

**République Algérienne Démocratique et Populaire**  
**Ministère de l'Enseignement Supérieur et de la Recherche Scientifique**

**Université Saad Dahleb - Blida 1**



**Faculté des Sciences**  
**Département d'Informatique**

**Mémoire de fin d'études pour l'obtention**  
**Du diplôme de Master en informatique**

**Option : Ingénierie des logiciels**

**Thème**

---

**Classification des images satellitaires pour l'aide à la gestion des**  
**catastrophes naturelles en utilisant l'apprentissage profond**

---

**Réalisé par :**

Mr. BRAHIM Aimen

Mr. NEBIH Akram

**Devant le jury composé de :**

Melle TOUBALINE Nesrine      Présidente de jury

Mme ABED Hafida                  Promotrice

Mme CHEGUIRENE Soraya      Examinatrice

**Promotion : 2019/2020**



# Remerciements

Nous remercions ALLAH de nous avoir donné la santé et le courage afin de pouvoir compléter ce projet. Ce travail est l'aboutissement d'un long cheminement au cours duquel nous avons profité d'encadrement, des encouragements et du soutien de plusieurs personnes, à qui nous tenons à dire profondément et sincèrement merci.

Tout d'abord, Nous exprimons notre grande gratitude envers notre promotrice la professeur H. Abed pour avoir accepté de nous encadrer et proposé ce sujet, d'avoir été présente avec ses conseils, son aide apportée durant tout ce parcours et la patience dont elle a fait preuve. Son sens des responsabilités et sa rigueur professionnelle nous ont indiquées les pistes à suivre pour aller de l'avant.

A travers ces quelques mots, nous adressons nos remerciements les plus chaleureux à nos chers parents et familles pour le soutien et les encouragements qu'ils nous ont toujours apportés, ainsi qu'à tous nos amis qui ont contribué de près ou loin à notre réussite.

Nous remercions aussi les membres du jury de nous avoir fait l'honneur de juger et d'évaluer notre travail.

Nous tenons à remercier l'ensemble du corps enseignant. Nous garderons un très bon souvenir de vous, nous apprécions toujours vos qualités humaines, votre savoir-faire et vos compétences scientifiques.

# Dédicaces

Je dédie ce travail a :

## **Mes parents:**

Ma mère pour son soutien inconditionnel, ses conseils, son écoute, et son suivi permanent en répondant toujours présente. Son sourire m'a rendu l'espoir dans les moments où il m'arrivait de le perdre. J'entends toujours sa voix dans ma tête me poussant à me dépasser et à faire de mon mieux. Merci de m'avoir donné une excellente éducation qui me sert énormément et me servira toute ma vie.

Mon père pour ses sacrifices afin que je ne manque de rien, son acharnement à me transmettre sa patience, son sens des responsabilités et son éthique du travail. Je comprends maintenant les trésors que contient ta parole.

Mon petit frère Monssif pour sa générosité, ses encouragements et son enthousiasme. Puissent nos liens fraternels se consolider encore plus.

Cher famille merci pour toutes les valeurs nobles que vous m'avez enseigné, je ne saurai exprimer mon respect et ma gratitude envers vous.

## **IT Community :**

Le club scientifique universitaire ITC et tous ses membres. Ce club m'a guidé et m'a mis sur la bonne voie, celle de la détermination, l'ambition et l'entraide. Il m'a donné l'opportunité d'élargir mes connaissances et mes compétences dans plusieurs domaines que je connaissais finalement que très peu mais pour lesquels j'ai immense intérêt, j'espère que cet intérêt soit transmis aux futurs membres et qu'il impactera leurs vie comme il a impacté la mienne.

Chers membres de ma deuxième famille, merci de m'avoir inspiré et m'avoir encouragé durant mes 5 ans universitaires, ce club restera à jamais gravé dans mon cœur.

## **Mes amis :**

Mon ami Kerbouche Mahfoudh qui m'a été d'une aide précieuse grâce à ses remarques constructives et ses conseils.

Mousserati Fatma, OuldSetti Hiba, Haroun Meriem, Boudali Souheib et Zoubir Chouaib envers qui j'ai une profonde reconnaissance pour leur inestimable appui et assistance.

Mes amis Karim, Chakib, Mehdi, Mehdi, Zakaria et Fares, pour qui j'ai énormément d'affection, et qui partagent avec moi les meilleurs souvenirs de ma vie.

