèle de reconnaissance de la fumée forestière. D'autres chercheurs ont développé des approches de détection d'incendie intégrant le mécanisme d'attention, obtenant ainsi des résultats prometteurs dans ce domaine. Par exemple ^[102] ont développé un nouveau modèle de détection de feu adapté à l'inférence en temps réel et applicable même pour les petits ensembles de données. Un réseau de détection d'incendie présenté par Taimoor Khan et al ^[103] en combinant un minuscule CNN avec le module d'attention du canal. Cette combinaison a permis une meilleure classification des d'incendie. Cependant, il présente des défis tels que la sensibilité aux paramètres choisis pour la formation et la nécessité de grands ensembles de données de formation.

Tableau II.2. Approches d'apprentissage en profondeur pour la détection des incendies. Innovations et limites

References	Techniques	Innovations	Limites
[91]	CNN classique	✓ Bonne performance de classification par rapport aux méthodes traditionnelles	✓ Manque d'une évaluation comparative du modèle
[92]	AlexNet	✓ Des progrès importants dans la gestion des catastrophes et la détection précoce des incendies	✓ Limités dans des environnements avec des ressources restreintes.
[14]	GoogleNet	✓ Robustesse contre divers types d'attaques	✓ Taux de faux positif élevé
[96]	MobileNetv2	✓ Détection d'incendie le jour et la nuit	✓ Manque d'images de flamme dans l'ensemble de données d'entraînement

Chapitre II : Fondements Théoriques et Revue de la Littérature

[97]	VGG16 /InceptionV3 /Xception	✓ Application efficace de plusieurs modèles préformés	/
[15]	CNNS Dilaté	✓ Approche bénéfique	✓ Limitée lorsque les pixels des incendies sont proches de ceux de l'arrière-plan
[98]	Réseau de saillance profonde	✓ Comparaison de différentes méthodes de détection de saillance de littérature	/
[99]	R-CNN / LSTM	✓ Approche bénéfique	✓ Complexité de calcul élevé
[100]	Faster R-CNN	✓ Évaluation de l'approche sur plusieurs ensembles de tests	✓ Complexité computationnelles élevée
[101]	YOLOv5 /YOLOv8	✓ Étude comparative bénéfique pour les travaux futurs	✓ L'étude se concentre uniquement sur l'ensemble de données Foggia
[103]	mécanismes d'attention	✓ une précision plus élevée et un temps d'inférence plus rapide	✓ Nécessitent un grand ensemble de données
[102]	mécanismes d'attention	✓ Précision plus élevée et temps d'inférence plus rapide	/

II.7. Lacunes de la recherche

Les systèmes de détection d'incendie basés sur la vision par ordinateur (CV) ont fait l'objet de nombreuses recherches au cours des dernières décennies. Ces travaux se sont concentrés sur des caractéristiques conçues manuellement, telles que la texture, la couleur, le scintillement de flammes, et le mouvement. Cependant, ces dernières années, l'attention s'est portée sur l'extraction des caractéristiques du feu à l'aide des CNNs, grâce à leurs performances remarquables en détection et en classification. Les méthodes de détection d'incendie en utilisant le DL mentionnées dans la section précédente ont montré une amélioration des performances de détection des incendies. Cependant, la plupart de ces approches reposent sur des réseaux très profonds, ce qui entraîne des coûts de calcul élevés Comme illustré dans le Tableau II.2. Les systèmes existants reposent souvent sur des architectures très profondes, qui ne s'adaptent pas aux environnements restreints. Bien que ces architectures sont efficaces pour des situations complexes, ils entraînent une charge computationnelle élevée et un temps de traitement prolongé, ce qui limite leur déploiement dans des environnements à ressources limité. Afin de surmonter ces limitations, cette thèse propose une nouvelle approche de classification des

Chapitre II : Fondements Théoriques et Revue de la Littérature

incendies basé sur des CNN légers avec moins de couches convolutifs, ce qui minimise la complexité de calcul et facilite son intégration dans des environnements avec des ressources restreintes.

II.8. Conclusion

Dans ce chapitre, nous avons présenté les fondements théoriques et la littérature existante sur les systèmes de détection d'incendie. Après avoir décrit les systèmes conventionnels et leurs capteurs (chaleur, fumée, gaz), nous avons exploré les méthodes basées sur la vision par ordinateur, en abordant les approches spectrales et l'analyse du mouvement. Enfin, les méthodes d'apprentissage profond, incluant les CNN et les modèles de détection d'objets, ont été présentées comme des solutions performantes pour la détection automatique et en temps réel des incendies.

Chapitre III

Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

Sommaire du chapitre :

III.1. Introduction	47
III.2. Collecte et Préparation des Ensembles de Données	47
III.2.1. Collecte et Extraction à Partir de Vidéos Publiques	47
III.2.2. Collecte à Partir de Bases de Données d'Images Publiques	48
III.2.2.1. Ensemble de donnée A : Forestry Images	48
III.2.2.2. Ensemble de donnée B : PyImageSearch	48
III.2.2.3. Ensemble de donnée C : Fismo	51
III.2.2.4. Ensemble de donnée D : Base de données des incendies de GitHub	51
III.2.2.5. Ensemble de donnée E : Google Image	52
III.2.2.6. Ensemble de donnée F : Base de données d'Oliva et de Torralba	52
III.2.3. Augmentation des Données	54
III.2.4. Fractionnement de l'Ensemble de Données	55
III.3. Environnement de Développement des Modèles CNN	57
III.4. Approche Proposée	58
III.4.1. Détection d'incendie basée sur les CNN	59
III.4.2. Détails de l'architecture proposée pour la détection d'incendie	601
III.4.2.1. CNN_A	61
III.4.2.2. CNN_B	62
III.4.2.3. CNN_C	64

III.4.2.4. CNN_D.....	65
III.4.3. Apprentissage d'Ensemble.....	66
III.5. Conclusion.....	67

Chapitre III : Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

III.1. Introduction

Ce chapitre décrit en détail la méthodologie proposée pour la détection des incendies. Il débute par une discussion sur la collecte et la préparation des ensembles de données constitués de vidéos et d'images, utilisés pour l'entraînement des modèles. Le processus d'augmentation des images, ainsi que le fractionnement des ensembles de données en sous-ensembles d'entraînement, de validation et de test, sont décrits. Par la suite, un aperçu de l'approche de détection d'incendie développée, incluant les quatre algorithmes de classification d'images d'incendie basés sur les réseaux de neurones convolutifs (CNN) est présenté. Le chapitre se termine par la présentation de la technique d'assemblage utilisée pour combiner les prédictions des quatre modèles proposé, en vue d'améliorer la fiabilité et la robustesse du système de détection d'incendie.

III.2. Collecte et Préparation des Ensembles de Données

Pour les problèmes basés sur des modèles d'apprentissage en profondeur, la disponibilité de grands ensembles de données public est nécessaire pour la formation et l'évaluation des modèles. Ainsi la comparaison des résultats avec d'autres techniques traitant le même problème. Cependant, ce n'est pas le cas pour le problème de détection d'incendies, la plupart des ensembles de données disponibles sont trop petits pour former un CNN efficace. Pour créer un ensemble de données riche qui donne de meilleures performances de détection, une gamme multiple de vidéos et d'images de feu a été collectée à partir de bases de données publiques et des travaux de recherche précédents ^[103–111]. Certaines images ont été capturées à partir de vidéos d'incendies issues de YouTube et de Facebook. La collection a été sélectionnée pour représenter différents scénarios réels : intérieur et extérieur, avec et sans feu, de jour et de nuit, etc. Les sous-sections ci-dessous décrivent la collecte des vidéos et des images d'incendie, et présentent des exemples d'images extraites.

III.2.1. Collecte et Extraction à Partir de Vidéos Publiques

Pour entraîner les algorithmes de détection d'incendies proposés, un ensemble de vidéos d'incendie de différente résolution a été téléchargées à partir de divers sources publiques ^[104,106,107,109–111], en plus nous avons collecté 125 clips vidéo de YouTube et Facebook, comprenant 71 clips de feu et 54 de non-feu. Ces vidéos ont été soigneusement choisies afin de couvrir une large gamme de scénarios réels, représentant à la fois des scènes intérieures, telles que des incendies dans les bâtiments résidentiels ou les bureaux, ainsi que des scènes

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

extérieures représentant des incendies en plein air, comme dans des industries, des forêts ou des zones urbaines. Les vidéos collectés contient des scènes avec et sans présence de feu, permettant d'entraîner le modèle à distinguer les situations normales des situations d'incendie. À partir de ces vidéos, des trames d'images ont été extraites pour constituer la base de données d'entraînement des modèles proposés. Des exemples d'images de feu et de non-feu extraites à partir de ces vidéos sont représentés dans la Figure III.1

III.2.2. Collecte à Partir de Bases de Données d'Images Publiques

Plusieurs images de feu et de non-feu ont été extraites à partir de bases de données d'images publiques ^[105,106,108,112] et de différents sites d'Internet tel que kaggle.com^[113] et Google Images. Dans les sous-sections suivantes, une description détaillée de chaque ensemble de données utilisé est présentée

III.2.2.1. Ensemble de données A : Forestry Images

Proposé par l'Université de Géorgie, l'ensemble de données Forestry Images ^[112] est une base de données publique contenant un grand nombre d'images de différentes résolutions, couvrant différents domaines, comme les incendies de forêt, les maladies des arbres, la faune et la flore...etc. 350 images ont été téléchargées à partir de cette base de données, dont 126 images d'incendies de forêt et le reste représentant des images de forêts sans feu. La figure III.2 illustre des exemples d'images de feu et de non-feu de l'ensemble de données A.

III.2.2.2. Ensemble de données B : PyImageSearch

PyImageSearch ^[105] est une base de données publique proposé par Adrian Rosebrock dans le cadre de développement d'un projet de détection d'incendie en utilisant l'apprentissage profond. Elle contient 1 315 images d'incendies ainsi qu'un ensemble d'images "non-feu". À partir de cette base de données, 1 250 images ont été téléchargées, dont 626 représentent des scènes d'incendie, et le reste correspondant à des images sans feu. La figure III.3 illustre des exemples d'images de feu et de non-feu de l'ensemble de données B.

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies



Figure III.1. Exemples d'images de feu et de non-feu extraites à partir de vidéos d'incendie

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

feu



non- feu



Figure III.2. Quelques exemples d'images extraites de l'ensemble de données A. (Haut) : Images de feu ; (Bas) : Images sans feu.

feu



non- feu



Figure III.3. Quelques exemples d'images extraites de l'ensemble de données B. (Haut) : Images de feu ; (Bas) : Images sans feu.

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

III.2.2.3. Ensemble de données C : Fismo

Fismo [7] est un ensemble de données public, développé par Cazzolato et al dans le cadre d'une recherche sur la détection d'incendie et de fumée en utilisant des techniques de vision par ordinateur. Il contient 9448 images issues de plusieurs bases de données d'incendie. Ces images sont annotées selon la présence ou l'absence de feu et/ou de fumée, certaines comprennent des régions d'intérêt et des caractéristiques de bas niveaux extraits. Dans le cadre de notre travail, nous avons extrait de cet ensemble uniquement les images annotées "feu" et "non feu", en excluant celles contenant uniquement de la fumée. Au total, 2059 images ont été extraites pour l'entraînement et l'évaluation de nos modèles de détection de flammes dont 1051 images sont des images d'incendie. La figure III.4 présente des exemples d'images issues de Fismo.




Figure III.4. Quelques exemples d'images extraites de l'ensemble de données C. (Haut) : Images de feu ; (Bas) : Images sans feu

III.2.2.4. Ensemble de données D : Base de données des incendies de GitHub

L'ensemble de données des incendies de Git Hub ^[108] est une base de données publique présenté par Sharma et al dans le cadre d'une recherche sur la détection d'incendie en utilisant des CNN profonds, contenant 651 images, réparties en 110 images de feu et 541 images sans feu. Cet ensemble de données est composé d'une variété de scénarios et de différentes situations de feu

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

(intensité, luminosité, taille, environnement, etc.). Il est largement utilisé pour la détection des incendies à l'aide de l'intelligence artificielle. Quelques échantillons d'images de l'ensemble de données D sont illustrés dans la figure III.5.




Figure III.5. Quelques exemples d'images extraites de l'ensemble de données D. (Haut) : Images de feu ; (Bas) : Images sans feu

III.2.2.5. Ensemble de données E : Google Image

Afin d'enrichir notre ensemble de données, Google Images ^[114] a été utilisé pour la collecte de 259 images d'incendie. La recherche a été effectuée en utilisant de mots-clés spécifiques tels qu'« incendie sur autoroute », « incendie industrielle », « incendie dans un immeuble », « incendie dans une station de bus », etc. Cette méthode a permis de diversifier les types de scénarios d'incendie représentés dans l'ensemble de données. Quelques exemples d'images collectées depuis Google Images sont illustrés dans la figure III.6.

III.2.2.6. Ensemble de donnée F : Base de données d'Oliva et de Torralba

Le célèbre ensemble de données proposé par Oliva et Torralba^[115] est utilisé pour la collecte d'images sans feu. Cet ensemble contient une diversité d'images réparties en huit catégories de scènes naturelles, telles que les forêts, les montagnes, les plages ou encore les rues. Au total, 840 images ont été extraites à partir de cet ensemble, il a été utilisé afin d'enrichir

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

la diversité des scènes naturelles sans incendie représentées dans l'ensemble global. Quelques échantillons d'images de l'ensemble d'Oliva et de Torralba sont illustrés dans la figure III.7.



