



République algérienne démocratique et populaire

Université Larbi Tébessi

Faculté des sciences exactes et des sciences naturelles et de la vie

Département d'informatique

2023/2024



Mémoire fin d'étude

En informatique

Spécialité : Systèmes et Multimédia (SYM)

Techniques D'inpainting Pour Evaluer Les Catastrophes Naturelles Par La Restauration D'images

Réalisé par :

Soltani Ikram

Devant les membres du jury :

Gherbi Tahar
Nouioua Tarek
Zeggari Ahmed

Président
Examineur
Encadrant

Dédicace

Les mots expressifs sont difficiles à trouver pour exprimer mon remerciement. Je tiens à remercier « Allah » le tout puissant de m'avoir donné la force pour réaliser ce travail, ainsi que l'audace pour dépasser toutes les difficultés.

Mes très chers parents, aucun mot ne pourrait exprimer réellement votre juste valeur, mon profond amour, mon respect et ma vive gratitude. En hommage à tous les sacrifices que vous avez consenti pour moi durant mes longues années d'études. Je vous remercie d'avoir fait de moi ce que je suis maintenant et de m'avoir appris de vivre dans l'honneur et dans la dignité. Votre confiance et votre encouragement m'ont toujours donné de la force pour persévérer et continuer vers l'avant.

A ma chère mère Nabila Ma douce et tendre maman. Le symbole de patriotisme, du courage, de la responsabilité et de l'amour. Quoique je fasse, je ne pourrais te rendre ce que tu as fait pour moi. Si je suis arrivée là, c'est bien grâce à toi. Que Dieux te garde, te comble de santé, et te donne longue vie.

Mon très cher papa Tarek, ce brave homme qui peut être fier et trouver ici le résultat de longues années de sacrifices pour m'aider à avancer dans la vie. Merci pour les valeurs nobles, l'éducation et le soutien permanent venue toi. Dieu tout puissant te garde et te procure santé, bonheur et longue vie.

A mes très chères frères « Mohamed elhabib, Mohamed islam » A mes très chères sœurs « Ismahen, Marwa » je ne peux exprimer à travers ses lignes tous mes sentiments d'amour envers vous. Puisse l'amour et la fraternité nous unissent à jamais. Je vous souhaite la réussite dans votre vie, et d'être comblé de bonheur. Merci d'être toujours présents à mes côtés et de m'avoir continuellement encouragé.

A tous mes très chères amies qui m'ont toujours encouragé et soutien moralement et à qui je leur souhaite plus de succès.

A tous mes tantes et mes oncles merci pour votre soutien.

Et à tous ceux qui me sont chères.

IKRAM

Remerciement

Avant toute chose, je tiens à exprimer mon grand
remerciement et ma profonde gratitude et reconnaissance à Allah,
mon créateur, Qui m'a donné la force pour réaliser
ce travail et Qui était avec moi par Sa miséricorde dans chaque moment
et chaque instant jusqu'à l'accomplir. Je désire exprimer
ma sincère reconnaissance et remerciement
à mon encadreur : **ZEGGARI Ahmed**
pour avoir accepté de m'encadrer et consacré autant
de temps pour moi, pour son suivi régulier, sa bienveillance,
ses conseils , et ses orientations.

Je remercie les membres du jury qui ont bien voulu accepter de juger
mon modeste travail et de m'honorer :

Président : **GHERBI Tahar**

Examineur : **NOUIOUA Tarek**

Je remercie également tous les membres des laboratoires du département
de mathématiques et informatique, Faculté des Sciences
de la Nature et de la Vie à l'université de Tébessa.

Je remercie tous ceux qui m'ont rendu service et qui m'ont
soutenu de près ou de loin pour réaliser ce travail.

Résumé

Notre mémoire examine l'utilisation des techniques d'inpainting pour évaluer les catastrophes naturelles en restaurant les images endommagées. Nous avons étudié deux phases : la première se concentre sur l'analyse des ensembles de données RescueNet et Massachusetts Buildings Dataset et l'entraînement des modèles à l'aide de ResNet. Dans la deuxième phase, les techniques d'inpainting ont été appliquées aux mêmes ensembles de données, suivies d'un nouvel entraînement avec ResNet. Les résultats ont été prometteurs, avec une précision du modèle atteignant parfois 93% avec une petite marge d'erreur. Les résultats démontrent l'efficacité des techniques d'inpainting dans l'évaluation des catastrophes naturelles et fournissent des résultats précis et fiables pour améliorer la réponse aux urgences et les opérations de rétablissement dans de telles situations.

Abstract

Our thesis explores the use of inpainting techniques to assess natural disasters by restoring damaged images. We studied two phases: the first focused on analyzing the RescueNet and Massachusetts Buildings Dataset and training models using ResNet. In the second phase, inpainting techniques were applied to the same datasets, followed by retraining with ResNet. The results were promising, with model accuracy reaching up to 93% in some cases with a small margin of error. The results demonstrate the effectiveness of inpainting techniques in assessing natural disasters and provide accurate and reliable results to enhance emergency response and recovery operations in such situations.

نبذة مختصرة

مذكرتنا تتناول استخدام تقنيات الـ Inpainting في تقدير الكوارث الطبيعية من خلال استعادة الصور المتضررة. قمنا بدراسة مرحلتين؛ الأولى ركزت على تحليل مجموعتي بيانات ResNet و Massachusetts Buildings Dataset وتدريب النماذج باستخدام ResNet. أما المرحلة الثانية، فقد تم تطبيق تقنيات الـ Inpainting على نفس المجموعتين مع إعادة التدريب باستخدام ResNet. النتائج كانت مباشرة، حيث وصلت دقة النموذج في بعض الحالات إلى 93% مع خطأ صغير. تظهر النتائج فعالية تقنيات الـ Inpainting في تقدير الكوارث الطبيعية وتوفير نتائج دقيقة وموثوقة لتحسين استجابة الطوارئ وعمليات الإعادة والترميم في مثل هذه الحالات.

Sommaire

Liste des figures	11
Liste des tableaux	12
Tableau des symboles	13
Introduction générale	14
Chapter 01: Concepts théoriques	16
1.1. Introduction :.....	17
1.2. Les catastrophes naturelles:	17
1.3. Restauration d'image :.....	18
1.3.1. Les méthodes de restauration d'images :.....	18
1.4. Les Techniques d'Inpainting :	19
1.4.1. Le but des techniques inpainting:	20
1.5. Réseaux de neurones convolutifs :	20
1.5.1. CNN Couches:	21
1.5.1.1. Convolutifs :	21
1.5.1.2. Couche de regroupement.....	22
1.5.1.3. Aplanir la couche.....	22
1.5.1.4. La couche entièrement connectée.....	22
1.5.2. époque.....	23
1.5.3. Taille du lot.....	23
1.5.4. Itération.....	23
1.5.5. Exemples d'architectures existantes.....	23
1.5.5.1. VGG.....	23
1.5.5.2. ResNet.....	25
1.5.5.3. AlexNet.....	26
1.5.6. CNN méthodes d'entraînement :	26

Sommaire

1.5.6.1.	<i>Formation à partir de zéro</i>	26
1.5.6.2.	<i>Transférer l'apprentissage</i>	27
1.6.	Le surapprentissage	28
1.6.1.	Prévention du surajustement	29
1.6.1.1.	<i>Réduction du réseau</i>	29
1.6.1.2.	<i>Augmentation des données</i>	29
1.6.1.3.	<i>Rappels</i>	30
1.6.1.3.1.	Points de contrôle.....	30
1.6.1.3.2.	Arrêt anticipé.....	30
1.6.1.4.	<i>Régularisation</i>	30
1.7.	Conclusion	32
Chapter 02: Les techniques de l'IA pour l'évaluation des catastrophes naturelles		33
2.1.	Introduction	34
2.2.	Intelligence artificielle et prévision des catastrophes	34
2.3.	Travaux connexes	35
2.3.1.	Depuis (2017 – 2019).....	35
2.3.2.	Depuis (2020 - 2024).....	36
2.4.	Résumé de l'état de l'art	37
2.5.	Conclusion	38
Chapter 03: Résultats Expérimentaux		39
3.1.	Introduction	40
3.2.	La contribution	40
3.3.	Méthode de formation	41
3.4.	Ensembles de données utilisés	42

Sommaire

3.4.1. RescueNet	42
3.4.2. Massachusetts Buildings	42
3.5. Traitement des données	44
3.5.1. Prétraitement des images	44
3.5.2. Techniques D'inpainting	45
3.6. ResNet.....	46
3.7. Matrice de confusion	47
3.8. Environnement d'exécution	49
3.8.1. Hardware.....	49
3.8.2. Software	49
3.9. Résultats expérimentaux	50
3.9.1. La première expérimentation :	50
3.9.2. La deuxième expérimentation :	51
3.9.1. Tous les résultats expérimentaux	53
3.10. Comparaisons.....	54
3.11. Conclusion	56
Conclusion générale	57
Bibliographie	59
Bibliographie	60
Bibliographie	61
Bibliographie	62
Bibliographie	63

Liste des figures

Figure 1: Les catastrophes naturelles [1]	17
Figure 2 : Les Techniques d'Inpainting [4]	19
Figure 3 : Basic 5 player CNN architecture outline [5]	21
Figure 4: "max pooling"	22
Figure 5: "average pooling"	22
Figure 6: VGG16 architecture [8].....	24
Figure 7: VGG19 architecture [9].....	24
Figure 8: ResNet50 architecture [11].....	25
Figure 9: AlexNet architecture [38]	26
Figure 10: différence entre une formation à partir de zéro et un apprentissage par transfert [37]	28
Figure 11: graphiques illustratifs affichant la différence entre le sous-ajustement, l'ajustement optimal et le surajustement [35].....	29
Figure 12: exemple de graphique d'un arrêt anticipé dans le cas d'une perte de formation ou d'une perte de validation [36]	30
Figure 13 : Méthode de formation	41
Figure 14 : Techniques D'inpainting.....	45
Figure 15 : matrice de confusion	47
Figure 16: google colab logo	49
Figure 17 : matrice de confusion de première expérimentation	51
Figure 18 : matrice de confusion de deuxième expérimentation	52

Liste des tableaux

Table 1 : Résumé de l'état de l'art	37
Table 2 : Répartition des données	43
Table 4 : première expérimentation	50
Table 5 : deuxième expérimentation.....	52
Table 6 : Tous les résultats expérimentaux.....	53
Table 7 : Comparaisons	54

Tableau des symboles

Symboles	Abréviation
CNN	Réseau Neuronal Convolutif
VGG	Groupe de Géométrie Visuelle
ResNet	Réseau Résiduel
AlexNet	AlexNet
ACC	Précision
ERR	Erreur
TP	Vrais Positifs
TN	Vrais Négatifs
FP	Faux Positifs
FN	Faux Négatifs
ANN	Artificial Neural Network
NN	Neural Network
SVM	Support Vector Machine
kNN	k-Nearest Neighbors
DT	Decision Tree

Introduction générale

L'évaluation et la prédiction des catastrophes naturelles sont cruciales pour protéger la vie humaine et les biens, ainsi que pour réduire les pertes pouvant résulter de ces catastrophes dévastatrices. Dans ce contexte, Techniques d'inpainting par la restauration d'images pour l'évaluation des catastrophes naturelles, qui repose sur l'intelligence artificielle, constitue un moyen efficace de comprendre et d'analyser les événements naturels, et de fournir une réponse rapide et appropriée.

Les technologies modernes basées sur l'intelligence artificielle sont parmi les outils les plus importants sur lesquels il est possible de compter pour évaluer et prédire les catastrophes naturelles. Grâce à leur capacité à traiter rapidement et précisément les données, l'intelligence artificielle peut analyser les données relatives à des phénomènes tels que les séismes, les ouragans et les inondations, et identifier les modèles, les tendances et les changements fondamentaux dans le comportement de ces phénomènes.