Mes amis je vous dédie ce travail et je vous souhaite une vie pleine de santé et de bonheur.

Je tiens également à adresser mes remerciements les plus sincères aux enseignants, étudiants et toute personne ayant apporté son aide de près ou de loin à l'élaboration de ce mémoire.

**BRAHIM Aimen**

# Dédicaces

A mes chers parents, pour tous leurs sacrifices, leur amour, leur soutien et leurs prières tout au long de mes études,

A ma chère sœur *Nesma* et mon frère *Zakaria* pour leurs encouragements permanents, et leur soutien moral,

A toute ma famille pour leur soutien tout au long de mon parcours universitaire,

A tous mes amis qui m'ont accompagné dans cette longue aventure en quête du savoir et d'un avenir meilleur,

Aux clubs universitaires scientifiques « ITC », « CSCC » et « CDEC » pour leurs esprits de partage,

Ainsi qu'à toute personne qui m'a aidé à atteindre mes objectifs,

Que ce travail soit l'accomplissement de vos vœux tant allégués, et le fruit de votre soutien infailible,

Merci d'être toujours là pour moi.

NEBIH Akram

De nos jours, les Catastrophes naturelles représentent l'une des plus grandes menaces terrestre, les pertes humaines et déficits matériels engendrés par ces phénomènes sont innombrables. La gestion de ces évènements est un problème majeur ici en Algérie et pour le reste du monde. La difficulté réside surtout dans le manque de données relatives aux conséquences de ces manifestations naturelles, ainsi que l'analyse et l'exploitation de ces dernières d'une manière optimale.

Les images fournies par les satellites d'observation terrestre sont de plus en plus utilisées pour obtenir des informations dans plusieurs domaines, cependant leurs utilisations dans la gestion des catastrophes naturelles restent très limitées.

Ainsi devant la vivacité du problème et l'importance de son enjeu, le travail qui nous a été proposé consiste à concevoir et implémenter un système de classification et segmentation des images satellitaires de manière automatique. Il est basé sur deux solutions pour la détection des zones endommagées et la gravité d'endommagement des constructions. Le système utilise des algorithmes d'apprentissage profond pour une classification et segmentation supervisée afin d'analyser et repérer les caractéristiques visuelles extraites à partir des images satellitaires.

**Mots Clés :** Catastrophes naturelles, Images satellitaires, Apprentissage profond, Classification images satellitaires, Gestion des situations d'urgence.

---

## Abstract

---

Nowadays, natural disasters represent one of the greatest threats on earth, the human losses and material deficits caused by these phenomena are innumerable. The management of these events is a major problem here in Algeria and for the rest of the world, this difficulty is caused by several complications among them the lack of data (information for management) related to the consequences of these natural manifestations, as well as the analysis and exploitation of these in an optimal way.

The images provided by Earth observation satellites are increasingly used to obtain information in several fields, however their uses in the management of natural disasters remain very limited.

The work that has been proposed to us consists of designing and implementing a system of classification and segmentation of satellite images automatically. It is based on two solutions for the detection of damaged areas and the severity of damage to buildings. The systems use deep learning algorithms for supervised classification and segmentation to analyze and locate visual features extracted from satellite images.

**Key words:** Natural disasters, Satellite images, Deep learning, Classification of satellite images, Management of emergency situations.

## ملخص

تشكل الكوارث الطبيعية هذه الأيام تهديدا كبيرا للحياة على الأرض، فالخسائر البشرية والعجز المادي الذي تسببه هذه الظواهر لا يعد ولا يحصى. بالإضافة إلى ذلك يشكل التحكم في الكوارث الناجمة عن هذه الظواهر مشكلة عويصة في الجزائر وباقي دول العالم، وتتمثل الصعوبة في عدة تعقيدات من بينها نقص المعطيات المرتبطة بنتائج الكوارث الطبيعية وكذا تحليلها واستغلالها بأفضل طريقة ممكنة.

الصور المقدمة من طرف الأقمار الصناعية المسؤولة عن مراقبة الأرض صارت أكثر استعمالا للحصول على العديد من المعلومات في مختلف الميادين، في حين بقي استعمالها في تسيير الظواهر الطبيعية محدودا جدا.