Figure III.6. Quelques exemples d'images d'incendie extraites de l'ensemble de données E.

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies



Figure III.7. Quelques exemples d'images sans feu extraites de l'ensemble de données F

III.2.3. Augmentation des Données

L'augmentation des données joue un rôle crucial dans les algorithmes d'apprentissage en profondeur et surtout les réseaux de neurones convolutifs, en particulier pour la détection des incendies, où l'acquisition de grands ensembles de données pour un entraînement efficace peut être difficile. Dans cette étude, nous avons appliqué des techniques classiques d'augmentation aux ensembles de données afin d'augmenter la taille et d'améliorer la diversité des images de notre ensemble de données final. Les ensembles de données ont été augmentés par des opérations de retournement horizontal et vertical (flip). Toutes les images de ces ensembles ont été retournées à la fois horizontalement et verticalement. Le retournement horizontal inverse les pixels de l'image de gauche à droite, tandis que le retournement vertical les inverse de haut en bas. Cela aide le modèle à reconnaître des objets dans différentes orientations et améliore la

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

robustesse du modèle face aux variations de position des éléments dans les images. Ces transformations simples permettent de générer plusieurs variantes à partir d'une même image originale ce qui permis d'enrichir notre base d'images. La figure III.8 et figure III.9 illustre des exemples de différentes transformations appliquées à une image d'incendie et une image normale sans feu respectivement.



Figure III.8. Exemple d'augmentations d'image appliquées à une image d'incendie industrielle



Figure III.9. Exemple d'augmentations d'image appliquées à une image sans feu

III.2.4. Fractionnement de l'Ensemble de Données

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

Nous avons construit un ensemble de données de 19 570 images, composées de 8843 images de feu et 10727 images non-feu. En règle générale, l'ensemble de données d'images est divisé en trois parties : sous-ensemble de formation, qui comprend environ 75% à 80% de l'ensemble de données global. Le sous-ensemble de formation est utilisé pour former les modèles CNN dans la phase d'apprentissage du modèle (phase d'entraînement), en lui permettant d'apprendre les caractéristiques des données. La deuxième partie, qui est les 20% à 25% restants de l'ensemble de données global est utilisé pour la validation et le test. L'ensemble de validation sert à évaluer le modèle tout au long du processus d'apprentissage en lui permettant d'ajuster les hyper paramètres. Une fois le modèle final entraîné et optimisé, il est testé sur l'ensemble de test afin de tester les performances du modèle et mesurer sa précision avant son déploiement [99].

Cette division des ensembles de données est cruciale pour assurer une évaluation fiable du modèle et éviter le sur-ajustement (overfitting). Sans cette séparation, le modèle sera évalué sur les mêmes données d'entraînement, ce qui pourrait limiter sa capacité à s'adapter à de nouvelles données. Pour notre ensemble de données final, les images sont divisées en 80% pour la formation, 10% pour la validation et 10% pour les tests. La répartition de l'ensemble de données d'images final en sous-ensembles d'entraînement, de validation et de test, en précisant le nombre d'images contenant du feu et sans feu, est illustrée dans la figure III.10.

Un ensemble de données large permet de construire un modèle CNN robuste et fiable qui peut être déployé dans un large éventail de scénarios différents : intérieur, notamment dans les maisons, les bâtiments résidentiels, ou les bureaux et extérieur : dans les parcs, les rues, les autoroutes, parkings, aéroports et ainsi de suite. Pour cette raison nous avons construit un ensemble de données varié intégrant des images issues de différentes conditions et même du jour et de nuit. Cette diversité permet d'améliorer la fiabilité des modèles dans la détection des incendies, en réduisant les erreurs et en optimisant ses performances face à des situations réelles. L'ensemble de données final a deux classes : les images de feu et les images non-feu (normales), qui sont étiquetées manuellement. Pour réduire les tailles de stockage et faciliter le processus de calcul, ces images ont été converties en tableaux Numpy avant d'être injectés en réseaux CNN.




Figure III.10. Répartition de l'ensemble de Données d'images en sous-ensembles d'entraînement, de Validation et de Test

III.3. Environnement de Développement des Modèles CNN

Aujourd'hui, il existe plusieurs bibliothèques pour le développement des modèles d'apprentissage en profondeur, parmi les outils les plus populaires figurent Pytorch ^[116], Tensorflow ^[117] et Keras ^[118]. Dans notre cas, la mise en œuvre et la formation des modèles de détection d'incendie CNNs et de toutes les expériences de test sont effectuées à l'aide de la bibliothèque Keras avec Tensorflow. TensorFlow est une bibliothèque open-source développée par Google, conçue pour le calcul numérique et l'apprentissage automatique. Il est particulièrement adapté aux applications d'intelligence artificielle. Keras offre une interface simple pour son utilisation. Leur combinaison permet de développer des modèles d'apprentissage en profondeur performants et faciles à implémenter en utilisant le langage Python ^[31]. L'exécution du code est effectuée en utilisant l'environnement Google Colaboratory (colab). Ce dernier est une plateforme de programmation en ligne développée par Google qui permet aux utilisateurs d'écrire et d'exécuter du code Python directement à partir d'un navigateur web, sans nécessiter d'installation locale. Colab offre des puissantes unités de traitement graphique GPU et unité de traitement de tenseurs TPU qui permet de réduire le temps d'exécution.

Dans cette étude, un GPU NVIDIA Tesla T4 a été utilisé afin d'accélérer le processus l'entraînement des modèles CNN de détection d'incendie proposé. La Figure III.11 présente les spécifications du (GPU) utilisé. Le GPU est un NVIDIA Tesla T4, doté de 15 Go de mémoire et fonctionnant avec la version CUDA 12.4 ainsi que le pilote 550.54.15. Lors des phases

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

d'entraînement, la consommation énergétique du GPU a atteint 9W, sur une capacité maximale de 70W, avec une utilisation variable en fonction de la charge de calcul requise.

Wed Feb 26 08:02:03 2025

NVIDIA-SMI 550.54.15			Driver Version: 550.54.15			CUDA Version: 12.4		
GPU	Name		Persistence-M	Bus-Id	Disp.A	Volatile	Uncorr. ECC	
Fan	Temp	Perf	Pwr:Usage/Cap		Memory-Usage	GPU-Util	Compute M.	
							MIG M.	
0	Tesla T4		Off	00000000:00:04.0	Off			0
N/A	36C	P8	9W / 70W	2MiB / 15360MiB		0%	Default	N/A

Processes:							
GPU	GI	CI	PID	Type	Process name	GPU Memory	
	ID	ID				Usage	
No running processes found							

Figure III.11. Spécifications du GPU utilisé pour la Formation des Modèles

III.4. Approche Proposée

Cette dernière décennie, des efforts ont été déployés pour améliorer la détection des incendies, mais le processus reste complexe, surtout lorsque les environnements de surveillance sont instables et difficiles à surveiller comme en présence de neige, de brouillard ou de fumée, ou que l'incendie est de très petite taille ou sur une longue distance. Dans de telles situations, généralement, les systèmes traditionnels de détection des incendies produisent un nombre important de fausses alarmes avec une précision limitée de détection des incendie ^[94].

Récemment, les réseaux de neurones convolutifs CNN qui sont des types spécialisés des réseaux de neurones sont les architectures les plus performantes pour la reconnaissance d'image et la détection d'objet obtenant une précision de classification élevé dans plusieurs domaines tel que le domaine médical ^[119], la biométrie ^[120], le domaine aéronautique ^[121], le domaine de la robotique ^[122]...etc. Ces approches basées sur CNN sont également utilisées pour la détection des incendies, mais leur temps de fonctionnement, leur grande taille et leurs performances limitées dans plusieurs situations difficiles, les rendent irréalisables pour les réseaux de surveillance aux ressources limitées. Pour surmonter ces limites, nous proposons donc une méthode peu coûteuse et efficace en termes de calcul basée sur des CNN légers sans couches

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

entièrement connectées pour la détection des incendies. Un aperçu de notre approche de détection des incendies dans les réseaux de surveillance est illustré dans la Figure III.12.




Figure III.12. Détection précoce des Incendies dans les Vidéos de Surveillance à l'aide de CNN

III.4.1. Détection d'incendie basée sur les CNN

Un CNN est conçu pour faire une tâche de classification à partir d'une base de données d'images. Le modèle CNN de détection d'incendie est composé de deux parties principales : ConvNet convolution et ConvNet classification comme illustré dans la Figure III.13. L'entrée d'un CNN sont des images qui sont représentées sous la forme de tenseurs tridimensionnels de taille $H \times W \times N$ pour des images en couleur comme illustré dans la Figure III.14, où H désigne la hauteur, W la largeur et N le nombre de canaux. Dans la première partie une série de noyaux de convolution de différentes dimensions sont appliqués à l'ensemble de données d'entrée pour produire des cartes de caractéristiques (feature maps). la convolution est effectuée en glissant un ensemble de filtres de convolution sur la matrice d'entrée, en effectuant une multiplication des valeurs adjacentes puis en les additionnant. Une fonction de non linéarité tel que Relu est appliquée aux résultats scalaires de convolution. Après chaque opération de convolution, des filtres de maxpooling sont appliqués afin de réduire les dimensionnalités spatiales des cartes de caractéristiques. Dans l'opération de convolution les couches agissent comme des extracteurs de caractéristiques. Les couches initiales apprennent les caractéristiques de bas niveau comme

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

les bords et les formes, les couches ultérieures deviennent plus abstraites et apprennent plus de texture et d'autres caractéristiques non interprétables humaines des images. La partie classification est composée de couche entièrement connectée qui reçoivent les caractéristiques abstraites à partir des couches précédentes pour faire une classification et détecter la présence du feu dans l'image.




Figure III.13. Exemple d'une architecture convnet pour la détection des incendies. Partie convolutionnelle et partie de classification

Image de Feu en Couleurs (RVB)




Figure III.14. Représentation matricielle de l'entrée d'un CNN pour une image RVB

III.4.2. Détails de l'architecture proposée pour la détection d'incendie

Dans le contexte de la détection des incendies, les études les plus récentes utilisent des CNNs très profonds, tels qu'Alexnet ^[17] avec 62,3 millions de paramètres, Google Net ^[18] avec 7 millions de paramètres et VGG-16 ^[19] avec 138 millions de paramètres. L'objectif principal de cette thèse est la détection précoce des incendies. L'algorithme développé doit être capable de détecter les incendies à un stade précoce et de minimiser simultanément le nombre de fausses alarmes. Pour atteindre cet objectif, nous avons étudié de nombreux CNN de détection précoce des flammes. Quatre modèles CNN légers efficaces sont choisis pour la tâche de classification des incendies et une méthode d'assemblage pour optimiser les performances des réseaux a été utilisée. Les modèles utilisent des couches de Global Average Pooling (GAP) au lieu de couches entièrement connectées ce qui permet de réduire le nombre de paramètres. Les architectures sont inspirées du travail ^[123], le premier modèle appelé CNN_A est le modèle de base. À partir de ce modèle, trois autres structures ont été dérivées respectivement : CNN_B, CNN_C et CNN_D. Ces modèles ont été obtenus en modifiant l'architecture du modèle de base (CNN_A) après la septième couche convolutif (Conv-A-7), en ajoutant d'autres couches comme les couches convolutifs, les couches maxpooling...etc. et en ajustant certains filtres de taille du noyau. Nous avons adapté les réseaux pour répondre au problème de classification des incendies en les ajustant afin que le modèle ne prenne en charge que deux classes : « feu » et « non-feu »

III.4.2.1. CNN_A

Le premier modèle appelé CNN_A est une minuscule architecture de réseaux de neurone convolutif, composé d'un ensemble de trois blocs de convolution, de deux max pooling et d'une couche GAP suivie par une couche d'activation. Le modèle obtient des images couleur de dimensions $(48 \times 48 \times 3)$. Chaque bloc convolutif est composé de trois couches convolutifs, au total, il y a neuf couches convolutifs. Dans le premier bloc, les trois couches convolutifs utilisent 96 filtres de taille (3×3) , sont appliqués sur l'ensemble de données d'entrée, produisant 96 cartes de caractéristiques. Le bloc suivant est composé de trois couches convolutifs avec 192 filtres de tailles (3×3) , ce qui donne 192 cartes de caractéristiques. Dans le troisième bloc, les deux premières couches convolutifs utilisent 192 filtres de convolution de taille (3×3) et (1×1) respectivement. La troisième couche convolutif utilise sept noyaux de taille (1×1) . Ce dernier est modifié pour résoudre le problème de classification d'image d'incendie, diminuant le nombre de noyaux à deux, correspondant à deux classes : « feu » et « non-feu ». Dans toutes les couches convolutifs, Le pas de convolution est de 1 et un remplissage

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

(padding) est appliqué afin de maintenir la taille des couches dans l'opération de convolution. Des couches de max-pooling de taille (3×3) avec un pas de 2 suivent les deux premiers blocs de convolution. Ces couches servent à diminuer la dimension des cartes d'activation. Le dernier bloc convolutif est introduit à une couche GAP. L'avantage de l'utilisation de cette couche de régularisation est d'éviter le sur-ajustement, en plus de ces couches d'autres techniques de régularisation sont utilisées dans le réseau telles que les couches Dropout et Batch Normalization. Enfin, une couche d'activation Softmax est ajoutée afin de faire la prédiction donnant un réseau de 1,37 million de paramètres. La structure du modèle CNN_A est représentée sur la Figure III.15. En complément, le tableau III.1 présente de manière détaillée la configuration des couches du modèle CNN_A, incluant les dimensions de sortie de chaque couche, le nombre de paramètres associés à chaque opération ainsi que le nombre total des paramètres du modèle.