De plus, l'intelligence artificielle contribue à améliorer les modèles de prévision et à développer des systèmes d'alerte précoce, aidant ainsi à réduire les pertes humaines et matérielles dues aux catastrophes naturelles. Ainsi, ces technologies sont un outil vital pour la construction de sociétés durables et pour renforcer la capacité à s'adapter aux défis environnementaux.

Cette mémoire vise à explorer et à analyser le rôle de la Techniques d'inpainting pour évaluer les catastrophes naturelles par la restauration d'images, avec l'aide de l'apprentissage en profondeur. Différents aspects de cette technologie seront explorés, y compris les méthodes et les techniques utilisées, les défis rencontrés et les applications pratiques qui pourraient bénéficier aux communautés exposées au risque de catastrophes naturelles.

Les principales contributions de ce travail sont les suivantes :

- ❖ **Application innovante des techniques d'inpainting** : Nous avons appliqué des techniques d'inpainting sur les ensembles de données pour la restauration d'images endommagées, ce qui est une approche novatrice dans le contexte de l'évaluation des catastrophes naturelles.
- ❖ **Utilisation de modèle CNN pour l'entraînement et la réévaluation** : Grâce à une étude expérimentale, nous voulons prouver qu'une architecture de réseau neuronal convolutif profond

peut atteindre une grande précision avec une petite marge d'erreur, démontrant ainsi l'efficacité de cette méthode dans des scénarios du monde réel.

- ❖ **Amélioration de la précision et de la fiabilité des évaluations des dommages :** Les résultats de notre étude montrent que l'utilisation combinée de CNN et des techniques d'inpainting permet d'obtenir des évaluations plus précises et fiables des dommages causés par les catastrophes naturelles, ce qui peut considérablement améliorer la réponse aux urgences et les opérations de rétablissement.

Cela dit, les chapitres de cette thèse seront organisés comme suit :

Chapitre 01 : dans ce premier chapitre, nous présentons les concepts théoriques et les idées abstraites pertinents pour ce travail ainsi que des définitions générales.

Chapitre 02 : dans ce deuxième chapitre, nous détaillons les travaux antérieurs effectués spécifiquement sur la détection et l'évaluation des catastrophes naturelles, les ensembles de données qu'ils ont utilisés, les méthodes qu'ils ont employées et les résultats qu'ils ont obtenus.

Chapitre 03 : dans ce troisième chapitre, nous fournirons des détails sur les différents ensembles de données utilisés dans ce travail, et les prétraitements qui ont été appliqués sur ces données. Nous présenterons également les architectures CNN formées, nous présentons les résultats obtenus à partir des méthodes de formation et des techniques de classification utilisées, ainsi qu'une observation et une justification perspicaces. Nous terminons ce chapitre par une comparaison avec l'état de l'art.

Nous concluons par un rappel de l'importance de cette étude et de bien d'autres similaires dans la détection et l'évaluation des catastrophes naturelles. Nous présenterons également une brève récapitulation de ce que nous avons réalisé dans ce travail, ainsi que des idées qui pourraient l'améliorer et que, faute de temps, nous n'avons pas pu tester.

Chapter 01: Concepts théoriques

1.1. Introduction :

Dans ce chapitre, nous fournirons une brève introduction aux idées et aux méthodes pertinentes pour ce travail. Afin de construire un réseau neuronal capable de faire des prédictions correctes et d'atteindre une grande précision, il est naturel d'avoir d'abord une bonne compréhension des catastrophes naturelles et de la manière dont les catastrophes peuvent être diagnostiquées. Nous passons ensuite à la technologie d'imagerie et de restauration, à son rôle dans l'évaluation des catastrophes et aux ensembles de données déjà existants liés à ce sujet, en plus des différentes techniques utilisées dans le traitement des données susmentionnées. L'étape suivante consiste à comprendre les réseaux de neurones convolutifs et certains des concepts qui leur sont associés, ainsi que les modèles préexistants et comment ils sont utilisés à travers l'idée d'apprentissage par transfert. Soit pour faire des prédictions, soit pour extraire des caractéristiques qui sont ensuite transmises au classificateur. Enfin, nous introduisons la question du surajustement et les méthodes qui peuvent être utilisées pour atténuer les effets de ce problème.

1.2. Les catastrophes naturelles:

Les catastrophes naturelles sont des événements imprévus résultant de phénomènes naturels tels que les tremblements de terre, les éruptions volcaniques, les inondations, les ouragans, les sécheresses, les glissements de terrain, les tsunamis, la foudre, les tornades, la désertification, les avalanches, le gel, les vents violents, entre autres. Ces événements peuvent causer d'énormes pertes humaines et matérielles, affectant considérablement les populations, l'environnement et l'économie. Ces catastrophes surviennent à grande échelle et sont souvent difficiles à prévoir, nécessitant souvent des efforts considérables pour se remettre de leurs effets. [1]



Figure 1: Les catastrophes naturelles [1]

1.3. Restauration d'image :

La technique de restauration d'images, ou reconstruction d'images, est un processus utilisé pour restaurer ou réparer les images qui ont été endommagées ou perdues en partie ou en totalité en raison de divers facteurs tels que l'usure temporelle, les dommages environnementaux, ou des erreurs lors de la capture ou du stockage. Ce type de technique vise à réparer les images endommagées ou manquantes de manière à ce qu'elles apparaissent plus précises et plus claires, et qu'elles soient adaptées à l'objectif souhaité. [2]

Le processus de restauration d'images comprend plusieurs étapes, notamment [3]:

- ❖ **Évaluation** : Examiner l'image pour identifier les zones endommagées et déterminer l'étendue des dommages subis.
- ❖ **Analyse** : Comprendre les raisons qui ont conduit aux dommages dans l'image, qu'ils soient dus à l'usure temporelle, à la négligence, aux conditions environnementales ou aux erreurs de capture.
- ❖ **Réparation** : Appliquer les techniques et outils appropriés pour réparer les dommages dans l'image, y compris l'utilisation de techniques numériques pour compenser les parties manquantes, ou corriger les couleurs et le contraste, ou éliminer les défauts.
- ❖ **Évaluation** : Évaluer la qualité de l'image restaurée et s'assurer qu'elle répond aux normes requises pour l'utilisation prévue.

1.3.1. Les méthodes de restauration d'images :

Il existe plusieurs techniques pour restaurer les images endommagées par les catastrophes naturelles. Voici quelques-unes d'entre elles [3] :

Inpainting : Cette méthode implique le remplacement ou la reconstruction des parties manquantes de l'image en se basant sur les informations disponibles dans les zones environnantes. L'inpainting peut être réalisé soit à l'aide d'algorithmes traditionnels, soit en utilisant des approches plus avancées basées sur l'apprentissage profond. [3]

Filtrage et déconvolution : Des techniques de filtrage et de déconvolution peuvent être appliquées pour réduire le flou ou les distorsions présents dans les images endommagées, ce qui améliore leur qualité visuelle. [3]

Débruitage : Les méthodes de débruitage sont utilisées pour éliminer ou réduire les artefacts de bruit présents dans les images, ce qui améliore leur lisibilité et leur interprétation. [3]

1.4. Les Techniques d'Inpainting :

L'inpainting est une méthode de restauration d'images qui vise à réparer les parties manquantes ou endommagées d'une image en se basant sur les données disponibles dans les zones avoisinantes. Son but est de reconstruire de manière plausible les parties manquantes tout en préservant les structures, les textures et les motifs visuels de l'image originale. Cette approche repose sur l'idée que les images naturelles présentent souvent des schémas récurrents et cohérents, permettant ainsi de prédire les valeurs des pixels manquants à partir des pixels environnants. Les applications de l'inpainting sont diverses : restauration d'œuvres d'art, récupération d'images médicales, suppression d'objets indésirables dans les photographies, et même évaluation des catastrophes naturelles en restaurant des images. En reconstruisant les zones manquantes, cette technique améliore la compréhension des dommages causés par la catastrophe et facilite les opérations de secours et de réhabilitation. [3]

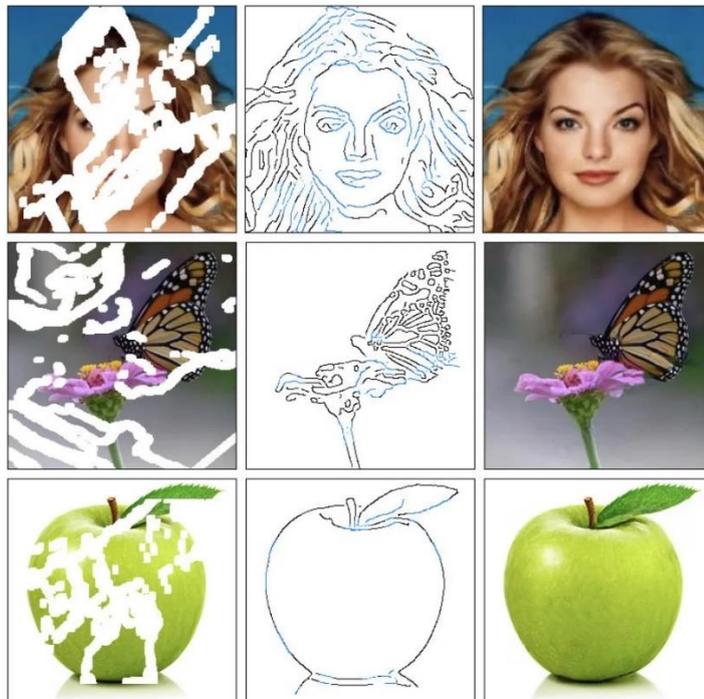


Figure 2 : Les Techniques d'Inpainting [4]

1.4.1. Le but des techniques inpainting:

Les objectifs de l'inpainting sont [3]:

Restaurer les parties manquantes ou endommagées d'une image : L'un des principaux objectifs de l'inpainting est de reconstruire les zones d'une image qui sont soit manquantes, soit endommagées. Cela peut être dû à des erreurs de numérisation, des défauts de compression, des artefacts de l'image, ou même des dommages physiques. L'inpainting vise à remplir ces zones manquantes en utilisant les informations disponibles dans les parties intactes de l'image ou dans les zones environnantes similaires.

Préserver les structures, les textures et les motifs visuels : Lors de la restauration des parties manquantes de l'image, l'inpainting s'efforce de préserver autant que possible les caractéristiques visuelles de l'image originale. Cela signifie qu'il cherche à maintenir les structures, les textures et les motifs visuels de l'image, de sorte que la zone restaurée s'intègre harmonieusement avec le reste de l'image et ne se démarque pas comme une interpolation artificielle.

Améliorer la qualité et l'apparence de l'image : En restaurant les parties manquantes, l'inpainting contribue à améliorer la qualité globale de l'image. En remplissant les zones manquantes, il aide à rendre l'image plus complète et plus esthétiquement satisfaisante. Cela peut être particulièrement important dans des applications telles que la restauration d'œuvres d'art endommagées, où l'objectif est de retrouver autant que possible l'apparence originale de l'œuvre.

Faciliter l'analyse et la compréhension des images : En éliminant les zones manquantes ou endommagées, l'inpainting rend les images plus utilisables pour diverses applications analytiques et de compréhension. Par exemple, dans le domaine médical, l'inpainting peut être utilisé pour restaurer les parties manquantes d'une image radiographique, ce qui facilite l'interprétation des résultats par les professionnels de la santé. De même, dans le domaine de la surveillance environnementale, l'inpainting peut être utilisé pour reconstruire les zones manquantes dans les images satellite, ce qui permet une analyse plus complète de l'état de l'environnement.