يتمثل العمل الذي تم اقتراحه علينا في تصميم وتنفيذ نظام لتصنيف صور الأقمار الصناعية وكذا تحديد مواقع البناءات بها. هذا النظام مركب من قسمين لتحديد المناطق المتضررة وشدة الضرر في بناياتها. النظام يستعمل خوارزميات التعلم العميق للتصنيف والتقسيم الموجه بهدف تحليل وتحديد السمات المرئية المستخرجة من صور الأقمار الصناعية.

**الكلمات المفتاحية:** الكوارث الطبيعية، صور الأقمار الصناعية، التعلم العميق، تصنيف صور الأقمار الصناعية، إدارة حالات الطوارئ.

<b>Introduction générale.....</b>	<b>18</b>
<b>PARTIE 01 : Recherche bibliographique.....</b>	<b>20</b>
<b>CHAPITRE 1 : Satellite et images satellitaires .....</b>	<b>21</b>
1. Définition Satellite .....	22
2. Télédétection .....	23
2.1. Définition Télédétection .....	23
2.2. Composants du processus de Télédétection.....	24
2.3. Le spectre électromagnétique.....	24
2.4. Résolution des senseurs à distance .....	25
2.4.1. Résolution spatiale.....	25
2.4.2. Résolution Spectral.....	26
2.4.3. Résolution radiométrique .....	27
2.4.4. Résolution temporelle.....	27
3. Types d'images de la Télédétection .....	27
3.1. Géo-référencement.....	27
3.2. Projection cartographique .....	28
3.3. Image de base.....	28
3.4. Images Standard.....	28
3.5. Couples stéréoscopiques .....	28
3.6. Image multi spectrale (MS) .....	28
3.7. Images hyper spectrales .....	29
3.8. Image panchromatique (PAN) .....	29
3.9. Image fusionnée (PS).....	29
3.10. L'image stéréo .....	29
4. Type des Satellites.....	29
4.1. Satellite de Télécommunication.....	29
4.2. Satellites d'observation terrestre.....	29
4.3. Satellites météorologiques .....	33
4.4. Les satellites radars .....	34
4.5. Satellites commerciaux à haute résolution optique.....	35
5. Classification des images satellitaires .....	36

6. Conclusion.....	37
<b>Chapitre 02 : les catastrophes naturelles .....</b>	<b>38</b>
1. Quelques notions sur les catastrophes .....	39
2. Les Dégâts causés par les catastrophes naturelles.....	39
2.1. Les éruptions volcaniques.....	40
2.2. Séisme .....	40
2.3. Les glissements de terrain.....	40
2.4. Les inondations .....	40
2.5. Cyclones.....	41
2.6. Les incendies de forêt .....	41
3. Les besoins pour gérer la crise .....	41
4. Evaluation des dégâts .....	41
5. Conclusion.....	42
<b>Chapitre 3 : Les techniques de l'apprentissage profond.....</b>	<b>43</b>
1. Qu'est-ce que l'apprentissage automatique.....	44
1.1. Types d'apprentissage .....	45
1.1.1. Apprentissage supervisé .....	45
1.1.2. Apprentissage non-supervisé.....	45
2. Apprentissage profond .....	46
2.1. Réseau de neurones artificiels.....	46
2.1.1. La propagation vers l'avant .....	47
2.1.2. Pré-activation.....	47
2.1.3. La retro propagation .....	47
2.1.4. Le taux d'apprentissage .....	48
2.1.5. Fonction d'activation.....	48
2.1.6. Type des fonctions d'activation.....	49
2.1.7. La fonction de perte .....	51
2.1.8. Les fonctions d'optimisation .....	52
2.1.9. Sous et sur apprentissage .....	53
2.2. Réseaux de neurones convolutif (CNN) .....	57
2.2.1. Filtre.....	57
2.2.2. Stride.....	58
2.2.3. Les couches des CNNs .....	58
2.2.4. Qu'est-ce qu'une Architecture d'un réseau neuronal convolutif.....	60