III.4.2.2. CNN_B

Le modèle CNN_B a modifié la taille du filtre de la huitième couche convolutif du premier modèle de (1×1) à (3×3) , une autre couche convolutif a été ajoutée (Conv-B-9), en utilisant 256 noyaux de taille (1×1) . Le nombre total de paramètres du modèle est d'environ 1,71 million. L'architecture du réseau CNN_B est représentée sur la Figure III.16. Le tableau III.2 montre les différentes couches de l'architecture du réseau CNN_B, ainsi que leurs dimensions et paramètres.




Figure III.15. Description de l'architecture CNN_A pour la Classification des Incendies

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

Tableau III.1. Description détaillée de l'architecture du modèle de base (CNN-A), où w = largeur, h = hauteur et n = nombre de canaux

Couches	Dimensions sortie (w×h×n)	Nombre de paramètres
Entrée	48×48×3	0
Conv-A-1(3×3, 96)	48×48×96	2688
Conv-A-2(3×3, 96)	48×48×96	83040
Conv-A-3(3×3, 96)	48×48×96	83040
Normalisation	48×48×96	384
pooling A-1(3×3, s=2)	23×23×96	0
dropout	23×23×96	0
Conv-A-4(3×3, 192)	23×23×192	166080
Conv-A-5(3×3, 192)	23×23×192	331968
Conv-A-6(3×3, 192)	23×23×192	331968
Normalisation	23×23×192	768
pooling A-2(3×3, s=2)	11×11×192	0
dropout	11×11×192	0
Conv-A-7(3×3, 192)	11×11×192	331 968
Conv-A-8(1×1, 192)	11×11×192	37056
Conv-A-9(1×1, 2)	11×11×2	386
Normalisation	11×11×2	8
Global Average Pooling1	1×1×2	0
Activation Softmax1	1×1×2	0
Nombre total des paramètres	—	1369354




Figure III.16. Description de la structure du modèle CNN_B pour la classification des incendies

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

Tableau III.2. Description détaillée de l'architecture du modèle CNN-B, où w = largeur, h = hauteur et n = nombre de canaux

Couches	Dimensions sortie (w×h×n)	Nombre de paramètres
Conv-B-7(3×3, 192)	11×11×192	331 968
Conv-B -8(3×3, 192)	11×11×192	331 968
pooling B-1(3×3, s=2)	5×5×192	0
dropout	5×5×192	0
Conv-B -9(3×3, 256)	5×5×256	49408
Conv-B-10(1×1, 2)	5×5×2	514
Normalisation	5×5×2	8
Global Average Pooling2	1×1×2	0
Activation Softmax2	1×1×2	0
Nombre total des paramètres	—	1713802

III.4.2.3. CNN_C

Le modèle CNN_C, a modifié la taille des noyaux de la neuvième couche convolutif (Conv-C-9) du modèle précédent est modifiée à (3 × 3) et une autre couche convolutif (Conv-C-10) de 256 filtres de taille (1 × 1) est ajoutée en donnant 2,17 millions de paramètres comme indiqué sur la Figure III.17. Le tableau III.3 montre les différentes couches de l'architecture du réseau CNN_C, ainsi que leurs dimensions et paramètres.




Figure III.17. Description de la structure du modèle CNN_C pour la classification des incendies

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

Tableau III.3. Description détaillée de l'architecture du modèle CNN-C, où w = largeur, h = hauteur et n = nombre de canaux

Couches	Dimensions sortie (w×h×n)	Nombre de paramètres
Conv-C-7(3×3, 192)	11×11×192	331 968
Conv- C -8(3×3, 192)	11×11×192	331 968
pooling C -1(3×3, s=2)	5×5×192	0
dropout	5×5×192	0
Conv- C -9(3×3, 256)	5×5×256	442624
Conv- C -10(1×1, 256)	5×5×256	65792
Conv- C -11(1×1, 2)	5×5×2	514
Normalisation	5×5×2	8
Global Average Pooling3	1×1×2	0
Activation Softmax3	1×1×2	0
Nombre total des paramètres	—	2 172 810

III.4.2.4. CNN_D

La dernière architecture appelée CNN_D a changé la taille des noyaux de la dixième couche convolutif en (3 × 3) et a ajouté une couche convolutif (Conv-D-11) avec 512 noyaux de taille (1 × 1) résultant un réseau de 2,83 millions de paramètres comme indiqué dans la Figure III.18. Le tableau III.4 montre les différentes couches de l'architecture du réseau CNN_D, ainsi que leurs dimensions et paramètres




Figure III.18. Description de la structure du modèle CNN_D pour la classification des incendies

Chapitre III: Approche innovante basée sur un ensemble de réseaux de neurones convolutifs pour la détection des incendies

Tableau III.4. Description détaillée de l'architecture du modèle CNN-D, où w = largeur, h = hauteur et n = nombre de canaux

Couches	Dimensions sortie (w×h×n)	Nombre de paramètres
Conv-D-7 (3×3, 192)	11×11×192	331 968
Conv-D-8 (3×3, 192)	11×11×192	331 968
pooling D -1 (3×3, s=2)	5×5×192	0
dropout	5×5×192	0
Conv-D-9 (3×3, 256)	5×5×256	442624
Conv-D-10 (1×1, 256)	5×5×256	590080
dropout	5×5×256	0
Conv-D-11 (1×1, 512)	5×5×512	131584
Conv-D-12 (1×1, 2)	5×5×2	1026
Normalisation	5×5×2	8
Global Average Pooling4	1×1×2	0
Activation Softmax4	1×1×2	0
Nombre total des paramètres	—	2 829 194

III.4.3. Apprentissage d'Ensemble

En apprentissage automatique plusieurs algorithmes d'apprentissage d'ensemble peuvent être utilisés afin d'améliorer la performance des algorithmes profonds et obtenir un classificateur plus performant. Pour notre problème de détection des incendies, une stratégie d'ensemble a été utilisée qui combine les prédictions de fonction Softmax des quatre modèles proposés pour obtenir un modèle avec de meilleures performances de classification du feu. Cette combinaison se fait en calculant la moyenne de prédiction des quatre modèles, comme décrit dans l'équation (III.1) ^[124], où $A(y_i / x_i)$ est la distribution de probabilité de l'ensemble, et K est le nombre de modèles uniques qui construisent l'ensemble.

$$A\left(\frac{y_i}{x_i}\right)_{ens} = \frac{1}{K} \sum \frac{\exp(z_{yi})}{\sum \exp(z_{yj})} \quad (III.1)$$

Dans un premier temps, les quatre modèles CNNs unique (**CNN_A, CNN_B, CNN_C et CNN_D**) ont été formés sur l'ensemble de données d'entraînement, ensuite tous les ensembles possibles ont été construits à partir des modèles uniques. (**CNN_AB, CNN_AC, CNN_AD, CNN_BC, CNN_BD, CNN_CD, CNN_ABC, CNN ABD, CNN_BCD, CNN_CAD et CNN_ABCD**).

III.5. Conclusion

Dans ce chapitre, nous avons présenté en détail la méthodologie proposée pour la détection d'incendies à partir d'images. Cette méthode repose sur l'apprentissage profond, à travers la conception de quatre architectures de réseaux de neurones convolutifs : CNN_A, CNN_B, CNN_C et CNN_D. Une attention particulière a été accordée à la constitution d'un ensemble de données diversifié, issu de sources variées telles que des bases de données publiques, des images collectées en ligne et des extraits de vidéos. Pour améliorer la robustesse des modèles, des techniques d'augmentation des données ont été appliquées, suivies d'un fractionnement structuré des données en ensembles d'entraînement, de validation et de test. Les modèles CNN ont été entraînés afin d'identifier automatiquement les caractéristiques visuelles discriminantes entre les images contenant du feu et celles qui n'en contiennent pas. Enfin, une stratégie d'apprentissage d'ensemble a été adoptée, dans le but de combiner les performances de chaque modèle et d'améliorer la précision globale de la classification.

Cette approche basée sur les CNN constitue une alternative moderne et efficace aux méthodes classiques. Le chapitre suivant sera consacré à l'analyse des performances expérimentales de ces modèles, afin d'évaluer leur fiabilité et leur efficacité dans un contexte réel de détection précoce d'incendie.

Chapitre IV

Résultats et discussion

Sommaire du chapitre :

IV.1. Introduction	69
IV.2. Résultats et Discussion	69
IV.2.1. Détails des ensembles de tests	69
IV.2.1.1. L'ensemble de test 1 (T-1)	69
IV.2.1.2. L'ensemble de test 2 (T-2)	70
IV.2.2. Métriques d'évaluation.....	71
IV.2.3. Évaluation des Modèles.....	73
IV.2.4. Comparaison des Résultats et Analyse des Performances.....	80
IV.2.4.1. Comparaison des approches de détection d'incendie existantes sur T-1	81
IV.2.4.2. Comparaison des approches de détection d'incendie existantes sur T-2	81
IV.2.4.3. Analyse de la complexité computationnelle	83
IV.3. Conclusion.....	87

IV.1. Introduction

Ce chapitre détaille l'évaluation expérimentale de l'approche proposée. Il débute par une présentation des ensembles de test ainsi que les différentes métriques d'évaluation utilisées pour mesurer les performances des modèles. Ensuite, une analyse des résultats expérimentaux est menée, en comparant les performances des réseaux proposés à d'autres approches, notamment en termes de précision, de rappel, d'exactitude, de rapidité (FPS) et de complexité des modèles sont présentés dans les sections 2.3 et 2.4. Enfin, des résultats visuels de classification d'incendie sont intégrés afin d'illustrer plus clairement l'efficacité du système proposé.

IV.2. Résultats et Discussion

Cette partie présente les résultats des tests et de la comparaison des modèles uniques et d'ensemble pour déterminer les meilleurs modèles. La stratégie de Muhammad K et al ^[14] a été suivie pour analyser les performances de nos modèles axés sur deux ensembles de tests ^[20,21]. Par la suite, les résultats de nos meilleurs modèles sont comparés aux approches existantes de détection des incendies. La discussion sur les ensembles de tests, les expériences sur l'ensemble de test 1, l'ensemble de test 2 et l'analyse de complexité des modèles est décrite dans les sous-sections suivantes.

IV.2.1. Détails des ensembles de tests

Deux ensembles de tests sont utilisés pour l'analyse des performances des modèles proposés : l'ensemble de test 1 ^[21] et l'ensemble de test 2 ^[20].

IV.2.1.1. L'ensemble de test 1 (T-1)

L'ensemble de test 1 (Foggia) ^[21] collecte une base de données de 31 vidéo clips dans différentes scènes dans des environnements intérieurs et extérieurs. Les 14 premières vidéos contiennent des incendies. Les 17 dernières vidéos incluent différentes situations de non-feu. Le laboratoire de recherche MIVIA ^[125] de l'Université de Salerne, situé à Fisciano en Italie, a été contacté afin d'obtenir un accès à cet ensemble de données sur les incendies. T-1 est difficile pour les méthodes de détection d'incendie basées seulement sur les couleurs et les mouvements, car il contient des vidéos d'objets ressemblant à des flammes ainsi que de montagnes couvertes de fumée et de nuages. Par exemple, les 17 dernières vidéos contiennent des objets et des situations semblables à des incendies, qui peuvent être prédits comme des incendies, ce qui rend la classification plus difficile. Pour cela, les méthodes basées sur la couleur ne peuvent pas faire

Chapitre IV. Résultats et discussion

la différence entre un feu réel et des scènes avec des objets de couleur rouge. De même, les techniques basées sur le mouvement peuvent classer les montagnes contenant de la fumée, des nuages ou du brouillard comme des incendies. Cette complexité constitue l'une des principales motivations de la sélection de cet ensemble de données pour les tests qui permet d'étudier les performances des algorithmes proposés dans diverses situations de l'environnement réel. L'ensemble de test 1 comprend un total de 62 690 images, dont 11 201 échantillons positifs et 51 489 échantillons négatifs. Des exemples d'images de T-1 sont présentés dans la Figure IV.1.

La Figure IV.1 (a) montre des exemples d'images positives de TestSet1, où certaines images montrent des incendies significatifs tandis que d'autres représentent des incendies plus petits. On peut noter à partir des images fournies que l'ensemble de données contient des images appartenant à la fois aux environnements intérieurs et extérieurs. Un autre défi introduit dans l'ensemble de données est la distance entre le feu et la caméra.



Figure IV.1. Exemples d'images illustrant les incendies et des scénarios non-feu de l'ensemble de test 1

La Figure IV.1 (b) illustre des exemples d'images négatifs de T-1. Il y a des objets de couleur rouge ressemblant à un incendie, tels que le soleil et de l'herbe rougeâtre dans ces images.