1.5. Réseaux de neurones convolutifs :

Les réseaux de neurones convolutifs (CNN) sont comparables aux ANN (réseaux de neurones artificiels) traditionnels dans la mesure où ils sont composés de neurones qui s'auto-optimisent grâce

à l'apprentissage. Depuis les vecteurs d'images brutes d'entrée jusqu'à la sortie finale du score de classe, l'ensemble du réseau exprimera une seule fonction de score perceptif ; le poids. La dernière couche contiendra une fonction de perte relative au nombre de classes, et tous les trucs et astuces habituels développés pour les ANN traditionnels s'appliquent toujours. L'architecture globale d'un CNN est composée de couches convolutives, de couches de regroupement, d'une couche aplatie et de couches entièrement connectées. [4]. comme le montre la figure suivante :

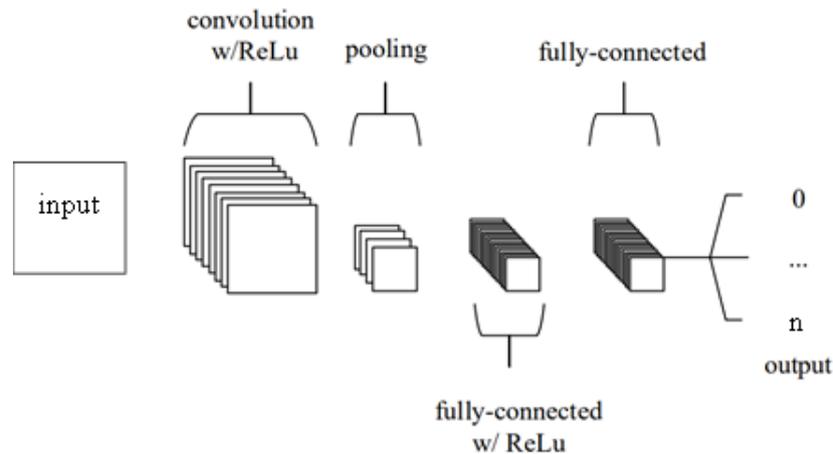


Figure 3 : Basic 5 player CNN architecture outline [5]

1.5.1. CNN Couches:

Il existe plusieurs types de couches CNN. Cependant, par souci de brièveté, nous ne considérerons que ceux qui sont pertinents pour cette thèse :

1.5.1.1. Convolutifs :

Détermine la sortie des neurones connectés aux régions locales de l'entrée grâce au calcul du produit scalaire entre leurs poids et la région connectée au volume d'entrée. ReLu (unité linéaire rectifiée) est couramment utilisé comme fonction d'activation. Les paramètres des couches se concentrent sur l'utilisation de noyaux apprenables. Ces noyaux sont généralement de petite dimension spatiale, mais s'étendent sur toute la profondeur de l'entrée. La couche convolutionne chaque filtre à travers la dimensionnalité spatiale de l'entrée pour produire une carte d'activation 2D [4].

1.5.1.2. Couche de regroupement

Cette couche sert à sous-échantillonner les résultats de la couche précédente selon la dimensionnalité spatiale de l'entrée donnée, réduisant ainsi davantage le nombre de paramètres au sein de cette activation. Cette étape peut être définie comme « pooling maximum » ou « pooling moyen » [4], la différence entre ceux-ci est illustrée dans les figures suivantes :



Figure 4: "max pooling"



Figure 5: "average pooling"

1.5.1.3. Aplanir la couche

Convertir les données en un tableau unidimensionnel pour les saisir dans la couche suivante. Nous aplatissons la sortie des couches convolutives pour créer un seul vecteur de caractéristiques longues. Et il est connecté au modèle de classification final, appelé couche entièrement connectée.

1.5.1.4. La couche entièrement connectée

La couche entièrement connectée, également appelée couche dense, contient des neurones qui sont directement connectés aux neurones des deux couches adjacentes mais pas aux neurones de la même couche. L'objectif de cette couche est de produire des scores de classe à partir des activations, qui seront utilisés pour la classification.

Autres concepts relatifs au processus de formation CNN [6].

1.5.2. époque

Une époque est prise en compte lorsque l'intégralité de l'ensemble de données de formation est transmise une seule fois vers l'avant et vers l'arrière via le réseau neuronal et offre la possibilité de mettre à jour les paramètres internes du modèle. Une époque est composée d'un ou plusieurs lots.

1.5.3. Taille du lot

La taille du lot correspond au nombre total d'exemples de formation présents dans un seul lot. Ce paramètre peut être réglé manuellement avant l'entraînement. et selon la taille du lot, la dénomination du nom de l'algorithme d'apprentissage peut varier:

- **Batch Gradient Descent:** Batch Size = Size of Training Set
- **Stochastic Gradient Descent:** Batch Size = 1
- **Mini-Batch Gradient Descent:** $1 < \text{Batch Size} < \text{Size of Training Set}$

La taille de lot la plus courante pour la descente de gradient en mini-lots est : 32, 64 et 128.

1.5.4. Itération

En termes simples, les itérations correspondent au nombre de lots nécessaires pour terminer une époque.

1.5.5. Exemples d'architectures existantes

Par souci de brièveté, nous nous limiterons aux trois cas que nous avons considérés dans le cadre de ce travail :

1.5.5.1. VGG

VGG Net est le nom d'un réseau neuronal convolutif (CNN) pré-entraîné inventé par Simonyan et Zisserman du Visual Geometry Group (VGG) de l'Université d'Oxford en 2014. VGG 16 et VGG 19 ont respectivement 16 et 19 couches de

poils. VGG Net prend en entrée des images RVB 224×224 et les transmet à travers une pile de couches convolutives avec une taille de filtre fixe de 3×3 et une foulée de 1. Il existe cinq filtres de regroupement maximum intégrés entre les couches convolutives afin de sous-échantillonner. la représentation d'entrée (image, matrice de sortie de couche cachée, etc.) suivi de 3 couches entièrement connectées, ayant respectivement 4096, 4096 et 1000 canaux [7].

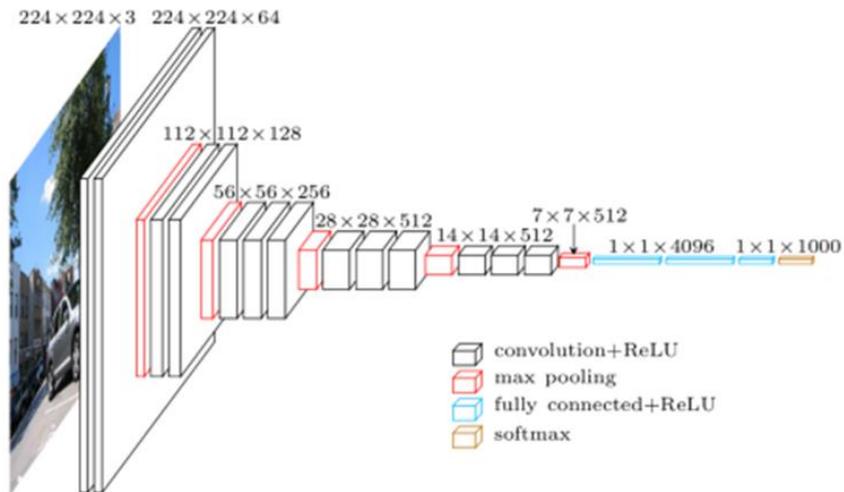


Figure 6: VGG16 architecture [8]

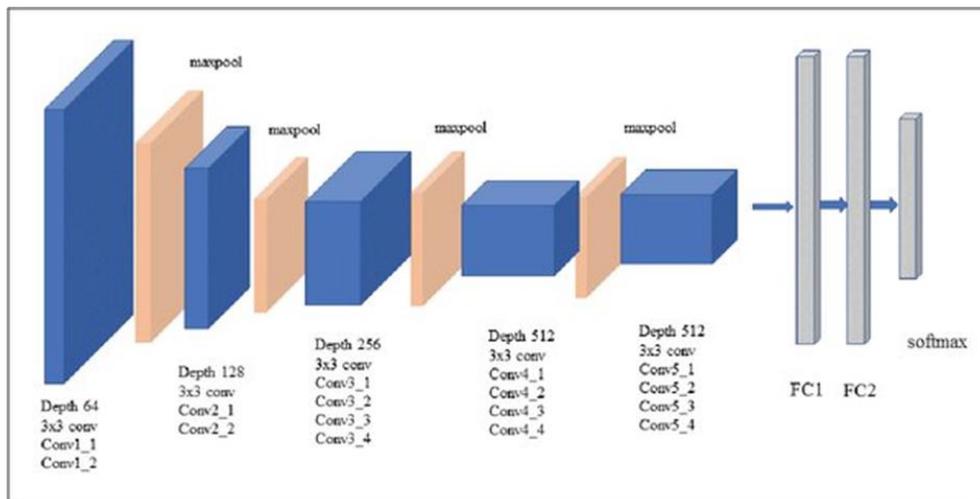


Figure 7: VGG19 architecture [9]

1.5.5.2. ResNet

ResNets ou réseaux résiduels, apprennent les fonctions résiduelles en référence aux entrées de couche, au lieu d'apprendre des fonctions non référencées. Au lieu d'espérer que chaque couche empilée corresponde directement à une cartographie sous-jacente souhaitée, les réseaux résiduels permettent à ces couches de s'adapter à une cartographie résiduelle. Ils empilent les blocs résiduels les uns sur les autres pour former un réseau : par ex. un ResNet-50 comporte cinquante couches utilisant ces blocs [10], son architecture est illustrée dans la figure suivante :

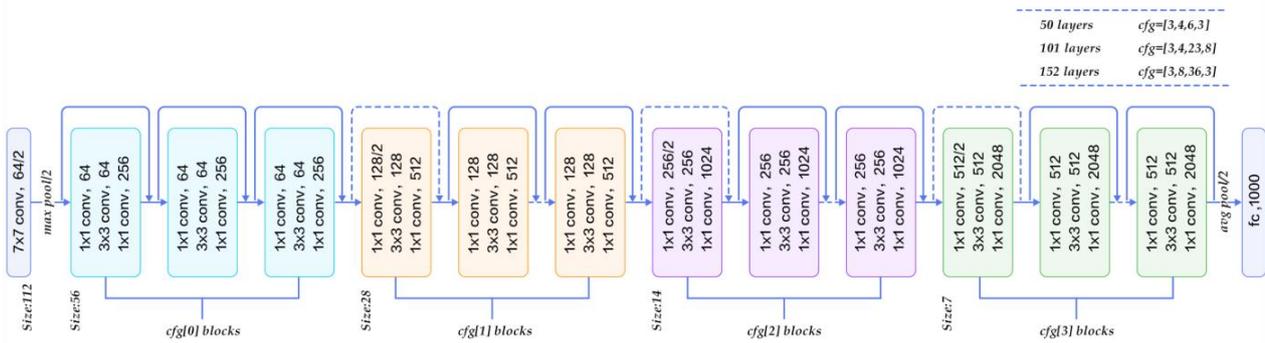
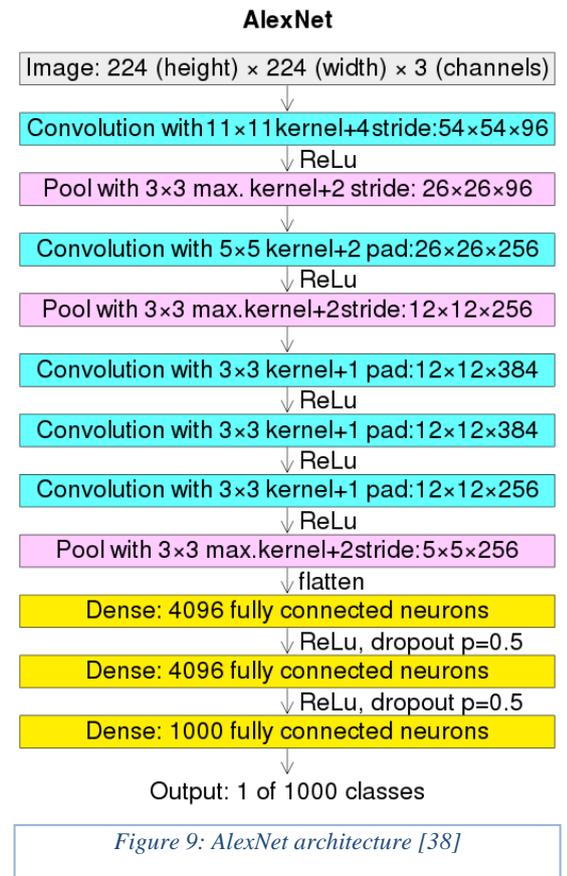