3.	Apprentissage par transfert.....	62
4.	Revue sur quelques travaux connexes.....	64
a)	Détection et classification automatique de bâtiments endommagés à l'aide d'une imagerie satellite haute en utilisant un réseau neuronal artificiel .....	64
b)	Détection de dommages aux bâtiments en imagerie satellite à l'aide de réseaux de neurones convolutifs .....	65
c)	Quantification de dégâts sur les structures liés aux catastrophes majeures par images satellite multimodales très haute résolution.....	65
d)	Contribution des Données Optiques au Traitement Multi-sources des Désastres Naturels .....	65
5.	Conclusion.....	65
<b>PARTIE 02 : Contribution.....</b>		<b>67</b>
<b>Chapitre 4 : Conception.....</b>		<b>68</b>
1.	Démarche de conception .....	69
2.	CRISP-DM.....	69
2.1.	Compréhension du problème .....	70
2.2.	Solution proposée.....	70
2.3.	Compréhension des données.....	71
2.4.	Préparation des données.....	74
2.4.1.	Nettoyage des données .....	74
2.4.2.	Traitement des données .....	75
2.5.	Entraînement des modèles .....	77
2.5.1.	Modèles utilisés dans la solution par zone .....	78
2.5.2.	Modèles utilisés dans la solution par structure.....	78
2.6.	Évaluation du modèle .....	79
2.7.	Exportation du modèle.....	79
3.	Conclusion.....	79
<b>Chapitre 5 : Implémentation et Tests.....</b>		<b>80</b>
1.	Matériels et outils .....	81
1.1.	Matériels utilisés .....	81
1.2.	Outils de développement.....	81
2.	Implémentation du système.....	84
2.1.	Préparation des données.....	84
2.1.1.	Traitement des données « IEEE DataPort » .....	84
2.1.2.	Traitement des données « xview2 » .....	85

2.1.3.	Redimensionnement des données .....	90
2.1.4.	Augmentation des données .....	90
2.2.	Modélisation des réseaux de neurones .....	91
2.3.	Déploiement du système .....	92
3.	Résultats et tests .....	99
3.1.	Test de robustesse des modèles.....	99
3.2.	Tests d'évaluation .....	105
4.	Conclusion.....	108
<b>Conclusion générale et perspectives .....</b>		<b>110</b>
<b>Références bibliographiques .....</b>		<b>112</b>

---

## Table des figures

---

<b>Figure 1.1</b> : figure qui explique le system de télédétection .....	24
<b>Figure 1.2</b> : Format d'une image digitale (7x9 pixels). Chaque pixel représente une zone de la surface terrestre .....	25
<b>Figure 1.3</b> : Des images qui expriment une différente résolution spatiale: 2 m/pixel (à gauche) face à 0,5 m/pixel (à droite). Source: SATELMAC .....	26
<b>Figure 1.4</b> : Bandes spectrales de différents senseurs pour la Télédétection .....	27
<b>Figure 1.5</b> : Image ERS 2 SAR d'un scénario en mer du Groenland .....	30
<b>Figure 1.6</b> : L'image ASAR couvre la Péninsule Antarctique .....	31
<b>Figure 1.7</b> : Capture d'un immense banc de phytoplancton le long des côtes mauritaniennes par MERIS.....	32
<b>Figure 1.8</b> : Principe de classification .....	36
<b>Figure 1.9</b> : Représentation des méthodes de classification.....	36
<b>Figure 3.1</b> : Schéma explicatif du domaine de l'IA .....	44
<b>Figure 3.2</b> : Représentation d'un Réseau de neurone artificiel.....	46
<b>Figure 3.3</b> : Le processus de la rétro propagation .....	48
<b>Figure 3.4</b> : Les différents cas du taux d'apprentissage .....	48
<b>Figure 3.5</b> : Quelques fonctions d'activations .....	49
<b>Figure 3.6</b> : La représentation graphique de sigmoïde .....	49
<b>Figure 3.7</b> : La représentation graphique de tanh .....	50
<b>Figure 3.8</b> : La représentation graphique de la fonction ReLu .....	51
<b>Figure 3.9</b> : La représentation de la fonction de perte.....	52
<b>Figure 3.10</b> : Compromis Biais-Variance .....	54
<b>Figure 3.11</b> : la relation entre la variance et sur apprentissage, le biais et le sous-apprentissage .....	54
<b>Figure 3.12</b> : représentation d'un réseau de neurone avec la méthode dropout .....	56
<b>Figure 3.13</b> : le point optimal pour arrêter le processus d'entrainement .....	57
<b>Figure 3.14</b> : Stride de 2 Pixels .....	58
<b>Figure 3.15</b> : Application de plusieurs filtres sur une image d'entrée .....	59
<b>Figure 3.16</b> : Utilisation de Zero Padding avant une convolution .....	59
<b>Figure 3.17</b> : Couche entièrement connectée .....	60
<b>Figure 3.18</b> : Schéma du réseau neuronal convolutif architecture AlexNet .....	61
<b>Figure 3.19</b> : Apprentissage isolé et apprentissage par transfert .....	63
<b>Figure 5.1</b> : schéma représentant la méthode CRISP-DM .....	69
<b>Figure 5.2</b> : schéma représentant la base de données utilisée .....	72
<b>Figure 5.3</b> : deux images satellitaires représentant post et pré catastrophe prise de la base de données xvview2.....	73
<b>Figure 5.4</b> : illustration montrant les lieux d'où les données de xvview2 sont prises .....	73
<b>Figure 5.5</b> : les annotations des données .....	74
<b>Figure 5.6</b> : Processus de traitement des données pour la localisation .....	76
<b>Figure 5.7</b> : Processus de traitement des données pour la classification.....	77
<b>Figure 5.8</b> : illustration qui représente la segmentation sémantique en utilisant Unet.....	78
<b>Figure 6.1</b> : Logo Python .....	82
<b>Figure 6.2</b> : Logo Anaconda.....	82
<b>Figure 6.3</b> : Logo OpenCV.....	82