IV.2.1.2. L'ensemble de test 2 (T-2)

Le deuxième ensemble de test utilisé dans cet article est Bowfire. Ce dernier contient 226 images parmi elles 119 échantillons positifs et 107 échantillons négatifs. T-2 est petit mais très difficile car il contient des scénarios non-feu similaires au feu (coucher de soleil, objets de couleur rouge et des éclairages de couleur du feu dans différents bâtiments), ce qui rend cet ensemble de données très difficile ; C'est la principale raison du choix de cet ensemble de

Chapitre IV. Résultats et discussion

données pour les tests. Une sélection d'images de TestSet2 est présentée dans la Figure IV.2. La Figure IV.2 (a) montre des échantillons de feu de Bowfire et la Figure IV.2 (b) illustre des échantillons normaux de cet ensemble de teste ressemblant à des flammes.




Figure IV.2. Exemples d'images illustrant les incendies et les scénarios non-feu de L'ensemble de test 2

IV.2.2. Métriques d'évaluation

Pour évaluer les performances des CNNs proposées sur l'ensemble de test 1 et l'ensemble de test 2 et déterminer les meilleurs modèles, plusieurs métriques sont calculées, notamment l'exactitude (E), la sensibilité (S), la précision (P), le FP (%), le FN (%) et le F1 score (F) en utilisant les valeurs des TP, TN, FP et FN. Où TP sont les vrais positifs, TN sont les vrais négatifs FP sont les faux positifs et FN sont les faux négatifs. Ces valeurs sont obtenues à partir des matrices de confusions (cm) de chaque modèle.

Pour notre problème de détection d'incendie deux classes sont prédite « feu » pour une image qui contient du feu et « non-feu » pour une image sans feu. TP sont des images de feu correctement prédites et TN sont des images sans feu correctement prédites. FP sont des images sans feu prédites comme des images de feu et FN sont des images de feu prédites comme des images qui ne contiennent pas de feu.

Pour évaluer les prédictions des modèles proposés, l'exactitude a été étudiée. L'exactitude de notre système qui est la métrique principale est le rapport des prédictions correctes sur l'ensemble de prédictions. Cette métrique est calculée par la formule suivante :

$$E = \frac{TP + TN}{TP + TN + FP + FN} \quad (IV.1)$$

Chapitre IV. Résultats et discussion

Pour la détection des incendies, l'exactitude n'est pas suffisante pour évaluer les performances des modèles, car si la majorité des images sont de la classe non-feu, un modèle pourrait obtenir un bon score simplement en prédisant toujours non-feu, sans réellement être capable de détecter les incendies. Par conséquent, une évaluation plus détaillée du modèle est nécessaire. C'est pourquoi d'autres métriques sont essentielles pour mieux évaluer la performance du modèle et garantir une détection fiable des incendies.

En détection d'incendie, deux mesures sont particulièrement importantes : le taux de faux positifs (FP%) et le taux de faux négatifs (FN%).

- **Le taux de faux positifs (FP%)** représente la proportion des images sans incendie qui sont incorrectement classées comme contenant un incendie. Un FP% élevé signifie que l'algorithme déclenche trop d'alarmes inutiles, ce qui peut entraîner une intervention inutile des services d'urgence. Il se calcule à l'aide de la formule suivante :

$$FP\% = \frac{FP}{FP + FN} \quad (IV.2)$$

- **Le taux de faux négatifs (FN%)** mesure la proportion des images contenant réellement un incendie mais qui ne sont pas détectées par l'algorithme. Un FN% élevé est dangereux, car il signifie que des incendies risquent de ne pas être détectés à temps. Cette métrique se calcule à l'aide de la formule suivante :

$$FN\% = \frac{FN}{TP + FN} \quad (IV.3)$$

Un bon algorithme de détection d'incendie doit avoir un FP% faible afin d'éviter les fausses alarmes et un FN% faible afin d'identifier correctement les incendies.

La précision et la sensibilité (ou le rappel) sont deux métriques importantes, la première permet d'identifier la capacité des modèles proposée à ne pas classer des images sans feu comme incendie et la deuxième permet de mesurer la capacité des modèles proposée à classer correctement les images d'incendies. Une précision faible signifie que le modèle génère trop de fausses alarmes et un rappel faible signifie que le modèle ne détecte pas tous les incendies réels. Ces deux métriques sont combinées dans le F1 score qui est la moyenne pondérée de la sensibilité et la précision. Le F1 score équilibre les deux métriques précédentes et donne une

Chapitre IV. Résultats et discussion

vision globale des performances des modèles. Toutes les métriques ci-dessus sont calculées par les formules suivantes :

$$P = \frac{TP}{TP + FP} \quad (IV.4)$$

$$S = \frac{TP}{TP + FN} \quad (IV.5)$$

$$F = 2 \times \frac{P \times S}{P + S} \quad (IV.6)$$

IV.2.3. Évaluation des Modèles

Les résultats obtenus en utilisant les quatre algorithmes uniques (**CNN_A**, **CNN_B**, **CNN_C** et **CNN_D**) et les algorithmes d'ensembles (**CNN_AB**, **CNN_AC**, **CNN_AD**, **CNN_BC**, **CNN_BD**, **CNN_CD**, **CNN_ABC**, **CNN ABD**, **CNN_BCD**, **CNN CAD** et **CNN ABCD**), sont résumées dans cette sous-section. Les réseaux CNN sont formés à l'aide de notre ensemble de données et évalués avec deux ensembles d'images de teste (T-1 et T-2). Le tableau IV.1 représente les résultats obtenus par les modèles proposés unique et d'ensemble sur les deux ensembles de tests. CM pour les quatre modèles uniques et les ensembles proposés pour la détection des incendies sur T-1 et T-2 sont illustrés dans les Figure IV.3, Figure IV.4, Figure IV.5 et Figure IV.6 respectivement. Selon les résultats rapportés dans le tableau IV.1, les modèles proposés ont obtenu de bons résultats sur les deux ensembles de tests T-1 et T-2. Le meilleur modèle unique CNN_C atteint une excellente exactitude de 99,55 % et 1,09 % de FN sur T-1, atteignant une précision de 99,09 %, avec un taux de fausse alarme de 0,93% sur T-2. Ensuite, en appliquant une stratégie d'ensemble aux modèles uniques, la meilleure exactitude sur T-2 est obtenue par algorithme CNN_AD, cependant, la valeur d'exactitude de cet algorithme sur T-1 est inférieure à celle des autres CNN. Le meilleur modèle d'ensemble est CNN_BC, qui a une exactitude de 99,69 %, et un FN %de 0,91% sur T-1, atteignant une précision de 98,24 sur T-2. Les modèles CNN_C et CNN_BC ont obtenu des résultats encourageants sur les deux ensembles de tests, confirmant l'efficacité de ces algorithmes. Les Figure IV.7 et IV.8 illustrent les résultats de la prédiction visuelle des algorithmes proposés, CNN_C et CNN_BC, sur des images difficiles d'incendie et normal respectivement. L'image s'accompagne par des probabilités calculées pour chaque modèle pour les deux classes : « feu » et « normal ».

Chapitre IV. Résultats et discussion

Tableau IV.1. Performances de classification obtenues pour les modèles CNN uniques et d'ensemble sur T-1 et T-2. Les meilleurs résultats sont indiqués en rouge gras et deuxièmes meilleurs résultats sont indiqués en noir gras

Modèles		T-1			T-2				
		E (%)	FP (%)	FN (%)	E (%)	FP (%)	P (%)	S (%)	F (%)
Modèles Uniques	CNN_A	92,42	0,16	41,63	96,9	2,8	97,45	96,63	97,03
	CNN_B	98.47	0.11	8	94.69	10.28	91.47	99.16	95.16
	CNN_C	99.55	0.3	1.09	95.57	0.93	99.09	92.43	95.64
	CNN_D	98.75	0.08	6.55	94.24	5.6	94.91	94.11	94.50
Modèles Ensemble	CNN_AB	95.81	0	23.4	96.9	3.73	96.66	97.47	97.06
	CNN_AC	98.99	0	5.64	96.01	1.86	98.24	94.11	96.13
	CNN_AD	94.34	0	31.67	97.34	1.86	98.29	96.63	97.45
	CNN_BC	99.69	0.17	0.91	96.01	1.86	98.24	94.11	96.13
	CNN_BD	98.95	0.29	4.5	93.80	6.54	94.11	94.11	94.11
	CNN_CD	99.55	0.11	1.88	95.57	1.86	98.23	93.27	95.68
	CNN_ABC	99.50	0.24	1.64	96.47	1.86	98.26	94.95	96.57
	CNN_ABD	97.99	0	11.19	95.57	5.6	95.04	96.63	95.82
	CNN_ACD	98.54	1.52	1.13	95.57	1.86	98.23	93.27	95.68
	CNN_BCD	96.97	0	16.92	95.13	4.67	95.76	94.95	95.35
	CNN_ABCD	99.07	0.88	1.11	96.01	2.8	97.41	94.95	96.16

Chapitre IV. Résultats et discussion




Figure IV.3. Matrice de confusion des modèles CNN uniques proposés pour la classification des incendies sur T-1. (a) CNN_A, (b) CNN_B, (c) CNN_C, (d) CNN_D

Chapitre IV Résultats et discussion




Figure IV.4. Matrice de confusion des CNN d'ensemble proposés pour la classification des incendies sur T-1. (a) CNN_AB, (b) CNN_ABC, (c) CNN_ABCD, (d) CNN_ABD, (e) CNN_AC, (f) CNN_ACD, (g) CNN_AD, (h) CNN_BC, (i) CNN_BCD, (j) CNN_BD, (k) CNN_CD

Chapitre IV. Résultats et discussion




Figure IV.5. Matrice de confusion des modèles CNN uniques proposés pour la classification des incendies sur T-2. (a) CNN_A, (b) CNN_B, (c) CNN_C, (d) CNN_D

Chapitre IV. Résultats et discussion




Figure IV.6. Matrice de confusion des CNN d'ensemble proposés pour la classification des incendies sur T-2. (a) CNN_AB, (b) CNN_ABC, (c) CNN_ABCD, (d) CNN_ABD, (e) CNN_AC, (f) CNN_ACD, (g) CNN_AD, (h) CNN_BC, (i) CNN_BCD, (j) CNN_BD, (k) CNN_CD

Entrée (Exemples d'images d'incendie)	Classe originale	Classe prédite	
		Le modèle CNN_C	Le modèle CNN_BC
	Feu	Feu: 93,69% Normal :6,31%	Feu:96,57% Normal : 3,43%
	Feu	Feu:80,79% Normal :19,21%	Feu:85,68% Normal :14,32%
	Feu	Feu:99,84% Normal :0,16%	Feu:99,85% Normal :0,15%
	Feu	Feu:99,37% Normal :0,63%	Feu:99,64% Normal : 0,36%

Figure IV.7. Scores de prédiction des algorithmes proposés les plus performants, CNN_C et CNN_BC, sur les images d'incendie difficiles

Entrée (Exemple d'image)	Classe originale	Classe prédite	
		Le modèle CNN_C	Le modèle CNN_BC
	Normal	Feu:25,99% Normal :74,01%	Feu:13,82% Normal :86,18%
	Normal	Feu:12,28% Normal :87,72%	Feu:22,39% Normal :77,61%
	Normal	Feu:11,56% Normal :88,44%	Feu:25,45% Normal :74,55%
	Normal	Feu:33,37% Normal :66,63%	Feu:22,40% Normal :77,60%

Figure IV.8. Scores de prédiction des algorithmes proposés les plus performants, CNN_C et CNN_BC, sur les images normales difficiles

IV.2.4. Comparaison des Résultats et Analyse des Performances

Chapitre IV. Résultats et discussion

Cette section compare les résultats obtenus dans cette thèse à ceux rapportés dans des travaux similaires. Cette évaluation s'appuie sur la comparaison de l'approche proposée avec différentes approches existantes de détection d'incendie sur l'ensemble de test1 et l'ensemble de test 2, ainsi que sur l'analyse de la complexité computationnelle.

IV.2.4.1. Comparaison des approches de détection d'incendie existantes sur T-1

Dans cette sous-section, les résultats de nos meilleurs modèles sont comparés à différentes approches existantes. Le Tableau IV.2 montre une comparaison en termes d'exactitude, FP (%) et FN (%) de diverses méthodes de détection d'incendie à l'aide de T-1. Selon les résultats, les méthodes de détection des incendies utilisant l'apprentissage en profondeur (de 5 à 11 dans le Tableau IV.2) obtiennent les meilleures performances que celles utilisant des algorithmes traditionnels (de 1 à 4 dans le Tableau IV.2). Le meilleur taux de faux positif est obtenu par le septième algorithme ^[94] Cependant, la valeur d'exactitude de cet algorithme est inférieure à celle des travaux récents. Ahmad K et al ^[126] ont obtenu une bonne valeur de FP (%) et FN (%). L'algorithme le plus précis est celui de Zheng Het al ^[127], avec une précision de 98,32%, un taux FN de 0 et un taux FP de 1,23%. Le modèle proposé CNN_C atteint une excellente valeur d'exactitude de 99,55%, ce qui dépasse les travaux existants. Le modèle d'ensemble CNN_BC atteint une meilleure valeur d'exactitude de 99,69%, ce qui est plus élevé par rapport aux travaux précédents, ainsi que la réduction du taux de faux positifs de 1,23% à 0,17 par rapport à Zheng Het al ^[127]. L'évaluation sur l'ensemble de tests 1 met en évidence l'excellente robustesse des algorithmes proposés.