Figure 8: ResNet50 architecture [11]

1.5.5.3. AlexNet

Ce CNN a été conçu par Alex Krizhevsky en collaboration avec Ilya Sutskever et Geoffrey Hinton [20]. Ce réseau a réussi à obtenir une erreur dans le top 5 de 15,3 % lors du défi de reconnaissance visuelle à grande échelle 2012. Le réseau a obtenu une erreur dans le top 5 de 15,3 %, battant la concurrence de plus de 10,8 %.[21]. AlexNet se caractérise par ses 650 000 neurones et 60 millions de paramètres, répartis sur trois blocs avec respectivement une, une et trois couches convolutives, soit cinq au total, chaque bloc est suivi d'une couche de pooling maximum. Le réseau se termine par trois couches entièrement connectées avec un softmax final à 1 000 voies.



1.5.6. CNN méthodes d'entraînement :

Dans le cadre de cette recherche, nous avons examiné une approche de la formation ; Apprendre à partir de zéro. Mais il existe deux méthodes de formation, les deux méthodes présentent des avantages et des inconvénients :

1.5.6.1. Formation à partir de zéro

La formation à partir de zéro s'apparente à la formation conventionnelle en machine learning, où le modèle n'a accès qu'aux ensembles de données pertinents. Les

poids sont initialisés avec des valeurs aléatoires puis progressivement ajustés en corrélation avec les données d'entraînement fournies.

1.5.6.2. Transférer l'apprentissage

L'apprentissage par transfert est l'acte de réutiliser les connaissances de tâches antérieures liées dans le but de tirer parti de l'apprentissage et de l'expérience précédemment acquis pour apprendre plus efficacement la nouvelle tâche. L'avantage de cette approche est, le plus souvent, la réduction du nombre d'échantillons d'entraînement nécessaires pour atteindre une performance souhaitée sur une série de tâches d'apprentissage connexes. Ce concept reflète essentiellement la façon dont les humains apprennent, étant donné qu'en général, quelques exemples de formation d'une nouvelle idée suffisent pour qu'une personne ayant des connaissances préalables sur les concepts associés comprenne très rapidement le nouveau concept. il est courant de geler la plupart des couches et de recycler sélectivement uniquement certaines couches dans un processus appelé réglage fin. [13].

Le réglage fin consiste à sélectionner manuellement les couches individuelles d'un CNN pré-entraîné et à les affiner (formation) pour mieux les adapter à une tâche donnée. Bien qu'il soit courant de concentrer le réglage fin sur les dernières couches du modèle (couches denses et activation couche), toutes les couches du réseau peuvent être affinées. Cependant, il n'existe pas de règle générale quant aux couches à sélectionner afin d'atteindre des performances optimales. Le réglage précis est donc un processus d'essais et d'erreurs. [14].

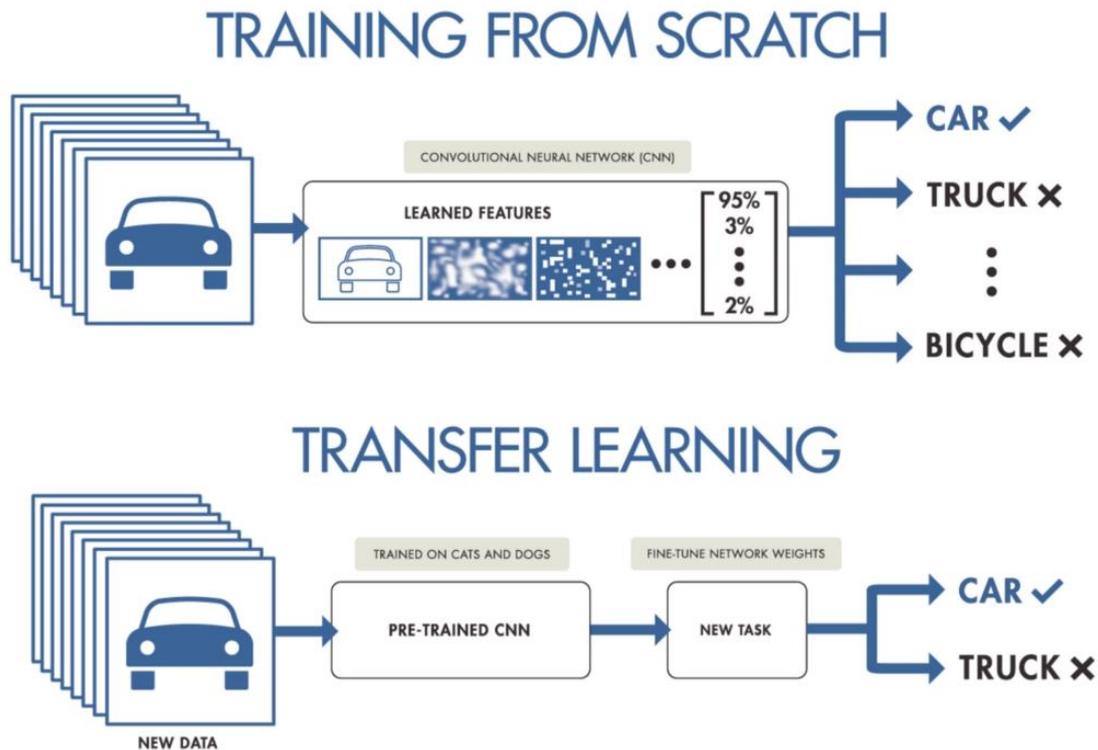


Figure 10: différence entre une formation à partir de zéro et un apprentissage par transfert [37]

Même si la formation d'un réseau à partir de zéro prend du temps et demande beaucoup de travail, l'apprentissage par transfert n'est pas toujours avantageux, en particulier lorsque l'ensemble de données utilisé pour la pré-formation est radicalement différent de la nouvelle tâche. De plus, se former à partir de zéro permet une meilleure compréhension du réseau [15].

1.6. Le surapprentissage

Le surapprentissage est un problème central dans l'apprentissage automatique supervisé (apprentissage à partir de données d'entraînement étiquetées). On l'observe lorsqu'un modèle finit par surapprendre et à mémoriser des aspects indésirables des données, l'empêchant ainsi de généraliser les modèles pour bien s'adapter non seulement aux données d'entraînement, mais également aux données invisibles contenues dans l'ensemble de validation/test. À ne pas confondre avec le sous-ajustement, un problème similaire qui se produit lorsqu'un modèle est sous-entraîné. Le surapprentissage se produit généralement en raison de : données mal prétraitées contenant trop de bruit, un petit ensemble de formation et/ou l'utilisation d'une architecture de modèle trop complexe [16].

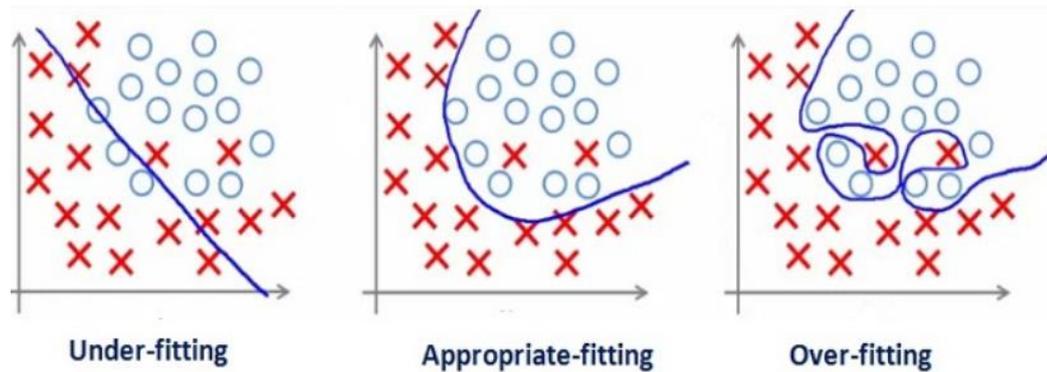


Figure 11: graphiques illustratifs affichant la différence entre le sous-ajustement, l'ajustement optimal et le surajustement [35]

1.6.1. Prévention du surajustement

Over the years, researchers have discovered various strategies to reduce the effects of overfitting:

1.6.1.1. Réduction du réseau

La réduction du réseau implique de réduire la complexité de classification du modèle. Et bien que l'apprentissage automatique général propose de multiples façons de mettre en œuvre ce concept, dans le cas des CNN, cela peut être réalisé grâce à : faire varier la complexité du modèle en modifiant le nombre de paramètres adaptatifs dans un processus appelé stabilisation structurelle, ou en choisissant une architecture de modèle plus petite s'il s'agit d'une architecture préexistante consistant à supprimer manuellement des couches pour réduire le nombre de neurones [17].

1.6.1.2. Augmentation des données

L'augmentation des données est un ensemble de techniques utilisées pour augmenter artificiellement la quantité de données en générant de nouveaux points de données à partir des données existantes. Cela inclut l'application de petites modifications aux données ou l'utilisation

de modèles d'apprentissage en profondeur pour générer de nouveaux points de données. Ces méthodes sont souvent utilisées comme solution au surajustement [18].

1.6.1.3. *Rappels*

Les rappels sont des méthodes qui peuvent effectuer certaines actions à différentes étapes de la formation, par exemple : au début ou à la fin d'une époque. Dans cette thèse, nous considérons deux types de rappels :

1.6.1.3.1. Points de contrôle

Les points de contrôle de modèle dans les karas sont des rappels utilisés pour enregistrer un modèle ou des poids (dans un fichier de point de contrôle) à un certain intervalle, habituel afin que le modèle ou les poids puissent être chargés plus tard pour continuer la formation à partir de l'état enregistré.

1.6.1.3.2. Arrêt anticipé

En bref, cette méthode arrêtera automatiquement la formation dès que les métriques de formation cesseront de s'améliorer. Ainsi, empêchant l'apprentissage du bruit. Cette technique est également très efficace pour éviter le sous-ajustement puisqu'elle arrête l'entraînement au moment le plus opportun, lorsque les métriques ont atteint leur pic apparent (meilleure valeur). [19].

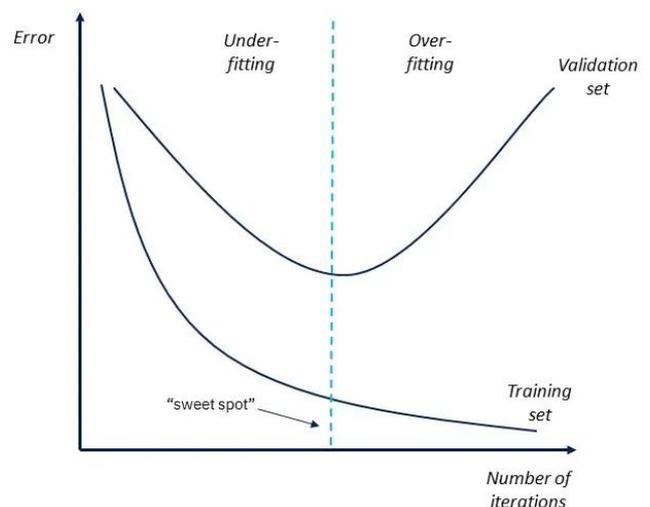


Figure 12: exemple de graphique d'un arrêt anticipé dans le cas d'une perte de formation ou d'une perte de validation [36]

1.6.1.4. *Régularisation*

La sortie du modèle est affectée par plusieurs fonctionnalités. Lorsque le nombre de fonctionnalités augmente, la complexité du modèle augmente également. Un modèle de surajustement a tendance à prendre en compte toutes les fonctionnalités, même si certaines d'entre elles ont un effet très limité sur le résultat final. Certains peuvent également être

considérés comme du bruit qui non seulement n'a aucune signification pour le résultat, mais peut même nuire aux performances. Ainsi, afin de limiter ces cas, il existe deux solutions ; la première est de sélectionner uniquement les fonctionnalités utiles et de supprimer les fonctionnalités inutiles de notre modèle via un prétraitement manuel ou automatique des données, la seconde est de minimiser les poids des fonctionnalités qui ont peu d'influence sur la classification finale [16].

1.7. Conclusion

Dans ce chapitre, nous avons fourni une brève introduction aux catastrophes naturelles et aux différentes techniques à utiliser pour comprendre ce travail. Cela comprenait Les méthodes de restauration d'images et Les Techniques d'Inpainting, en plus des différentes techniques utilisées dans le traitement des données mentionnées. Nous avons ensuite fait un rapide tour d'horizon des concepts de réseaux convolutifs ainsi que de quelques exemples de modèles préexistants et de la manière dont ils peuvent être utilisés à travers l'idée d'apprentissage par transfert. Enfin, nous avons parlé du problème du surapprentissage et présenté quatre façons d'atténuer ce problème ; Réduisez le réseau, augmentez les données, les bouclages et l'organisation. Dans le prochain chapitre, nous discuterons de l'état de l'art.

Chapter 02: Les techniques de l'IA pour l'évaluation des catastrophes naturelles

2.1. Introduction

Récemment, l'apprentissage automatique et les réseaux neuronaux profonds ont gagné en utilisation dans diverses applications scientifiques, y compris la prédiction et l'évaluation des catastrophes naturelles. Il y a eu un intérêt de recherche significatif pour la création de systèmes automatisés pour la détection précoce des catastrophes naturelles basés sur les données. Dans ce chapitre, nous détaillons les travaux antérieurs qui ont été spécifiquement réalisés concernant la prédiction et l'évaluation des catastrophes naturelles, quels ensembles de données ils ont utilisés, quelles méthodes ils ont employées, et quels résultats ils ont obtenus. Cette section servira également d'histoire évolutive de ces travaux, car ils seront triés du plus ancien au plus récent.

2.2. Intelligence artificielle et prévision des catastrophes

Les technologies intelligentes, y compris l'intelligence artificielle (IA), peuvent aider les gens à répondre efficacement après une catastrophe naturelle de plusieurs manières. Nous allons discuter de ces méthodes en nous concentrant sur les défauts des technologies anciennes utilisées avant le développement de l'IA.

Défauts des Anciennes Technologies dans la Réponse aux Catastrophes

Lenteur de la Collecte et de l'Analyse des Données :

Défaut : Dans les anciennes technologies, les processus de collecte et d'analyse des données étaient lents en raison de la dépendance aux rapports papier ou aux bases de données manuelles.

Technologies Intelligentes : L'IA peut analyser de grandes quantités de données en très peu de temps, permettant une réponse rapide.

Manque de Précision des Prévisions :

Défaut : Les prévisions étaient basées sur des modèles mathématiques simples et ne pouvaient pas s'adapter rapidement aux nouvelles données ou aux changements des conditions environnementales.

Technologies Intelligentes : Les technologies d'IA, telles que l'apprentissage profond et les réseaux neuronaux, analysent les données historiques et en temps réel pour fournir des prévisions plus précises et fiables.

Faiblesse de la Communication et de la Coordination :

Défaut : Il y avait un manque de coordination entre les différentes entités, telles que les équipes de secours et les autorités locales, entraînant des réponses inefficaces.

Technologies Intelligentes : L'IA et les plateformes intelligentes peuvent améliorer la communication et la coordination entre les différentes équipes en fournissant des plateformes centralisées pour l'échange d'informations en temps réel.

Difficulté de Suivi des Ressources :

Défaut : Le suivi et la distribution des ressources comme la nourriture, l'eau et les médicaments se faisaient manuellement, entraînant une distribution inéquitable ou inefficace.

Technologies Intelligentes : L'IA peut gérer intelligemment les chaînes d'approvisionnement, améliorant la distribution des ressources en fonction des besoins réels et des emplacements critiques.

2.3. Travaux connexes

2.3.1. Depuis (2017 – 2019)

L'article [20] explore l'utilisation des Réseaux de Neurones Convolutifs (CNN) pour détecter les bâtiments emportés par les eaux à partir d'images aériennes, atteignant une précision de 94 à 96 %. L'étude [21] met en avant l'utilisation de drones équipés de caméras et de CNN pour la classification des scènes de catastrophe, obtenant une précision de 91,9 %. La recherche [22] propose une méthode d'évaluation des dommages post-catastrophe à l'aide d'images satellite et de SegNet, avec une précision de 86,3 %. Enfin, l'étude [23] utilise des techniques d'apprentissage automatique pour prédire les dommages causés par le séisme de

Gorkha au Népal, la méthode de la forêt aléatoire surpassant celle des réseaux de neurones avec un score F1 de 74,32 %.

2.3.2. Depuis (2020 - 2024)

L'étude [24] se concentre sur l'utilisation de l'apprentissage profond pour améliorer la réponse aux urgences via des drones équipés de caméras, introduisant EmergencyNet, un CNN léger qui fonctionne efficacement sur des plateformes à faible puissance et atteint un score F1 de 95,7 %. Le document [25] présente une approche pour évaluer les dommages des bâtiments après des catastrophes naturelles en utilisant Mask R-CNN et un modèle Siamese pour améliorer la précision de 16 fois. L'étude [26] introduit FloodNet, un ensemble de données UAV haute résolution pour l'analyse des inondations après l'ouragan Harvey, atteignant un score de 96,54 %. Dans [27], une version pré-entraînée de ResNet-34 est utilisée pour détecter les dommages aux bâtiments à partir d'images post-événement avec une précision de 91 %. L'étude [28] propose MoCo-Q, un modèle d'apprentissage auto-supervisé pour la reconnaissance d'images de catastrophes, surpassant les méthodes supervisées avec une précision de 91,56 %. Enfin, l'étude [29] propose ECADS-CNN pour détecter les dommages aux bâtiments, améliorant la vitesse de 7,4% et le score F1 global de 5,2%, atteignant un score F1 de 82,14.

2.4. Résumé de l'état de l'art

À titre d'illustration, la figure suivante résume brièvement tous les travaux mentionnés dans ce chapitre:

	Étude	Année	Approche	Dataset	Accuracy%
1	A.fujita et al [20]	2017	CNN	ABCD	96%
2	Christos et al [21]	2019	CNN	AIDER	91.9%
3	S. jones et al [22]	2019	SegNet	The Copernicus EMS	86.3%
4	K. Chaurasia et al [23]	2019	NN+RF	-	74.32%
5	C. kyrkou et al [24]	2020	EmergencyNet	AIDER	95.7
6	F. zhao et al [25]	2020	ResNet	xBD	80%
7	M. Rahnemoonfar et al [26]	2021	Xception	FloodNet	96.54%
8	G. abdi et al [27]	2021	ResNet	-	91%
9	L.wang et al [28]	2022	ResNet50	CrisisMMD et ASONAM17	91.56%
10	Zongze Zhao et al [29]	2024	ECADS-CNN	xBD	82.14%

Table 1 : Résumé de l'état de l'art

2.5. Conclusion

Dans ce chapitre, nous avons examiné différentes études récentes allant de 2017 à l'année de rédaction de cette thèse (2024), les ensembles de données qu'elles ont utilisés, les méthodes qu'elles ont appliquées et les résultats qu'elles ont obtenus. Cette section présente également l'évolution historique des systèmes de détection et d'évaluation des catastrophes naturelles. Nous concluons en compilant tous les articles mentionnés dans ce chapitre dans un tableau récapitulatif à des fins d'illustration. Dans le prochain chapitre, nous détaillerons notre propre approche en expliquant notre méthode de formation, les ensembles de données utilisés, ainsi que le processus de traitement et d'amélioration des données mentionnées précédemment. De plus, nous présenterons les modèles utilisés (modèle de Deep Learning) et les résultats expérimentaux obtenus grâce à nos méthodes de formation. Enfin, nous fournirons des détails sur l'environnement d'exécution dans lequel les formations ont été réalisées (infrastructure de calcul, GPU utilisés, frameworks de deep learning comme TensorFlow).

Chapter 03: Résultats Expérimentaux

3.1. Introduction

Dans ce chapitre, nous détaillerons les différentes approches utilisées dans ce travail, du traitement des données aux étapes d'entraînement et nos architectures CNN proposées. Nous fournirons des informations sur les ensembles de données utilisés et expliquerons l'environnement d'exécution, y compris le matériel et les logiciels. De plus, nous aborderons les répartitions exactes des données et le nombre d'échantillons. Nous expliquerons également le concept de matrice de confusion et comment nous l'utiliserons pour l'acquisition de nos résultats. Enfin, nous présenterons les différents résultats d'entraînement obtenus, que nous évaluerons à l'aide de quatre métriques : Précision (Accuracy), Sensibilité (Sensitivity), Spécificité (Specificity) et Précision Équilibrée (Balanced Accuracy), et nous conclurons par une comparaison avec l'état de l'art.

3.2. La contribution

La contribution de notre mémoire réside dans l'application des techniques d'inpainting pour évaluer les dommages causés par les catastrophes naturelles à travers la restauration d'images. Nous avons développé une méthodologie en deux phases pour atteindre cet objectif. Tout d'abord, nous avons analysé les ensembles de données disponibles et entraîné des modèles à l'aide de ResNet, un réseau de neurones convolutif profond. Ensuite, nous avons appliqué des techniques d'inpainting sur les mêmes ensembles de données et réentraîné les modèles pour améliorer la précision de la restauration des images. Nos résultats démontrent l'efficacité de cette approche pour estimer avec précision les dommages causés par les catastrophes naturelles, ce qui pourrait contribuer à améliorer les opérations d'intervention d'urgence et de reconstruction dans ces situations critiques.

3.3. Méthode de formation

Une analyse de l'ensemble de données utilisé a été effectuée, avec 277 échantillons pour l'entraînement et 31 échantillons pour le test pour toutes les exécutions d'entraînement réalisées. De plus, tous les modèles ont été entraînés pour un maximum de 100 époques avec une taille de lot fixe de 32. Pour une explication des concepts de ces thèses, voir le chapitre un.