IV.2.4.2. Comparaison des approches de détection d'incendie existantes sur T-2

Dans cette sous-section, les modèles suggérés sont comparés à diverses approches de détection d'incendies, y compris les méthodes traditionnelles et les approches basées sur l'apprentissage profond, en utilisant T-2. Des métriques telles que le taux de FP, E, S, P et F sont calculés pour ces modèles. Le Tableau IV.2 présente les résultats obtenus à partir de ces différentes approches sur T-2. Les résultats montrent que les modèles proposés CNN_C et CNN_BC surpassent tous les algorithmes traditionnels de détection d'incendie en termes de P, S et F. La meilleure méthode en termes de E et F est celle de Taimoor K et al ^[103]. Zheng H, et al. ^[127] obtiennent le meilleur score de S ; cependant le P de cet algorithme est inférieur aux travaux précédents. Une amélioration supplémentaire a été atteinte à l'aide des modèles suggérés, augmentant le P de 97,05 à 99,09 avec réduction du FP (%) de 2,8 à 0,93 pour le modèle proposé CNN_C et augmentant le P de 97,05 à 98,24 pour l'algorithme proposé

Chapitre IV. Résultats et discussion

CNN_BC avec la réduction de la FP (%) de 2,8 à 1,86 comparé à la meilleure approche ^[103] . Bien que les modèles proposés ont une sensibilité faible par rapport aux deux derniers algorithmes, ils ont maintenu toujours un meilleur équilibre entre E, FP (%), P et F. Les modèles proposés sont bons par rapport aux études récemment publiées pour la détection des incendies sur T-2, atteignant un score élevé en termes de précision et de réduction du taux de fausses alarmes.

Tableau IV.2. Comparaison des performances des modèles proposés CNN_C et CNN_BC avec diverses méthodes de détection d'incendie sur le T-1. Les meilleurs résultats sont indiqués en rouge gras et deuxièmes meilleurs résultats sont indiqués en noir gras

N°	Algorithmes	FP (%)	FN (%)	E (%)
1	Celik T et al. (2009) ^[128]	29.41	0	83.87
2	Rafiee A et al.(2011) ^[129]	17.65	7.14	87.10
3	De Lascio R et al.(2014) ^[75]	13.33	0	92.86
4	Foggia P et al.(2015) ^[21]	11.67	0	93.55
5	Muhammad K et al.(2018) (Alex Net) ^[92]	9.07	2.13	94.39
6	Muhammad K et al.(2018) (Google Net) ^[14]	0.054	1.5	94.43
7	Muhammad K et al.(2019) (Mobile Net) ^[94]	0	0.14	95.86
8	Kim B and Lee J.(2019) ^[99]	2.47	1.38	97.92
9	Ahmad K et al.(2022) ^[126]	0.042	0.034	97.20
10	Zheng H, et al. (2023) ^[130]	-	-	96.81
11	Zheng H, et al.(2024) ^[127]	1.23	0	98.32
12	Modèle proposé CNN_C	0.3	1.09	99.55
13	Modèle proposé CNN_BC	0.17	0.91	99.69

Chapitre IV. Résultats et discussion

Tableau IV.3. Comparaison des performances des modèles proposés CNN_C et CNN_BC avec diverses méthodes de détection d'incendie sur le T-2. Les meilleurs résultats sont indiqués en rouge gras et deuxièmes meilleurs résultats sont indiqués en noir gras

N°	Algorithmes	E (%)	FP (%)	P (%)	S (%)	F (%)
1	Celik T et al. (2009) ^[128]	-	-	55	54	54
2	Rossi A et al.(2011) ^[80]	-	-	39	22	28
3	Chino et al.(2015) ^[20] (Bowfire)	-	-	51	65	57
4	Muhammad K et al.(2018) (AlexNet) ^[92]	88.05	23.36	82.39	98.31	89.64
5	Muhammad K et al.(2018) (Google Net) ^[14]	84.96	24.29	80	93.27	86.71
6	Muhammad K et al.(2019) (Mobile Net) ^[94]	92.03	9.34	90	93.27	92
7	Chaoxia et al.(2020) ^[100]	93.36	5.61	95	92.44	94
8	H.Pan et al.(2020) ^[131]	93.36	4.67	95.61	91.60	93.56
9	Ahmad K et al.(2022) ^[126]	94.42	1.88	-	-	-
10	Zheng H, et al. (2023) ^[130]	-	-	88	97	92
11	Taimoor K et al.(2023) ^[103]	97.82	2.8	97.05	98.15	97.77
12	Zheng H, et al.(2024) ^[127]	-	-	94	99	95
13	Modèle proposé CNN_C	95.57	0.93	99.09	92.43	95.64
14	Modèle proposé CNN_BC	96.01	1.86	98.24	94.11	96.13

IV.2.4.3. Analyse de la complexité computationnelle

Cette sous-section présente une évaluation détaillée de l'approche proposée en termes de complexité computationnelle, en suivant la stratégie de Taimoor Khan^[103], axée sur la taille du modèle (en MB), la vitesse de détection (FPS) et le nombre d'opérations en virgule flottante (MFLOP). Le nombre de paramètres des modèles proposés est également mentionné.

Le MFLOP indique la complexité computationnelle d'un modèle. Il s'agit du nombre estimé d'opérations à virgule flottante nécessaires pour traiter une seule image. Un nombre plus faible indique une meilleure efficacité, notamment pour une exécution sur CPU ou sur des plateformes à ressources limitées. La vitesse de détection représente la vitesse moyenne d'inférence du modèle, mesurée en images par seconde (FPS) lorsqu'il est exécuté sur un processeur (CPU). Une vitesse élevée est cruciale pour les systèmes de détection en temps réel.

Chapitre IV. Résultats et discussion

La taille du modèle correspond à l'espace disque occupé par le modèle. Une taille réduite facilite le déploiement sur des appareils embarqués ou dans des environnements à mémoire limitée. Le nombre total de paramètres influence à la fois la mémoire nécessaire pour stocker le modèle et le temps requis pour l'entraînement. Un modèle avec moins de paramètres peut être plus rapide, mais aussi potentiellement moins performant s'il est trop simplifié.

Les résultats de nos modèles efficaces sont comparés à diverses approches à architecture légères de détection d'incendie basées sur l'apprentissage profond, dans le Tableau IV.4, dont les algorithmes 1 à 5 sont extraits de la référence ^[103]. Les graphiques 9, 10 et 11 illustrent respectivement la comparaison des MFLOPs, des images par seconde (FPS) et de la taille du modèle (Mo) pour les différentes méthodes testées, y compris nos deux modèles proposés.

Les résultats du Tableau IV.4 montrent que les deux premiers algorithmes ont un nombre élevé de MFLOP et une grande taille. Les algorithmes de Muhammad K et al.^[94] et de Songbin L et al.^[132] présentent une taille réduite, mais ont un nombre élevé de FLOP, avec un nombre minimal d'images par seconde, entraînant des retards notables dans la détection. Le modèle de Taimoor Khan atteint un FPS de 14,32, ce qui indique une forte capacité de traitement en temps réel comparée aux autres modèles, qui varient entre 2,4 et 4,3 FPS. Toutefois, cette performance s'accompagne d'une taille de modèle importante, ce qui pourrait constituer une contrainte pour les applications à mémoire limitée. Une efficacité de calcul significative est obtenue avec l'algorithme proposé CNN_C, qui combine un nombre relativement faible de MFLOP (18,39), une valeur élevée de FPS (18,83) et une meilleure efficacité énergétique grâce à une taille de 8,28 Mo. L'algorithme CNN_BC proposé a obtenu une valeur de MFLOP inférieure par rapport aux autres algorithmes et surpasse les quatre premières méthodes en termes de vitesse de détection

La Figure IV.9 compare les MFLOPs des différents modèles. Les approches de Sharma et al. (2017) et Muhammad et al. (2018) présentent une complexité élevée, atteignant respectivement 3800 M et 1500 M de MFLOPs. Cela les rend peu adaptés à une exécution en temps réel, notamment sur des dispositifs embarqués. Les modèles proposés CNN_C (18,39 MFLOPs) et CNN_BC (36,56 MFLOPs) montrent une excellente réduction de la complexité computationnelle. Cette réduction confirme que l'architecture proposée est non seulement performante mais également légère en termes de charge de calcul.

La Figure IV.10 compare la vitesse d'inférence sur CPU. Le modèle CNN_C se démarque avec un FPS de 18,83, surpassant les autres modèles. Ce résultat met en évidence la capacité de

Chapitre IV. Résultats et discussion

CNN_C à fonctionner en temps réel CNN_BC, maintient un bon FPS (9,35) par rapport aux autres approches, ce qui le rend également fiable dans un contexte pratique. Ces performances sont particulièrement intéressantes pour une utilisation dans des systèmes de surveillance en direct.

La Figure IV.11 présente la taille mémoire des modèles. Les approches de Sharma et al. (98 Mo), Muhammad et al. (43,3 Mo), sont relativement lourdes ce qui limite leur déploiement dans des environnements contraints. Nos deux modèles se distinguent une fois avec une taille réduite : CNN_C occupe seulement 8,28 Mo, tandis que CNN_BC atteint 14,81 Mo. Cette faible mémoire facilite l'implémentation sur des systèmes embarqués à mémoire limitée.

Tableau IV.4. Analyse comparative de la complexité des algorithmes proposés CNN_C et CNN_BC avec la littérature : Mflops, FPS et taille du modèle. Les meilleurs résultats sont indiqués en rouge gras et deuxièmes meilleurs résultats sont indiqués en noir gras

N°	Algorithmes	MFLOPs (M)	Vitesse de détection (CPU)	Taille du modèle (MB)	Nombre de paramètres (M)
1	Sharma J et al. (2017) ^[108]	3800	2.4	98	-
2	Muhammad K et al.(2018) (Google Net) ^[14]	1500	4.3	43.30	-
3	Muhammad K et al.(2019) (Mobile Net) ^[94]	300	2.4	13	-
4	Songbin L et al. (2020) ^[132]	1130	3	4.8	-
5	Taimoor K et al.(2023) ^[103]	125.71	14.32	74.43	-
13	Modèle proposé CNN_C	18.39	18.83	8.28	2.17
14	Modèle proposé CNN_BC	36.56	9.35	14.81	3.88




Figure IV.9. Comparaison de la complexité computationnelle (MFLOPs)




Figure IV.10. Comparaison de la vitesse de détection sur CPU (FPS)




Figure IV.11. Comparaison de la taille des modèles (en mégaoctets)

IV.3. Conclusion

Dans ce chapitre, nous avons évalué les performances des quatre modèles CNN proposés pour la détection d'incendie à l'aide de deux ensembles de test (T-1 et T-2). Les résultats obtenus ont été analysés à l'aide de plusieurs métriques d'évaluation, telles que la précision, le rappel, le score F1 et l'exactitude. L'évaluation a montré que les modèles offrent de bons résultats dans l'ensemble, avec une capacité à détecter le feu, tout en minimisant les fausses détections. Parmi les quatre architectures, certaines ont une meilleure performance.

Une comparaison avec des approches existantes a également été réalisée, confirmant l'efficacité de la méthode proposée. De plus, une analyse de la complexité computationnelle a permis d'identifier les modèles les plus adaptés à une mise en œuvre en conditions réelles. Ces résultats confirment la pertinence de l'approche proposée et ouvrent la voie à son intégration dans un système de détection d'incendie intelligent, capable de fonctionner en temps réel et avec une grande fiabilité.

Conclusion générale

Cette thèse vise à développer un système de détection d'incendie efficace, léger et adapté aux environnements contraints. Selon la littérature, il existe de nombreuses méthodes récentes de détection d'incendie basées sur l'apprentissage profond. Ces méthodes présentent plusieurs avantages, mais elles restent limitées par leur complexité computationnelle et leur capacité à détecter les incendies à un stade précoce. L'objectif principal était de proposer une approche basée sur l'apprentissage profond, capable de détecter les incendies dès leurs premiers stades, tout en comblant les lacunes identifiées dans les travaux précédents.

Le travail a commencé par une analyse approfondie des notions fondamentales liées à l'incendie et des approches classiques et modernes de détection. Les caractéristiques des différents types d'incendies, les bases du traitement d'images et de l'intelligence artificielle, en particulier les réseaux de neurones convolutifs (CNN), ont été étudiées en détail. Une étude comparative des systèmes de détection existants, allant des capteurs conventionnels aux méthodes avancées basées sur la vision par ordinateur, a permis d'identifier les limites des approches traditionnelles et des systèmes récents.

La contribution principale de cette thèse réside dans le développement d'un ensemble de quatre CNN légers et efficaces pour la classification d'incendie (CNN_A, CNN_B, CNN_C et CNN_D). Ces architectures ont été entraînées sur un ensemble de données diversifié, composé d'images réelles d'incendie et de scènes non-feu, enrichi par des techniques d'augmentation d'images. Une stratégie d'apprentissage d'ensemble a été introduite afin de combiner les prédictions des quatre réseaux, optimisant ainsi la précision globale et réduisant le taux de fausses alarmes. L'implémentation a été réalisée avec Python et la bibliothèque Keras/TensorFlow pour la classification d'images.

Les résultats expérimentaux obtenus sur deux ensembles de test de référence (T-1 et T-2) ont montré que les modèles proposés offrent une capacité élevée à détecter le feu, tout en minimisant les erreurs de classification. La comparaison avec les approches existantes a confirmé l'efficacité de la méthode proposée. L'analyse de la complexité computationnelle a permis d'identifier les modèles les plus adaptés à une mise en œuvre en conditions réelles, démontrant un compromis favorable entre rapidité de détection et précision. Ces résultats valident la fiabilité du système de détection d'incendie proposé.