Les trois points de contrôle avaient l'attribut `save_best_only` réglé sur `true`, `save_weights_only` réglé sur `false`, et ces points de contrôle étaient les suivants :

- **Accuracy** : L'accuracy se réfère au degré de précision atteint par le modèle sur une période donnée dans l'ensemble de données d'entraînement. Notre objectif est d'obtenir une précision maximale.
- **Validation accuracy** : La validation accuracy se réfère au degré de précision atteint par le modèle sur une période donnée dans l'ensemble de données de validation. Tout comme pour le point de validation, nous souhaitons également une validation aussi précise que possible.
- **Validation loss** : La validation loss se réfère au taux d'erreur atteint par le modèle sur une période donnée dans l'ensemble de données de validation. Contrairement aux deux points de contrôle précédents, dans ce cas, nous cherchons à obtenir une perte de validation minimale.

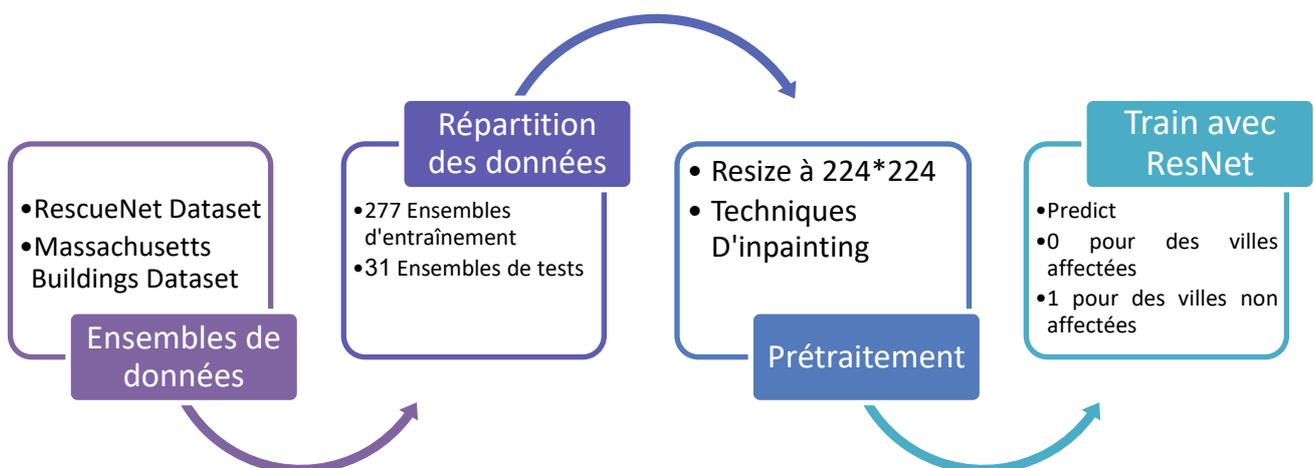


Figure 13 : Méthode de formation

3.4. Ensembles de données utilisés

Dans ce travail, nous avons utilisé deux ensembles de données largement disponibles : RescueNet et Massachusetts Buildings Dataset. Nous avons utilisé le premier ensemble de données, RescueNet, comme classe des villes affectées par des catastrophes naturelles, et nous avons utilisé le deuxième ensemble de données, Massachusetts Buildings Dataset, comme classe des villes non touchées par des catastrophes naturelles.

3.4.1. RescueNet

RescueNet fournit des images UAS haute résolution avec une annotation sémantique détaillée concernant les dommages. Les données sont collectées avec une plateforme UAS, les quadricoptères DJI Mavic Pro, après l'ouragan Michael. L'ensemble de données comprend 4494 images, réparties en ensembles d'entraînement (~80%), de validation (~10%) et de test (~10%). Les labels de segmentation sémantique incluent : Fond, Eau, Bâtiment sans dommage, Bâtiment avec dommages mineurs, Bâtiment avec dommages majeurs, Bâtiment totalement détruit, Route dégagée, Route bloquée, Véhicule, Arbre, Piscine. [30]

3.4.2. Massachusetts Buildings

Le Massachusetts Buildings Dataset se compose de 151 images aériennes de la région de Boston, chaque image ayant une taille de 1500×1500 pixels pour une superficie de 2,25 kilomètres carrés. Ainsi, l'ensemble de données couvre environ 340 kilomètres carrés. Les données sont réparties en un ensemble d'entraînement de 137 images, un ensemble de test de 10 images et un ensemble de validation de 4 images. [31]

la figure suivante détaille brièvement le contenu des deux ensembles de données utilisés avec les aperçus d'images inclus:

Data Set	Data Types	L'image originale		Techniques D'inpainting	
RescueNet	Bâtiments endommagés				
		Train	Test	Train	Test
		140	21	140	21
Massachusetts Buildings	Bâtiments intacts				
		Train	Test	Train	Test
		137	10	137	10

Table 2 : Répartition des données

3.5. Traitement des données

3.5.1. Prétraitement des images

Le prétraitement d'images fait référence aux étapes prises pour nettoyer les données d'images brutes de toute valeur fautive, manquante ou incomplète, ou de tout bruit, avant son utilisation dans les modèles et extracteurs de caractéristiques. Bien que l'application intelligente de ces techniques puisse grandement bénéficier aux systèmes de reconnaissance, il convient de souligner que cette phase est facultative en fonction des données d'entrée disponibles. [32].

En raison du fonctionnement des noyaux, les CNN n'utilisent relativement peu voire pas de prétraitement par rapport à d'autres algorithmes de classification d'images. [33]. Cependant, une manière d'implémenter le prétraitement d'images dans les CNN consiste à avoir une couche initiale de filtres prédéfinis qui sont conservés fixes pendant l'entraînement. De cette manière, des informations supplémentaires en plus de l'image d'entrée brute peuvent être fournies au réseau, par exemple, les contours et les gradients. [34].

Cela dit, les échantillons de données contenus dans les ensembles de données utilisés dans nos expériences n'ont pas nécessité de segmentation des données car ils étaient déjà séparés en échantillons. Cependant, nous avons redimensionné tous les échantillons à une taille standardisée de 224x224 pixels, comme le recommande la forme d'entrée pour l'architecture ResNet. Toutes les redimensionnements ont été effectués en utilisant la méthode de redimensionnement de la bibliothèque python OpenCV (version 4.1.2).

En plus de cela, nous avons choisi de sérialiser toutes nos données à l'avance en utilisant la bibliothèque pickle.



3.5.2. Techniques D'inpainting

La technique d'inpainting est un outil crucial dans la restauration des images endommagées, et dans notre étude, elle a été utilisée pour faciliter l'identification des bâtiments et des zones clés dans les images aériennes après les catastrophes naturelles. Avant le traitement, cette technique transformait l'image en un fond noir, où les bâtiments, les surfaces et les routes étaient distingués en blanc. Cette démarche essentielle permet une compréhension précise des données et facilite l'analyse des zones touchées. [3]

L'utilisation de cette technique simplifie le processus d'identification des bâtiments dans les images aériennes après une catastrophe naturelle. En marquant clairement les bâtiments sur un fond noir, elle améliore la précision des évaluations et des interventions. En fournissant des images restaurées plus claires et précises, cette méthode permet des décisions plus éclairées et une intervention plus efficace lors de situations d'urgence.



Figure 14 : Techniques D'inpainting

3.6. ResNet

Dans les blocs résiduels, l'entrée de chaque couche est combinée à la sortie de cette couche à l'aide d'une connexion résiduelle. Cette connexion résiduelle permet au réseau de conserver des informations sur l'entrée d'origine, ce qui facilite l'apprentissage de fonctions complexes. Cette architecture a permis de construire des réseaux de neurones profonds atteignant des performances de pointe dans la classification d'images, et elle est devenue une référence dans le domaine de la vision par ordinateur. [16].

Nom de couche	Type de couche	Taille	Taille du noyau	Stride	Paramètres
Input_1	Input layer	224x224x3	-	-	-
conv1	Convolution 2D	112x112x64	7x7	2	9,472
Maxpool	Max pooling 2D	56x56x64	3x3	2	0
ResBlock1	Residual Block	56x56x256	-	-	-
ResBlock2	Residual Block	28x28x512	-	-	-
ResBlock3	Residual Block	14x14x1024	-	-	-
ResBlock4	Residual Block	7x7x2048	-	-	-
GlobalAvgPool	Global Average Pooling	1x1x2048	-	-	0
Dense	Fully Connected	1x1x1000	-	-	2,790,018

3.7. Matrice de confusion

La matrice de confusion, ou matrice d'erreur, est un agencement tabulaire qui permet une visualisation pratique des performances d'un modèle. Cette représentation est plus couramment utilisée avec l'apprentissage supervisé. Chaque ligne de la matrice représente les instances dans une classe réelle tandis que chaque colonne représente les instances dans une classe prédite, ou vice versa. [35].

- **Positifs (P)** : nombre total de positifs, individus atteints de Parkinson. Alternativement:

$$P = TP + FN$$

- **Négatifs (N)**: nombre total de négatifs, dans le contexte de ce travail ; individus en bonne santé. Alternativement: $N = TN + FP$

- **True Positives (TP)**: le nombre d'exemples positifs que le modèle a correctement classés comme positifs.
- **True Negatives (TN)**: le nombre d'exemples négatifs que le modèle a correctement classés comme négatifs.
- **False Positives (FP)**: le nombre d'exemples négatifs que le modèle a incorrectement classés comme positifs.

Confusion Matrix

	Actually Positive (1)	Actually Negative (0)
Predicted Positive (1)	True Positives (TPs)	False Positives (FPs)
Predicted Negative (0)	False Negatives (FNs)	True Negatives (TNs)

Figure 15 : matrice de confusion

- **False Negatives (FN)**: le nombre d'exemples positifs que le modèle a incorrectement classés comme négatifs.

Bien qu'il existe plusieurs points de données qui peuvent être extraits d'une matrice de confusion, dans ce travail, nous avons choisi de nous concentrer sur les cinq suivants :

- **Accuracy**: Connue sous le nom de précision conventionnelle, souvent abrégée en ACC, elle est déterminée en divisant le nombre de prédictions correctes par le nombre total d'échantillons dans l'ensemble de données. Elle peut également être obtenue en soustrayant le taux d'erreur de 1 :

$$ACC = \frac{TP + TN}{P + N}$$

- **Error rate** : Aussi appelé ERR, il s'agit de la division du nombre de toutes les prédictions incorrectes par le nombre total d'échantillons dans l'ensemble de données utilisé. En corrélation avec ACC, le meilleur taux d'erreur est de 0.0, tandis que le pire est de 1.0.

$$ERR = \frac{FP + FN}{P + N}$$

- **Sensitivity** : Également connu sous le nom de Recall ou TPR (pour Taux de Vrais Positifs), il représente tous les cas réellement positifs. Le meilleur TPR est de 1.0, tandis que le pire est de 0.0. Il est défini comme suit :

$$TPR = \frac{TP}{P}$$

- **Specificity**: Également connu sous le nom de Selectivity ou TNR (pour Taux de Vrais Négatifs), son objectif est d'identifier la proportion de cas Positifs Prédits qui sont correctement des Positifs Réels. Encore une fois, dans le meilleur des cas, TNR = 1.0. Il est défini comme suit :

$$TNR = \frac{TN}{N}$$

- **Balanced Accuracy** [37]: Souvent abrégée en ACC_{bal}, elle vise à identifier les performances d'un modèle indépendamment du déséquilibre des données entre le nombre de négatifs et de positifs. Elle est définie comme suit :

$$ACC_{bal} = \frac{TNR + TPR}{2}$$

3.8. Environnement d'exécution

Dans cette section, nous détaillons le matériel et les logiciels utilisés pour tous les entraînements réalisés dans le cadre de cette thèse :

3.8.1. Hardware

Tous les entraînements ont été réalisés dans l'environnement d'exécution de Google Colab, et au moment de cette thèse, la version gratuite de Google Colab fournit un GPU Tesla T4 ou équivalent avec 16 Go de VRAM. Deux threads d'un processeur Intel Xeon avec 12 à 13 Go de RAM système. Et environ 41 Go de stockage de disque cloud disponibles pendant 12 heures par jour. Le GPU, cependant, n'est disponible que pendant 6 heures.