En conclusion, cette thèse démontre la faisabilité et l'efficacité du système de détection d'incendie proposé. Le système développé combine la légèreté, la précision et la rapidité, offrant une solution adaptée aux applications réelles. Les résultats obtenus confirment la pertinence de l'approche et constituent une base solide pour des travaux futurs visant à améliorer encore la détection précoce et la sécurité des personnes et des infrastructures.

Bibliographies

1. *LE TRIANGLE DU FEU*. (s. d.). Consulté 19 septembre 2025, à l'adresse <https://fr.linkedin.com/pulse/le-triangle-du-feu-james-roussel>
2. Kaabi, R. (s. d.). *Apprentissage profond et traitement d'images pour la détection de fumée*.
3. *BEKKARI Lakhdar.pdf*. (s. d.). Consulté 2 septembre 2025, à l'adresse <https://dspace.univ-ouargla.dz/jspui/bitstream/123456789/30829/1/BEKKARI%20Lakhdar.pdf>
4. Posch, D., & Rask, J. (2019). *A multimodal deep learning approach for real-time fire detection in aerial imagery*. <https://odr.chalmers.se/bitstream/20.500.12380/257214/1/257214.pdf>
5. *Artificial Neural Network : Beginning of the AI revolution | HackerNoon*. (s. d.). Consulté 13 septembre 2025, à l'adresse <https://hackernoon.com/artificial-neural-network-a843ff870338>
6. *Qu'est-ce qu'un réseau de neurones convolutifs ? | IBM*. (2021, octobre 6). <https://www.ibm.com/fr-fr/think/topics/convolutional-neural-networks>
7. Blotta, E., Bouchet, A., Ballarin, V., & Pastore, J. (2011). Enhancement of medical images in HSI color space. *Journal of Physics: Conference Series*, 332. <https://doi.org/10.1088/1742-6596/332/1/012041>
8. Pandey, B., Pandey, D. K., Mishra, B. P., & Rhmann, W. (2022). A comprehensive survey of deep learning in the field of medical imaging and medical natural language processing : Challenges and research directions. *Journal of King Saud University-Computer and Information Sciences*, 34(8), 5083-5099. <https://www.sciencedirect.com/science/article/pii/S1319157821000070>
9. AFP. (2021, juin 3). *Incendie « maîtrisé » mais non éteint à la raffinerie de pétrole de Téhéran*. Sciences et Avenir. https://www.sciencesetavenir.fr/nature-environnement/feu-maitrise-mais-non-eteint-a-la-raffinerie-de-petrole-de-teheran_154751
10. *Deep Learning and Transformer Approaches for UAV-Based Wildfire Detection and Segmentation*. (s. d.). Consulté 26 septembre 2025, à l'adresse <https://www.mdpi.com/1424-8220/22/5/1977>

11. وكالة الأنباء الجزائرية. (s. d.). و ا ج. Consulté 26 septembre 2025, à l'adresse <https://www.aps.dz/economie/139524-feux-de-foret-plus-100-000-hectares-ravages-dans-21-wilayas-durant-l-ete-2021>
12. *Automatic Fire and Smoke Detection Method for Surveillance Systems Based on Dilated CNNs.* (s. d.). Consulté 26 septembre 2025, à l'adresse <https://www.mdpi.com/2073-4433/11/11/1241>
13. Park, M., & Ko, B. C. (2020). Two-Step Real-Time Night-Time Fire Detection in an Urban Environment Using Static ELASTIC-YOLOv3 and Temporal Fire-Tube. *Sensors*, 20(8), 2202. <https://doi.org/10.3390/s20082202>
14. Muhammad, K., Ahmad, J., Mehmood, I., Rho, S., & Baik, S. W. (2018). Convolutional Neural Networks Based Fire Detection in Surveillance Videos. *IEEE Access*, 6, 18174-18183. <https://doi.org/10.1109/ACCESS.2018.2812835>
15. Valikhujaev, Y., Abdusalomov, A., & Cho, Y. I. (2020). Automatic Fire and Smoke Detection Method for Surveillance Systems Based on Dilated CNNs. *Atmosphere*, 11(11), 1241. <https://doi.org/10.3390/atmos11111241>
16. Wang, X. (2013). Intelligent multi-camera video surveillance : A review. *Pattern Recognition Letters*, 34(1), 3-19. <https://doi.org/10.1016/j.patrec.2012.07.005>
17. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25. <https://proceedings.neurips.cc/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html>
18. Szegedy, C., Wei Liu, Yangqing Jia, Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>
19. Simonyan, K., & Zisserman, A. (2015). *Very Deep Convolutional Networks for Large-Scale Image Recognition* (No. arXiv:1409.1556). arXiv. <https://doi.org/10.48550/arXiv.1409.1556>

20. Chino, D. Y. T., Avalhais, L. P. S., Rodrigues, J. F., & Traina, A. J. M. (2015). BoWFire : Detection of Fire in Still Images by Integrating Pixel Color and Texture Analysis. *2015 28th SIBGRAPI Conference on Graphics, Patterns and Images*, 95-102.
<https://doi.org/10.1109/SIBGRAPI.2015.19>
21. Foggia, P., Saggese, A., & Vento, M. (2015). Real-Time Fire Detection for Video-Surveillance Applications Using a Combination of Experts Based on Color, Shape, and Motion. *IEEE Transactions on Circuits and Systems for Video Technology*, 25(9), 1545-1556.
<https://doi.org/10.1109/TCSVT.2015.2392531>
22. Maher, M. (2021). *Fire risks and fighting equipment .pdf* (p. 17).
23. Ko, B. C., Cheong, K.-H., & Nam, J.-Y. (2009). Fire detection based on vision sensor and support vector machines. *Fire Safety Journal*, 44(3), 322-329.
<https://doi.org/10.1016/j.firesaf.2008.07.006>
24. Kumar, K. P., & Chintala, R. R. (2024). A Review of Forest Fires : Causes, Impacts, and Management Strategies. *International Journal of Intelligent Systems and Applications in Engineering*, 12(3), 229-234. <https://ijisae.org/index.php/IJISAE/article/view/5245>
25. Kala, C. P. (2023). Environmental and socioeconomic impacts of forest fires : A call for multilateral cooperation and management interventions. *Natural Hazards Research*, 3(2), 286-294. <https://doi.org/10.1016/j.nhres.2023.04.003>
26. *About dangerous substances—HSE*. (s. d.). Consulté 17 septembre 2025, à l'adresse <https://www.hse.gov.uk/fireandexplosion>
27. DGS_Céline.M, & DGS_Céline.M. (s. d.). *Incendies domestiques*. Ministère du Travail, de la Santé, des Solidarités et des Familles. Consulté 17 septembre 2025, à l'adresse <https://sante.gouv.fr/prevention-en-sante/risques-de-la-vie-courante/article/incendies-domestiques>
28. *Vehicle fires report | NFPA Research*. (2024, novembre 1). <https://www.nfpa.org/education-and-research/research/nfpa-research/fire-statistical-reports/vehicle-fires>

29. Chithra, K., & Santhanam, T. (2018). A novel denoising technique for mixed noise removal from grayscale and color images. *Journal of Theoretical & Applied Information Technology*, 96(3).
30. Helms, R. M. (1990). Introduction to image technology. *IBM Systems Journal*, 29(3), 313-332.
<https://doi.org/10.1147/sj.293.0313>
31. Ounissi, M., Harnane, Z. I., & Lamamra, K. (2020). *Modélisation et classification avec Deep Learning*.
32. Sahla, N. (2018). *A deep learning prediction model for object classification*.
https://repository.tudelft.nl/file/File_e6f5eae3-480f-4edc-bcf0-6db8d397a93d
33. Wang, P., Fan, E., & Wang, P. (2021). Comparative analysis of image classification algorithms based on traditional machine learning and deep learning. *Pattern recognition letters*, 141, 61-67. <https://www.sciencedirect.com/science/article/pii/S0167865520302981>
34. y Cajal, S. R. (1906). *The structure and connexions of neurons*. <http://www.xn--patologia-i2a.es/volumen35/vol35-num4/pdf%20patologia%2035-4/35-4-11.pdf>
35. *Types of neurons*. (s. d.). Kenhub. Consulté 10 septembre 2025, à l'adresse
<https://www.kenhub.com/en/library/physiology/types-of-neurons>
36. Çallı, E., Sogancioglu, E., Van Ginneken, B., van Leeuwen, K. G., & Murphy, K. (2021). Deep learning for chest X-ray analysis : A survey. *Medical image analysis*, 72, 102125.
<https://www.sciencedirect.com/science/article/pii/S1361841521001717>
37. Rawat, W., & Wang, Z. (2017). Deep Convolutional Neural Networks for Image Classification : A Comprehensive Review. *Neural Computation*, 29, 2352-2449.
https://doi.org/10.1162/NECO_a_00990
38. Sultana, F., Sufian, A., & Dutta, P. (2018). Advancements in image classification using convolutional neural network. *2018 Fourth international conference on research in computational intelligence and communication networks (ICRCICN)*, 122-129.
<https://ieeexplore.ieee.org/abstract/document/8718718/>
39. Al-Saffar, A. A. M., Tao, H., & Talab, M. A. (2017). Review of deep convolution neural network in image classification. *2017 International conference on radar, antenna, microwave,*

electronics, and telecommunications (ICRAMET), 26-31.

<https://ieeexplore.ieee.org/abstract/document/8253139/>

40. Bernard, T. E., & Duker, J. (1981). Modeling carbon monoxide uptake during work. *American Industrial Hygiene Association Journal*, 42(5), 361-364.

<https://doi.org/10.1080/15298668191419884>

41. Ferguson, L. H., & Jenicak, C. A. (2005). Alarm and detection systems. In *Fundamentals of Fire Protection for the Safety Professional* (p. 185). The Scarecrow Press Inc.

42. Wang, S., Berentsen, M., & Kaiser, T. (2005). Signal processing algorithms for fire localization using temperature sensor arrays. *Fire Safety Journal*, 40(8), 689-697.

<https://doi.org/10.1016/j.firesaf.2005.06.004>

43. Chiang, C.-T., & Chang, F.-W. (2016). Design of a Calibrated Temperature Difference Sensor Transducer for Monitoring Environmental Temperature Difference Applications. *IEEE Sensors Journal*, 16(4), 1038-1043. *IEEE Sensors Journal*.

<https://doi.org/10.1109/JSEN.2015.2495216>

44. Meacham, B. J., & Motevalli, V. (1992). Characterization of Smoke From Smoldering Combustion for the Evaluation of Light Scattering Type Smoke Detector Response. *Journal of Fire Protection Engineering*, 4(1), 17-32. <https://doi.org/10.1177/104239159200400103>

45. Aspey, R. A., Brazier, K. J., & Spencer, J. W. (2005). Multiwavelength sensing of smoke using a polychromatic LED : Mie extinction characterization using HLS analysis. *IEEE Sensors Journal*, 5(5), 1050-1056. *IEEE Sensors Journal*. <https://doi.org/10.1109/JSEN.2005.845207>

46. To, H., & Fong, N. (2013). Investigation of the performance and improvement of optical smoke detectors. *Procedia engineering*, 62, 985-993.

<https://www.sciencedirect.com/science/article/pii/S1877705813013349>

47. Jackson, M. A., & Robins, I. (1994). Gas sensing for fire detection : Measurements of CO, CO₂, H₂, O₂, and smoke density in European standard fire tests. *Fire safety journal*, 22(2), 181-205. <https://www.sciencedirect.com/science/article/pii/0379711294900728>

48. Kosterev, A. A., Tittel, F. K., & Bearman, G. (2008). Advanced Quartz-Enhanced Photoacoustic Trace Gas Sensor for Early Fire Detection. *SAE International Journal of Aerospace*, 1(1), 331-336. <https://doi.org/10.4271/2008-01-2091>
49. Reimann, P., Horras, S., & Schütze, A. (2009). Field-test system for underground fire detection based on semiconductor gas sensor. *SENSORS, 2009 IEEE*, 659-664. <https://ieeexplore.ieee.org/abstract/document/5398337/>
50. Majid, S., Alenezi, F., Masood, S., Ahmad, M., Gündüz, E. S., & Polat, K. (2022). Attention based CNN model for fire detection and localization in real-world images. *Expert Systems with Applications*, 189, 116114. <https://doi.org/10.1016/j.eswa.2021.116114>
51. Premal, C. E., & Vinsley, S. S. (2014). Image processing based forest fire detection using YCbCr colour model. *2014 International Conference on Circuits, Power and Computing Technologies [ICCPCT-2014]*, 1229-1237. <https://doi.org/10.1109/ICCPCT.2014.7054883>
52. *Video fire detection – Review—ScienceDirect*. (s. d.). Consulté 23 décembre 2024, à l'adresse <https://www.sciencedirect.com/science/article/abs/pii/S1051200413001462>
53. Thou-Ho Chen, Ping-Hsueh Wu, & Yung-Chuen Chiou. (2004). An early fire-detection method based on image processing. *2004 International Conference on Image Processing, 2004. ICIP '04.*, 3, 1707-1710. <https://doi.org/10.1109/ICIP.2004.1421401>
54. Celik, T., Demirel, H., Ozkaramanli, H., & Uyguroglu, M. (2007). Fire detection using statistical color model in video sequences. *Journal of Visual Communication and Image Representation*, 18(2), 176-185. <https://doi.org/10.1016/j.jvcir.2006.12.003>
55. Toulouse, T., Rossi, L., Celik, T., & Akhloufi, M. (2016). Automatic fire pixel detection using image processing : A comparative analysis of rule-based and machine learning-based methods. *Signal, Image and Video Processing*, 10(4), 647-654. <https://doi.org/10.1007/s11760-015-0789-x>
56. Munshi, A. (2021). Fire detection methods based on various color spaces and gaussian mixture models. *Advances in Science and Technology. Research Journal*, 15(3), 197-214. <https://bibliotekanauki.pl/articles/2123292.pdf>

57. stevewhims. (2023, juin 12). *Prise en charge de JPEG YCbCr—Win32 apps*.
<https://learn.microsoft.com/fr-fr/windows/win32/wic/jpeg-ycbcr-support>
58. Verstockt, S. (2011). *Multi-modal video analysis for early fire detection* [Dissertation, Ghent University]. <http://hdl.handle.net/1854/LU-1969758>
59. Avula, S. B., Badri, S. J., & Reddy P, G. (2020). A Novel Forest Fire Detection System Using Fuzzy Entropy Optimized Thresholding and STN-based CNN. *2020 International Conference on COMMunication Systems & NETworkS (COMSNETS)*, 750-755.
<https://doi.org/10.1109/COMSNETS48256.2020.9027347>
60. Luo, Y. (2014). *Moving Object Detection based on Background Modeling*. <https://www.diva-portal.org/smash/record.jsf?pid=diva2:739474>
61. Jinlan, L., Lin, W., Ruliang, Z., Chengquan, H., & Yan, R. (2016). A Method of Fire and Smoke Detection Based on Surendra Background and Gray Bitmap Plane Algorithm. *2016 8th International Conference on Information Technology in Medicine and Education (ITME)*, 370-374. <https://doi.org/10.1109/ITME.2016.0089>
62. Qureshi, W. S., Ekpanyapong, M., Dailey, M. N., Rinsurongkawong, S., Malenichev, A., & Krasotkina, O. (2016). QuickBlaze : Early Fire Detection Using a Combined Video Processing Approach. *Fire Technology*, 52(5), 1293-1317. <https://doi.org/10.1007/s10694-015-0489-7>
63. Khondaker, A., & Khandaker, A. (2018). *Early fire detection using enhanced optical flow analysis technique* [Thesis, BRAC University].
<https://dspace.bracu.ac.bd:8443/xmlui/handle/10361/10094>
64. Yuan, C. (s. d.). *Automatic Fire Detection Using Computer Vision Techniques for UAV-based Forest Fire Surveillance*.
65. Qi, X., & Ebert, J. (2009). A computer vision based method for fire detection in color videos. *International journal of imaging*, 2(S09), 22-34.
<https://www.usu.edu/cs/people/XiaoJunQi/Promotion/IJI.FireDetection.09.pdf>

66. Çelik, T., Özkaramanlı, H., & Demirel, H. (2007). Fire and smoke detection without sensors : Image processing based approach. *2007 15th European Signal Processing Conference*, 1794-1798. <https://ieeexplore.ieee.org/abstract/document/7099116>
67. Marbach, G., Loepfe, M., & Brupbacher, T. (2006). An image processing technique for fire detection in video images. *Fire Safety Journal*, 41(4), 285-289. <https://doi.org/10.1016/j.firesaf.2006.02.001>
68. Wang, D., Cui, X., Park, E., Jin, C., & Kim, H. (2013). Adaptive flame detection using randomness testing and robust features. *Fire Safety Journal*, 55, 116-125. <https://doi.org/10.1016/j.firesaf.2012.10.011>
69. Horng, W.-B., Peng, J.-W., & Chen, C.-Y. (2005). A new image-based real-time flame detection method using color analysis. *Proceedings. 2005 IEEE Networking, Sensing and Control*, 2005., 100-105. <https://doi.org/10.1109/ICNSC.2005.1461169>
70. Horng, W.-B., & Peng, J.-W. (2008). A fast image-based fire flame detection method using color analysis. *Tamkang Journal of Science and Engineering*, 11(3), 273-285. <https://www.academia.edu/download/56346884/11-3-6.pdf>
71. Toreyin, B. U., Dedeoglu, Y., & Cetin, A. E. (2005). Flame detection in video using hidden Markov models. *IEEE International Conference on Image Processing 2005*, 2, II-1230. <https://doi.org/10.1109/ICIP.2005.1530284>
72. Zhang, Z., Shen, T., & Zou, J. (2014). An Improved Probabilistic Approach for Fire Detection in Videos. *Fire Technology*, 50(3), 745-752. <https://doi.org/10.1007/s10694-012-0253-1>
73. Dimitropoulos, K., Barmpoutis, P., & Grammalidis, N. (2015). Spatio-Temporal Flame Modeling and Dynamic Texture Analysis for Automatic Video-Based Fire Detection. *IEEE Transactions on Circuits and Systems for Video Technology*, 25(2), 339-351. *IEEE Transactions on Circuits and Systems for Video Technology*. <https://doi.org/10.1109/TCSVT.2014.2339592>
74. Koerich Borges, P. V., Mayer, J., & Izquierdo, E. (2008). Efficient visual fire detection applied for video retrieval. *2008 16th European Signal Processing Conference*, 1-5. <https://ieeexplore.ieee.org/abstract/document/7080733>

75. Di Lascio, R., Greco, A., Saggese, A., & Vento, M. (2014). Improving Fire Detection Reliability by a Combination of Videoanalytics. In A. Campilho & M. Kamel (Éds.), *Image Analysis and Recognition* (Vol. 8814, p. 477-484). Springer International Publishing.
https://doi.org/10.1007/978-3-319-11758-4_52
76. Chen, R., Luo, Y., & Alsharif, M. R. (2013). Forest Fire Detection Algorithm Based on Digital Image. *J. Softw.*, 8(8), 1897-1905.
<https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=05aff12f733c36dd33c5a0f6eee1f8f67cd9498e>
77. Han, X.-F., Jin, J. S., Wang, M.-J., Jiang, W., Gao, L., & Xiao, L.-P. (2017). Video fire detection based on Gaussian Mixture Model and multi-color features. *Signal, Image and Video Processing*, 11(8), 1419-1425. <https://doi.org/10.1007/s11760-017-1102-y>
78. Ko, B., Jung, J.-H., & Nam, J.-Y. (2014). Fire detection and 3D surface reconstruction based on stereoscopic pictures and probabilistic fuzzy logic. *Fire Safety Journal*, 68, 61-70.
<https://www.sciencedirect.com/science/article/pii/S0379711214000721>
79. Schröder, T., Krüger, K., & Kümmerlen, F. (2014). Image processing based deflagration detection using fuzzy logic classification. *Fire Safety Journal*, 65, 1-10.
<https://doi.org/10.1016/j.firesaf.2014.02.004>
80. Rossi, L., Akhloufi, M., & Tison, Y. (2011). On the use of stereovision to develop a novel instrumentation system to extract geometric fire fronts characteristics. *Fire Safety Journal*, 46(1), 9-20. <https://doi.org/10.1016/j.firesaf.2010.03.001>
81. Chi, R., Lu, Z.-M., & Ji, Q.-G. (2017). Real-time multi-feature based fire flame detection in video. *IET Image Processing*, 11(1), 31-37. <https://doi.org/10.1049/iet-ipr.2016.0193>
82. Kong, S. G., Jin, D., Li, S., & Kim, H. (2016). Fast fire flame detection in surveillance video using logistic regression and temporal smoothing. *Fire Safety Journal*, 79, 37-43.
<https://doi.org/10.1016/j.firesaf.2015.11.015>

83. Belarbi, F., Hassini, A., & Benamara, N. K. (2024). A novel approach based on convolutional neural networks ensemble for fire detection. *Signal, Image and Video Processing*, 18(12), 8805-8818. <https://doi.org/10.1007/s11760-024-03508-3>
84. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2014). *Going Deeper with Convolutions* (No. arXiv:1409.4842). arXiv. <https://doi.org/10.48550/arXiv.1409.4842>
85. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2019). *MobileNetV2 : Inverted Residuals and Linear Bottlenecks* (No. arXiv:1801.04381). arXiv. <https://doi.org/10.48550/arXiv.1801.04381>
86. Ren, S., He, K., Girshick, R., & Sun, J. (2016). *Faster R-CNN : Towards Real-Time Object Detection with Region Proposal Networks* (No. arXiv:1506.01497). arXiv. <https://doi.org/10.48550/arXiv.1506.01497>
87. Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). *You Only Look Once : Unified, Real-Time Object Detection* (No. arXiv:1506.02640). arXiv. <https://doi.org/10.48550/arXiv.1506.02640>
88. Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). *SSD : Single Shot MultiBox Detector* (Vol. 9905, p. 21-37). https://doi.org/10.1007/978-3-319-46448-0_2
89. Graves, A. (2012). *Supervised Sequence Labelling with Recurrent Neural Networks* (Vol. 385). Springer. <https://doi.org/10.1007/978-3-642-24797-2>
90. Nc.dvi. (s. d.). Consulté 24 octobre 2025, à l'adresse <https://www.bioinf.jku.at/publications/older/2604.pdf>
91. Frizzi, S., Kaabi, R., Bouchouicha, M., Ginoux, J.-M., Fnaiech, F., & Moreau, E. (s. d.). *Détection de la fumée et du feu par réseau de neurones convolutifs*.
92. Muhammad, K., Ahmad, J., & Baik, S. W. (2018). Early fire detection using convolutional neural networks during surveillance for effective disaster management. *Neurocomputing*, 288, 30-42. <https://doi.org/10.1016/j.neucom.2017.04.083>

93. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25. https://proceedings.neurips.cc/paper_files/paper/2012/hash/c399862d3b9d6b76c8436e924a68c45b-Abstract.html
94. Muhammad, K., Khan, S., Elhoseny, M., Hassan Ahmed, S., & Wook Baik, S. (2019). Efficient Fire Detection for Uncertain Surveillance Environment. *IEEE Transactions on Industrial Informatics*, 15(5), 3113-3122. <https://doi.org/10.1109/TII.2019.2897594>
95. *Deep Convolutional Neural Networks for Fire Detection in Images* | SpringerLink. (s. d.). Consulté 10 juillet 2024, à l'adresse https://link.springer.com/chapter/10.1007/978-3-319-65172-9_16
96. Pan, H., Badawi, D., & Cetin, A. E. (2021). Fourier Domain Pruning of MobileNet-V2 with Application to Video Based Wildfire Detection. *2020 25th International Conference on Pattern Recognition (ICPR)*, 1015-1022. <https://doi.org/10.1109/ICPR48806.2021.9412613>
97. Sathishkumar, V. E., Cho, J., Subramanian, M., & Naren, O. S. (2023). Forest fire and smoke detection using deep learning-based learning without forgetting. *Fire Ecology*, 19(1), 9. <https://doi.org/10.1186/s42408-022-00165-0>
98. Xu, G., Zhang, Y., Zhang, Q., Lin, G., Wang, Z., Jia, Y., & Wang, J. (2019). Video smoke detection based on deep saliency network. *Fire Safety Journal*, 105, 277-285. <https://doi.org/10.1016/j.firesaf.2019.03.004>
99. Kim, B., & Lee, J. (2019). A Video-Based Fire Detection Using Deep Learning Models. *Applied Sciences*, 9(14), 2862. <https://doi.org/10.3390/app9142862>
100. Chaoxia, C., Shang, W., & Zhang, F. (2020). Information-Guided Flame Detection Based on Faster R-CNN. *IEEE Access*, 8, 58923-58932. IEEE Access. <https://doi.org/10.1109/ACCESS.2020.2982994>
101. Casas, E., Ramos, L., Bendek, E., & Rivas-Echeverria, F. (2024). YOLOv5 vs. YOLOv8 : Performance Benchmarking in Wildfire and Smoke Detection Scenarios. *Journal of Image and Graphics*, 12(2), 127-136. <https://doi.org/10.18178/joig.12.2.127-136>

102. Yar, H., Khan, Z. A., Hussain, T., & Baik, S. W. (2024). A modified vision transformer architecture with scratch learning capabilities for effective fire detection. *Expert Systems with Applications*, 252, 123935. <https://doi.org/10.1016/j.eswa.2024.123935>
103. Khan, T., Khan, Z. A., & Choi, C. (2023). Enhancing real-time fire detection : An effective multi-attention network and a fire benchmark. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-023-09298-y>
104. Jadon, A., Omama, M., Varshney, A., Ansari, M. S., & Sharma, R. (2019). *FireNet : A Specialized Lightweight Fire & Smoke Detection Model for Real-Time IoT Applications* (No. arXiv:1905.11922). arXiv. <https://doi.org/10.48550/arXiv.1905.11922>
105. Rosebrock, A. (2019, novembre 18). Fire and smoke detection with Keras and Deep Learning. *PyImageSearch*. <https://pyimagesearch.com/2019/11/18/fire-and-smoke-detection-with-keras-and-deep-learning/>
106. Bedo, M., Blanco, G., Oliveira, W., Cazzolato, M., Costa, A., Rodrigues, J., Traina, A., & Traina Jr, C. (2015). *Techniques for effective and efficient fire detection from social media images* (No. arXiv:1506.03844). arXiv. <https://doi.org/10.48550/arXiv.1506.03844>
107. Ko, B. C., Ham, S. J., & Nam, J. Y. (2011). Modeling and Formalization of Fuzzy Finite Automata for Detection of Irregular Fire Flames. *IEEE Transactions on Circuits and Systems for Video Technology*, 21(12), 1903-1912. <https://doi.org/10.1109/TCSVT.2011.2157190>
108. Sharma, J., Granmo, O.-C., Goodwin, M., & Fidje, J. T. (2017). Deep Convolutional Neural Networks for Fire Detection in Images. In G. Boracchi, L. Iliadis, C. Jayne, & A. Likas (Éds.), *Engineering Applications of Neural Networks* (p. 183-193). Springer International Publishing. https://doi.org/10.1007/978-3-319-65172-9_16
109. Fire. (2016). *NIST*. <https://www.nist.gov/fire>
110. *Image and video databases*. (s. d.). Consulté 8 février 2025, à l'adresse http://wildfire.fesb.hr/index.php?option=com_content&view=article&id=62&Itemid=72
111. *RABOT 2012 | Multimedia Lab*. (s. d.). Consulté 9 juin 2023, à l'adresse <http://multimedialab.elis.ugent.be/rabot2012/>