Figure 16: google colab logo

3.8.2. Software

L'EDI que nous avons principalement utilisé est le gestionnaire de notebooks de Google Colab. Avec Python 3.7.13 et la version 2.8.0 des bibliothèques Tensorflow et Keras. Cependant, pour les brèves instances où nous avons dû utiliser un environnement d'exécution local, nous avons opté pour Anaconda Navigator (anaconda3) version 3.9.7 avec Jupiter notebook version 6.4.8. Les versions de Tensorflow et Keras dans ce cas étaient 2.6.0.

3.9. Résultats expérimentaux

Dans cette section, nous discuterons, étape par étape, de tous les résultats obtenus grâce à notre méthodologie, en fournissant des explications et des justifications.

Nos tests expérimentaux ont été menés sur les ensembles de données RescueNet et Massachusetts Buildings Dataset. Nous les avons combinés de manière que l'ensemble de données RescueNet représente les villes affectées et que le Massachusetts Buildings Dataset représente les villes saines et non affectées. Le modèle ResNet a également été utilisé pour entraîner l'ensemble de données en deux étapes. La première étape concerne les images du dataset capturées par des satellites, et la deuxième étape consiste en l'application de techniques d'inpainting au dataset.

3.9.1. La première expérimentation :

Dans la première étude, après avoir préparé l'ensemble de données, qui se compose de RescueNet représentant les villes affectées et du Massachusetts Buildings Dataset représentant les villes saines et non affectées, et après l'étape de prétraitement consistant à uniformiser les tailles des images et l'ensemble de données à une taille uniforme de 224x224, qui est la taille requise pour l'architecture ResNet, nous avons finalement entraîné le modèle et suivi les résultats de l'étude en utilisant les métriques suivantes : Accuracy, Loss, Validation Accuracy et Validation Loss, comme représenté dans le tableau suivant :

	Model	Accuracy	Loss	Validation Accuracy	Validation Loss
DataSet	ResNet	0.90	0.0534	0.90	0.0912

Table 3 : première expérimentation

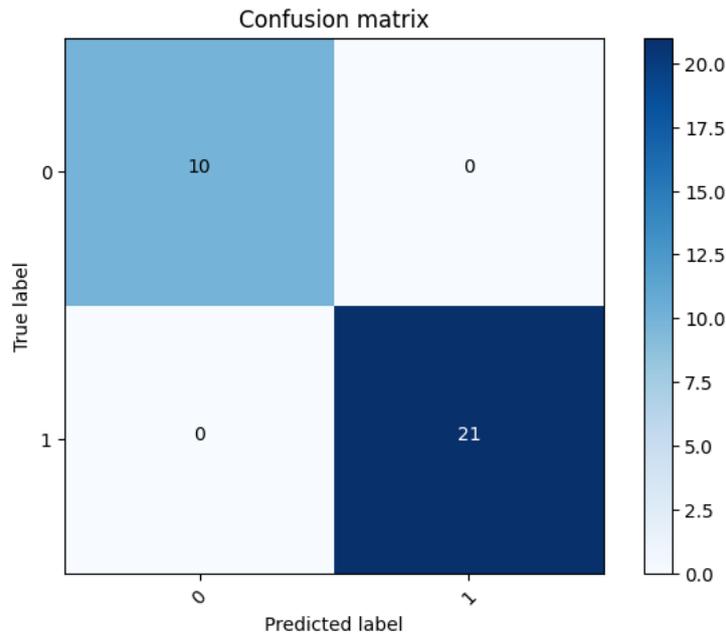


Figure 17 : matrice de confusion de première expérimentation

La précision du modèle (Accuracy) sur l'ensemble de données d'entraînement était de 0.90, ce qui indique que le modèle était correct à 90 % dans ses prédictions. La perte (Loss) était très faible, atteignant 0.0534, ce qui reflète que l'erreur dans les prédictions était minime. La précision de validation (Validation Accuracy) était également de 0.90, ce qui signifie que le modèle était précis à 90 % sur l'ensemble de données non utilisé pour l'entraînement. Quant à la perte de validation (Validation Loss), elle était de 0.0912, légèrement supérieure à la perte sur l'ensemble de données d'entraînement mais restant faible. Ces résultats indiquent que le modèle ResNet était capable de distinguer parfaitement entre les villes affectées et les villes saines sur les ensembles de données d'entraînement et de validation, ce qui démontre une performance solide du modèle dans ce contexte.

3.9.2. La deuxième expérimentation :

Dans l'étude précédente, nous avons utilisé l'ensemble de données qui se compose de RescueNet représentant les villes affectées et du Massachusetts Buildings Dataset représentant les villes saines et non affectées. De plus, cet ensemble de données a été standardisé à la même taille qu'auparavant, soit 224*224, et entraîné à l'aide du même modèle ResNet.

Cependant, dans cette étude, l'ensemble de données a été traité à l'aide de la technique d'inpainting, qui convertit l'image en un arrière-plan noir et identifie les bâtiments intacts et endommagés en blanc, les rendant facilement distinguables dans les images.

Les résultats ont été présentés à l'aide des mesures suivantes : Précision, perte et validation Précision et perte de validation, telles que renvoyées dans le tableau suivant:

	Model	Accuracy	Loss	Validation Accuracy	Validation Loss
DataSet + Techniques D'inpainting	ResNet	0.93	1.0644e-5	0.93	1.1194e-05

Table 4 : deuxième expérimentation

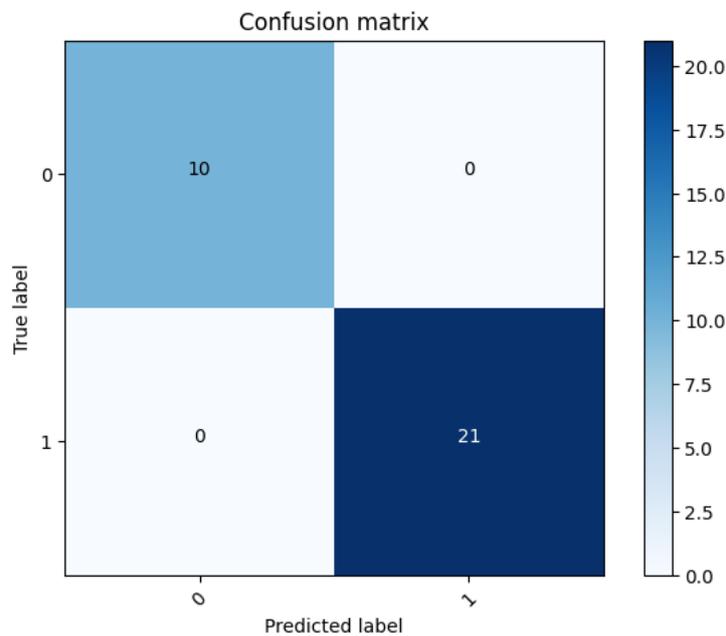


Figure 18 : matrice de confusion de deuxième expérimentation

Les résultats de l'étude montrent que l'utilisation de la technique d'inpainting sur l'ensemble de données en plus du modèle ResNet a donné d'excellents résultats. Une précision (Accuracy) de 93% a été atteinte sur l'ensemble de données avec une perte (Loss) très faible estimée à $1.0644e-5$. De plus, une précision de validation (Validation Accuracy) de 93% a été réalisée avec une perte de validation (Validation Loss) également très faible, estimée à $1.1194e-05$. Ces résultats indiquent que le modèle est capable de reconnaître avec précision les structures intactes et endommagées dans les images grâce à l'utilisation de la technique d'inpainting.

3.9.1. Tous les résultats expérimentaux

	Accuracy	Loss	Validation Accuracy	Validation Loss
First Experimental	0.90	0.0534	0.90	0.0912
Second Experimental	0.93	1.0644e-5	0.93	1.1194e-05

Table 5 : Tous les résultats expérimentaux

Dans la première expérience, vous avez utilisé ResNet sans la technique d'inpainting sur le jeu de données Massachusetts Buildings. Voici les résultats :

- Précision du modèle : 0,90
- Perte : 0,0534
- Précision de validation : 0,90
- Perte de validation : 0,0912

Dans la deuxième expérience, vous avez utilisé le même modèle (ResNet) sur le même ensemble de données, mais cette fois-ci en utilisant la technique d'inpainting. Voici les résultats :

- Précision du modèle : 0,93
- Perte : 1,0644e-5
- Précision de validation : 0,93
- Perte de validation : 1,1194e-05

Les résultats montrent que l'utilisation de la technique d'inpainting a considérablement amélioré les performances du modèle. Dans la deuxième expérience, la précision du modèle est passée à 0,93 et la perte a considérablement diminué, ce qui indique que la technique d'inpainting a contribué à améliorer la capacité du modèle à apprendre et à distinguer plus efficacement entre les données. En conclusion, la comparaison des résultats montre que l'utilisation de la technique d'inpainting a eu un impact positif sur les performances du modèle, en augmentant sa précision et en améliorant la valeur de la perte.

3.10. Comparaisons

Dans cette section, nous présentons une comparaison récente des travaux dans le même domaine d'étude, où la comparaison portera sur le jeu de données, les méthodes utilisées ainsi que les résultats obtenus, avec nos spécificités.

	Étude	Année	Approche	Dataset	Accuracy%
0	notre travail	2024	ResNet	RescueNet + Massachusetts Buildings	93%
1	A.fujita et al [15]	2017	CNN	ABCD	96%
2	Christos et al [16]	2019	CNN	AIDER	91.9%
3	S. jones et al [17]	2019	SegNet	The Copernicus EMS	86.3%
4	K. Chaurasia et al [18]	2019	NN+RF	/	74.32%
5	C. kyrkou et al [19]	2020	EmergencyNet	AIDER	95.7
6	F. zhao et al [20]	2020	ResNet	xBD	80%
7	M. Rahneemoonfar et al [21]	2021	Xception	FloodNet	96.54%
8	G. abdi et al [22]	2021	ResNet	-	91%
9	L.wang et al [23]	2022	ResNet50	CrisisMMD et ASONAM17	91.56%
10	Zongze Zhao et al [24]	2024	ECADS-CNN	xBD	82.14%

Table 6 : Comparaisons

En comparant nos résultats avec d'autres travaux dans le même domaine, nous constatons que notre approche utilisant ResNet sur le jeu de données RescueNet + Massachusetts Buildings a obtenu une précision de 93%. Cela indique une performance exceptionnelle dans la classification des structures touchées et intactes.

Parmi les travaux précédents, les méthodes varient, allant des réseaux de neurones convolutifs (CNN) aux réseaux de neurones classiques (NN), en passant par des approches comme SegNet et Xception. Les précisions varient également, allant de 74,32% à 96,54%.

Nos résultats se distinguent par leur précision maximale, ce qui suggère une efficacité supérieure de notre approche par rapport aux autres méthodes présentées dans le tableau

3.11. Conclusion

Dans ce chapitre, nous avons exploré différentes méthodes de prétraitement des données et d'entraînement utilisées dans ce travail. Nous avons également fourni des informations cruciales sur les ensembles de données utilisés lors de cet entraînement et les prétraitements qui ont été appliqués. Nous avons également introduit ResNet. Ensuite, nous avons expliqué le concept d'une matrice de confusion et comment elle sera utilisée dans l'acquisition de nos résultats. Après cela, en décrivant l'environnement d'exécution utilisé pour les entraînements, nous avons ensuite détaillé les partitions des ensembles de données avant de présenter les résultats de l'entraînement. Nous avons examiné quatre différentes mesures d'évaluation ; ACC, TPR, TNR, cette dernière étant particulièrement utile pour évaluer les modèles entraînés sur des ensembles de données déséquilibrés. Notre modèle le plus performant était ResNet, avec une précision équilibrée de ACC=93%. Nous avons ensuite comparé ces résultats, ainsi que d'autres, à des travaux de pointe et observé que ResNet surpassait des travaux aussi récents que 2024, année de rédaction de cette thèse.

Conclusion générale

Dans cette étude, nous avons exploré en profondeur l'application des techniques d'inpainting pour évaluer les dommages causés par les catastrophes naturelles à travers la restauration d'images. Les catastrophes naturelles, qu'elles soient des séismes dévastateurs, des tempêtes dévastatrices, des inondations catastrophiques ou d'autres phénomènes, ont un impact dévastateur sur les régions touchées. L'utilisation de l'intelligence artificielle dans la prévision et l'évaluation des dommages causés par ces catastrophes revêt une importance capitale. En effet, les techniques d'intelligence artificielle, telles que l'apprentissage automatique et la vision par ordinateur, peuvent être utilisées pour analyser de vastes quantités de données, telles que des images satellites, des photographies aériennes ou des données recueillies sur le terrain, afin de détecter les signes précurseurs de catastrophes imminentes, de modéliser leur impact potentiel et de guider les interventions d'urgence.

Notre recherche s'inscrit dans ce contexte, en se concentrant spécifiquement sur l'utilisation des techniques d'inpainting pour restaurer les images endommagées par les catastrophes naturelles. Ces techniques, qui consistent à reconstruire les parties manquantes ou endommagées d'une image, sont essentielles pour évaluer l'ampleur des dommages et planifier les opérations de secours et de reconstruction.

Dans la première phase de notre étude, nous avons travaillé avec les ensembles de données RescueNet et Massachusetts Buildings Dataset, qui contiennent des images avant et après des catastrophes naturelles, telles que des séismes et des inondations. En utilisant ResNet, un réseau de neurones convolutif profond, nous avons entraîné des modèles pour reconstruire les images endommagées et estimer les dommages causés par ces catastrophes.

Dans la deuxième phase, nous avons étendu notre approche en appliquant des techniques d'inpainting sur les mêmes ensembles de données. Ces techniques nous ont permis de reconstruire les parties manquantes des images endommagées de manière plus précise et réaliste, ce qui a conduit à des évaluations plus précises des dommages causés par les catastrophes naturelles.

En particulier, nous avons constaté que la précision des modèles atteignait un niveau optimal de 93% dans certains cas, avec une marge d'erreur minime. Ces résultats témoignent de l'efficacité et de la robustesse des techniques d'inpainting dans l'évaluation des dommages causés par les catastrophes naturelles à travers la restauration d'images.

En conclusion, notre étude démontre l'efficacité des techniques d'inpainting dans l'évaluation des dommages causés par les catastrophes naturelles à travers la restauration d'images. En combinant l'intelligence artificielle avec des données spatiales et temporelles, nous pouvons obtenir une vision plus complète et précise des effets des catastrophes naturelles, ce qui peut aider les autorités et les organisations humanitaires à prendre des décisions plus éclairées et à intervenir plus efficacement lors de situations d'urgence.

Bibliographie

- [1] P. T.d.L, «le parisien,» Le 11 septembre 2017 à 18h07. [En ligne]. Available: <https://www.leparisien.fr/environnement/interactif-catastrophes-naturelles-la-carte-du-monde-de-la-menace-11-09-2017-7251885.php>.
- [2] «Yu, Tianxiu & Lin, Cong & Zhang, Shijie & You, Shaodi & Ding, Xiaohong & Wu, Jian & Zhang, Jiawan. (2019). End-to-End Partial Convolutions Neural Networks for Dunhuang Grottoes Wall-Painting Restoration. 10.1109/ICCVW.2019.00182.».
- [3] «Agarwal, Chandni & Bhatnagar, Charul. (2023). Unmasking the potential: evaluating image inpainting techniques for masked face reconstruction. Multimedia Tools and Applications. 83. 10.1007/s11042-023-15807-x.».
- [4] R. N. Keiron O'Shea, «An Introduction to Convolutional Neural Networks,» *ArXiv e-prints*, n° %1arXiv:1511.08458v2, 2015.
- [5] S. T. H. a. B. A. a. H. M. H. A. a. K. H. Kieu, «A Survey of Deep Learning for Lung Disease Detection on Medical Images: State-of-the-Art, Taxonomy, Issues and Future Directions,» *Journal of Imaging*, vol. 6, 2020.
- [6] B. Jason, «What is the Difference Between a Batch and an Epoch,» 2018.
- [7] K. S. a. A. Zisserman, «Very deep convolutional networks for large-scale image recognition,» chez *International Conference on Learning Representations (ICLR)*, San Diego, 2015.
- [8] «vgg16,» programmersought, [En ligne]. Available: <https://programmersought.com/article/12141264861/>. [Accès le 31 05 2022].
- [9] I. a. C. J. a. B. A. Constantin, «On the Use of Deep Active Semi-Supervised Learning for Fast Rendering in Global Illumination,» *Journal of Imaging*, vol. 6, 2020.

Bibliographie

- [10] K. He, X. Zhang, S. Ren et J. Sun, «Deep Residual Learning for Image Recognition,» chez *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 2016.
- [11] A. Rastogi, «ResNet50,» Medium, [En ligne]. Available: <https://blog.devgenius.io/resnet50-6b42934db431>. [Accès le 31 05 2022].
- [12] «ImageNet Large Scale Visual Recognition Competition 2012 (ILSVRC2012),» image-net.org, [En ligne]. Available: <https://image-net.org/challenges/LSVRC/2012/results.html>. [Accès le 04 06 2022].
- [13] L. Yang, S. Hanneke et J. Carbonell, «A theory of transfer learning with applications to active learning,» *Machine Learning*, p. 161–189, 2013.
- [14] G. Vrbancic et V. Podgorelec, «Transfer Learning With Adaptive Fine-Tuning,» *IEEE Access*, vol. 8, p. 196197–196211, (2020).
- [15] K. Zhao, Y. Zhou et X. Chen, «Object Detection: Training From Scratch,» *IEEE Access*, vol. 8, p. 157520–157529, 2020.
- [16] X. Ying, «An Overview of Overfitting and its Solutions,» *Journal of Physics: Conference Series*, n° 11168, 2019.
- [17] C. M. Bishop, *Neural Networks for Pattern Recognition*, 1995, p. 332.
- [18] C. Shorten et T. M. Khoshgoftaar, «A survey on Image Data Augmentation for Deep Learning,» *Journal of Big Data*, n° 1, 6(1), 60–. doi:10.1186/s40537-019-0197-0, 2019.
- [19] «Callbacks,» Keras, [En ligne]. Available: <https://keras.io/api/callbacks/>. [Accès le 14 05 2022].

Bibliographie

- [20] «A. Fujita, K. Sakurada, T. Imaizumi, R. Ito, S. Hikosaka and R. Nakamura, "Damage detection from aerial images via convolutional neural networks," 2017 Fifteenth IAPR International Conference on Machine Vision Applications (MVA), Nagoya, Japan, 2017».
- [21] «Christos Kyrkou, Theocharis Theocharides, "Deep-Learning-Based Aerial Image Classification for Emergency Response Applications Using Unmanned Aerial Vehicles».
- [22] «S. Jones and J. Saniie, "Using Deep Learning and Satellite Imagery to Assess the Damage to Civil Structures After Natural Disasters," 2019 IEEE International Conference on Electro Information Technology (EIT)».
- [23] «K. Chaurasia, S. Kanse, A. Yewale, V. K. Singh, B. Sharma and B. R. Dattu, "Predicting Damage to Buildings Caused by Earthquakes Using Machine Learning Techniques," 2019 IEEE 9th International Conference on Advanced Computing (IACC)».
- [24] «C. Kyrkou and T. Theocharides, "EmergencyNet: Efficient Aerial Image Classification for Drone-Based Emergency Monitoring Using Atrous Convolutional Feature Fusion," in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing».
- [25] «F. Zhao and C. Zhang, "Building Damage Evaluation from Satellite Imagery using Deep Learning," 2020 IEEE 21st International Conference on Information Reuse and Integration for Data Science (IRI)».
- [26] «M. Rahnemoonfar, T. Chowdhury, A. Sarkar, D. Varshney, M. Yari and R. R. Murphy, "FloodNet: A High Resolution Aerial Imagery Dataset for Post Flood Scene Understanding," in IEEE Access».
- [27] «G. Abdi, M. Esfandiari and S. Jabari, "Building Damage Detection in Post-Event High-Resolution Imagery Using Deep Transfer Learning," 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS, Brussels, Belgium, 2021».

Bibliographie

- [28] «L. Wang, R. Wu, C. Li and Z. Zou, "Recognition of Disaster Images Based on Self-Supervised Learning," 2022 7th International Conference on Cloud Computing and Big Data Analytics (ICCCBDA), Chengdu, China, 2022».
- [29] «Deep object segmentation and classification networks for building damage detection using the xBD dataset».
- [30] «Rahnemoonfar, M., Chowdhury, T. & Murphy, R. RescueNet: A High Resolution UAV Semantic Segmentation Dataset for Natural Disaster Damage Assessment. *Sci Data* 10, 913 (2023). <https://doi.org/10.1038/s41597-023-02799-4>».
- [31] «Massachusetts Buildings,» [En ligne]. Available: <https://eod-grss-ieee.com/dataset-detail/M1diYXBxdlViK0dubFgwdFFsS0ZWQT09>.
- [32] N. D. Jyotisma Chaki, *A Beginner's Guide to Image Preprocessing Techniques*, 2019.
- [33] P. N. M. T. P. A. J. E. Tomonobu Senjyu, «Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition,» chez *Proceedings of ICTIS 2020*, 2020.
- [34] U. M. J. M. L. M. G. J. S. Dan C. Cireşan, «Flexible, High Performance Convolutional,» chez *the Twenty-Second International Joint Conference on Artificial Intelligence*, IDSIA, USI and SUPSI Galleria 2, 6928 Manno-Lugano, Switzerland.
- [35] D. Powers, «Evaluation: From Precision, Recall and F-Factor to ROC, Informedness, Markedness & Correlation,» *Mach. Learn. Technol.*, vol. 2, 2008.
- [36] L. Ali, C. Zhu, N. A. Golilarz, A. Javeed, M. Zhou et Y. Liu, «Reliable Parkinson's Disease Detection by Analyzing Handwritten Drawings: Construction of an Unbiased Cascaded Learning System based on Feature Selection and Adaptive Boosting Model,» *IEEE Access*, pp. 1-1, 2019.

Bibliographie

- [37] A. Patel, «Chapter-7 Under-fitting, over-fitting and its solution,» Medium, [En ligne]. Available: <https://medium.com/ml-research-lab/under-fitting-over-fitting-and-its-solution-dc6191e34250>. [Accès le 31 05 2022].
- [38] IBM Cloud Education, «Overfitting,» IBM, [En ligne]. Available: <https://www.ibm.com/cloud/learn/overfitting>. [Accès le 31 05 2022].
- [39] R. A. E. (RAX), «Introducing Transfer Learning as Your Next Engine to Drive Future Innovations,» medium, [En ligne]. Available: <https://medium.datadriveninvestor.com/introducing-transfer-learning-as-your-next-engine-to-drive-future-innovations-5e81a15bb567>. [Accès le 04 06 2022].
- [40] «Comparison image neural networks,» wikimedia commons, [En ligne]. Available: https://commons.wikimedia.org/wiki/File:Comparison_image_neural_networks.svg. [Accès le 05 06 2022].