112. *Forestry Images*. (s. d.). Consulté 5 février 2025, à l'adresse <https://www.forestryimages.org/>
113. *Find Open Datasets and Machine Learning Projects | Kaggle*. (s. d.). Consulté 5 novembre 2025, à l'adresse <https://www.kaggle.com/datasets>
114. *Google Images*. (s. d.). Consulté 1 mai 2025, à l'adresse <https://www.google.com/imghp?hl=fr&authuser=0&ogbl>
115. Oliva, A., & Torralba, A. (s. d.). *Modeling the Shape of the Scene : A Holistic Representation of the Spatial Envelope*.
116. *PyTorch*. (s. d.). Consulté 25 février 2025, à l'adresse <https://pytorch.org/>
117. *Why TensorFlow*. (s. d.). TensorFlow. Consulté 25 février 2025, à l'adresse <https://www.tensorflow.org/about?hl=fr>
118. *Keras : Deep Learning for humans*. (s. d.). Consulté 25 février 2025, à l'adresse <https://keras.io/>
119. Çalışkan, A. (2023). Diagnosis of malaria disease by integrating chi-square feature selection algorithm with convolutional neural networks and autoencoder network. *Transactions of the Institute of Measurement and Control*, 45(5), 975-985.
<https://doi.org/10.1177/01423312221147335>
120. *MTCNN++ : A CNN-based face detection algorithm inspired by MTCNN | The Visual Computer*. (s. d.). Consulté 26 février 2025, à l'adresse <https://link.springer.com/article/10.1007/s00371-023-02822-0>
121. Wei, R., Jiang, J., Xu, H., & Zhang, D. (2021). Novel topology convolutional neural network fault diagnosis for aircraft actuators and their sensors. *Transactions of the Institute of Measurement and Control*, 43(11), 2551-2566. <https://doi.org/10.1177/01423312211005612>
122. *Convolutional Neural Networks for Image Processing : An Application in Robot Vision | SpringerLink*. (s. d.). Consulté 26 février 2025, à l'adresse https://link.springer.com/chapter/10.1007/978-3-540-24581-0_55
123. *Real-time facial expression recognition using smoothed deep neural network ensemble*. (s. d.). <https://doi.org/10.3233/ICA-200643>

124. Benamara, N. K., Val-Calvo, M., Álvarez-Sánchez, J. R., Díaz-Morcillo, A., Ferrández-Vicente, J. M., Fernández-Jover, E., & Stambouli, T. B. (2020). Real-time facial expression recognition using smoothed deep neural network ensemble. *Integrated Computer-Aided Engineering*, 28(1), 97-111. <https://doi.org/10.3233/ICA-200643>
125. MIVIA Lab. (s. d.). GitHub. Consulté 3 mars 2025, à l'adresse <https://github.com/MiviaLab>
126. Khan, Z. A., Hussain, T., Ullah, F. U. M., Gupta, S. K., Lee, M. Y., & Baik, S. W. (2022). Randomly Initialized CNN with Densely Connected Stacked Autoencoder for Efficient Fire Detection. *Engineering Applications of Artificial Intelligence*, 116, 105403. <https://doi.org/10.1016/j.engappai.2022.105403>
127. Zheng, H., Wang, G., Xiao, D., Liu, H., & Hu, X. (2024). FTA-DETR : An efficient and precise fire detection framework based on an end-to-end architecture applicable to embedded platforms. *Expert Systems with Applications*, 248, 123394. <https://doi.org/10.1016/j.eswa.2024.123394>
128. Çelik, T., & Demirel, H. (2009). Fire detection in video sequences using a generic color model. *Fire Safety Journal*, 44(2), 147-158. <https://doi.org/10.1016/j.firesaf.2008.05.005>
129. Rafiee, A., Dianat, R., Jamshidi, M., Tavakoli, R., & Abbaspour, S. (2011). Fire and smoke detection using wavelet analysis and disorder characteristics. *2011 3rd International Conference on Computer Research and Development*, 262-265. <https://doi.org/10.1109/ICCRD.2011.5764295>
130. Zheng, H., Duan, J., Dong, Y., & Liu, Y. (2023). Real-time fire detection algorithms running on small embedded devices based on MobileNetV3 and YOLOv4. *Fire Ecology*, 19(1), 31. <https://doi.org/10.1186/s42408-023-00189-0>
131. *Computationally Efficient Wildfire Detection Method Using a Deep Convolutional Network Pruned via Fourier Analysis*. (s. d.). Consulté 6 mars 2025, à l'adresse <https://www.mdpi.com/1424-8220/20/10/2891>

132. Li, S., Yan, Q., & Liu, P. (2020). An Efficient Fire Detection Method Based on Multiscale Feature Extraction, Implicit Deep Supervision and Channel Attention Mechanism. *IEEE Transactions on Image Processing*, 29, 8467-8475. <https://doi.org/10.1109/TIP.2020.3016431>

Annexe A

Bases Physico-Chimiques de la Combustion

Sommaire de l'Annexe :

A.1. Introduction	119
A.2. Cinétique de la combustion	119
A.3. Réactions en chaîne de combustion.....	119
A.4. Propagation thermique de la combustion	120
A.5. Caractéristiques dynamiques de la flamme	121
A.5.1. Turbulence	121
A.5.2. Comportement non stationnaire	121
A.5.3. Instabilités de la flamme.....	121
A.5.4. Scintillement de la flamme.....	122

A.1. Introduction

La combustion est un phénomène physico-chimique complexe impliquant des réactions exothermiques rapides entre un combustible et un comburant. Dans le contexte de la détection d'incendie basée sur l'analyse d'images, la compréhension des mécanismes fondamentaux de la combustion permet d'expliquer l'apparition des caractéristiques visuelles du feu, telles que les flammes, les variations de luminosité et les mouvements turbulents

A.2. Cinétique de la combustion

La cinétique chimique décrit la vitesse des réactions de combustion ainsi que les mécanismes microscopiques qui contrôlent leur évolution dans le temps. Elle dépend principalement de la température, de la concentration des réactifs et de l'énergie d'activation, qui représente la barrière énergétique nécessaire pour initier la réaction.

La vitesse de réaction peut être exprimée par une loi de la forme :

$$W = K \cdot CA^{v1} \cdot CB^{v2} \quad (A.1)$$

Où CA et CB représentent les concentrations des espèces réactives, v1 et v2 les ordres partiels de réaction, et k la constante cinétique dépendante de la température.

La dépendance de cette constante à la température est décrite par la loi d'Arrhenius :

$$k = A \exp \frac{(-Ea)}{RT} \quad (A.2)$$

Où A est le facteur pré-exponentiel, Ea l'énergie d'activation, R la constante des gaz parfaits et T la température absolue.

Cette relation met en évidence le caractère fortement non linéaire de la cinétique de combustion, une légère augmentation de la température entraîne une augmentation très rapide de la vitesse de réaction. Ce phénomène explique le développement rapide d'un incendie

A.3. Réactions en chaîne de combustion

La combustion repose sur des mécanismes de réactions en chaîne radicalaires impliquant des espèces intermédiaires hautement réactives, appelées radicaux libres (tels que H·, O· et

OH·). Le principe général repose sur la formation initiale de radicaux libres, suivie de réactions successives avec les molécules de combustible, produisant de nouveaux radicaux. Ce processus peut conduire à un phénomène de ramification (chain-branching), caractérisé par une augmentation rapide du nombre de radicaux. Ces mécanismes sont responsables de l'accélération brutale de la réaction, de la transition vers l'inflammation et du comportement instable des flammes

Le tableau A.1 présente les différentes étapes fondamentales des réactions en chaîne de combustion, ainsi que des exemples simplifiés de chaque mécanisme

Tableau A.1 Étapes fondamentales des réactions en chaîne de combustion

Étape	Description	Exemple simplifié
Initiation	Formation des premiers radicaux libres à partir de molécules stables sous l'effet de la température	$\text{H}_2 \rightarrow 2\text{H}\cdot$
Propagation	Réactions entre radicaux et molécules produisant de nouveaux radicaux	$\text{H}\cdot + \text{O}_2 \rightarrow \text{OH}\cdot + \text{O}\cdot$
Ramification (Branching)	Augmentation du nombre de radicaux, accélérant la réaction	$\text{O}\cdot + \text{H}_2 \rightarrow \text{OH}\cdot + \text{H}\cdot$
Terminaison	Disparition des radicaux par formation de molécules stables	$\text{H}\cdot + \text{H}\cdot \rightarrow \text{H}_2$

Ces caractéristiques sont directement liées aux variations visuelles du feu, telles que les fluctuations de luminosité, les déformations de la flamme et les mouvements turbulents. Elles constituent des indicateurs importants exploités dans les systèmes de détection d'incendie basés sur l'analyse d'images

A.4. Propagation thermique de la combustion

La propagation thermique de la combustion désigne le processus par lequel la chaleur générée par une réaction exothermique est transférée aux zones adjacentes, entraînant leur élévation en température jusqu'à atteindre les conditions d'inflammation. Ce phénomène repose sur trois modes fondamentaux de transfert thermique. La conduction correspond à un transfert de chaleur à travers un milieu sous l'effet d'un gradient de température, contribuant à l'échauffement progressif des matériaux combustibles. La convection, quant à elle, est liée au

déplacement des gaz chauds, favorisant le transport de chaleur et le mélange entre le combustible et le comburant. Enfin, le rayonnement thermique permet un transfert d'énergie sans contact direct, jouant un rôle déterminant dans l'inflammation d'objets situés à distance de la source de chaleur.

Dans le cadre de la détection d'incendie par analyse d'images, ces mécanismes physiques se manifestent par des signatures visuelles distinctives, telles que les fluctuations de luminosité, les mouvements ascendants des fumées et les déformations de la flamme. Leur prise en compte permet d'améliorer la modélisation et la détection automatique des phénomènes de combustion.

A.5. Caractéristiques dynamiques de la flamme

La flamme constitue un système physico-chimique complexe dont le comportement résulte des interactions entre les réactions chimiques de combustion et les phénomènes de transfert. Ces interactions donnent lieu à des propriétés dynamiques de la flamme, telles que la turbulence, le caractère instationnaire et les instabilités de la flamme.

A.5.1. Turbulence

La turbulence correspond à un régime d'écoulement caractérisé par des mouvements chaotiques et désordonnés des gaz. Dans le cas de la combustion, elle favorise le mélange entre le combustible et le comburant, ce qui augmente l'efficacité des réactions chimiques. Elle engendre également des structures irrégulières de la flamme, accompagnées de déformations et d'oscillations rapide

A.5.2. Comportement non stationnaire

La flamme est un système intrinsèquement non stationnaire, c'est-à-dire que ses propriétés évoluent continuellement dans le temps. Sa forme, sa position et son intensité lumineuse varient de manière dynamique sous l'effet des fluctuations de température, des variations de concentration des espèces chimiques et des conditions environnementale.

A.5.3. Instabilités de la flamme

Les instabilités de la flamme résultent des interactions entre les phénomènes thermiques, chimiques et hydrodynamiques. Elles se manifestent par des oscillations, des déformations et des structures complexes de la flamme. Ces instabilités peuvent être amplifiées par la turbulence et influencent directement la propagation de la combustion.

A.5.4. Scintillement de la flamme

Le scintillement correspond à des fluctuations rapides et irrégulières de l'intensité lumineuse de la flamme. Il est principalement causé par les instabilités de l'écoulement et les variations locales de la combustion, notamment en régime turbulent. Ce phénomène constitue une signature visuelle importante du feu et est largement exploité dans les systèmes de détection d'incendie basés sur l'analyse temporelle des images.

Annexe B

Modèle d'un neurone artificiel

Un neurone artificiel reçoit un vecteur d'entrée $x=(x_1, x_2, \dots, x_n)$, associé à un ensemble de poids $w=(w_1, w_2, \dots, w_n)$, ainsi qu'un biais b . La sortie du neurone est donnée par :

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

Où :

- w_i sont les poids,
- b est le biais,
- $f(\cdot)$ est la fonction d'activation

La fonction d'activation introduit une non-linéarité dans le modèle. Parmi les fonctions les plus utilisées :

- **Sigmoid** : $f(x) = \frac{1}{1+e^{-x}}$
- **ReLU (Rectified Linear Unit)** : $f(x) = \max(0, x)$
- **Tangente hyperbolique** : $f(x) = \tanh(x)$

Ces fonctions permettent au réseau de modéliser des relations complexes entre les données.