<b>Figure 6.4</b> : Logo Tensorflow .....	82
<b>Figure 6.5</b> : Logo Keras .....	83
<b>Figure 6.6</b> : Logo Numpy.....	83
<b>Figure 6.7</b> : Logo Scikit-Learn.....	83
<b>Figure 6.8</b> : Logo Google Drive .....	83
<b>Figure 6.9</b> : Logo Colaboratory.....	84
<b>Figure 6.11</b> : Logo Qt.....	84
<b>Figure 6.12</b> : schéma représentant la fragmentation de la base de données.....	85
<b>Figure 6.13</b> : représentant les différents dossiers et leur contenu.....	85
<b>Figure 6.14</b> : schéma de la première étape de fractionnement des données.....	86
<b>Figure 6.15</b> : schéma de l'étape finale de fractionnement des données .....	87
<b>Figure 6.16</b> : illustration qui représente une image et son masque. ....	88
<b>Figure 6.17</b> : schéma qui représente la première étape dans la fragmentation des images post catastrophe pour la classification .....	89
<b>Figure 6.18</b> : schéma qui représente l'étape final dans la fragmentation des images post catastrophe pour la classification .....	90
<b>Figure 6.19</b> : Interface graphique du menu d'entrée.....	93
<b>Figure 6.20</b> : Interface graphique principale de la solution d'analyse par zone .....	94
<b>Figure 6.21</b> : Interface graphique qui aborde le résultat final de la solution d'analyse.....	95
<b>Figure 6.22</b> : Interface graphique principale de la solution d'analyse par structure.....	96
<b>Figure 6.23</b> : Image qui illustre la phase d'importation d'image .....	97
<b>Figure 6.24</b> : Figure qui représente l'image satellitaire qu'on va l'utiliser comme entrée dans le système .....	97
<b>Figure 6.25</b> : Interface graphique qui représente le résultat final du système.....	99
<b>Figure 6.26</b> : graphe représentant la valeur de précision lors de l'entraînement et validation du modèle VGG16 .....	100
<b>Figure 6.27</b> : graphe représentant la valeur de perte lors de l'entraînement et validation du modèle de VGG16.....	100
<b>Figure 6.28</b> : graphe représentant la valeur de précision lors de l'entraînement et validation du modèle Resnet50 .....	101
<b>Figure 6.29</b> : graphe représentant la valeur de perte lors de l'entraînement et validation du modèle de Resnet50 .....	101
<b>Figure 6.30</b> : graphe représentant la valeur de précision lors de l'entraînement et validation du modèle d'Unet .....	102
<b>Figure 6.31</b> : graphe représentant la valeur de perte lors de l'entraînement et validation du modèle d'Unet .....	103
<b>Figure 6.32</b> : graphe représentant la valeur de précision lors de l'entraînement et validation du modèle de classification par structures Resnet50.....	104
<b>Figure 6.33</b> : graphe représentant la valeur de perte lors de l'entraînement et validation du modèle de classification par structures Resnet50.....	104
<b>Figure 6.34</b> : Matrice de confusion VGG16.....	106
<b>Figure 6.35</b> : Matrice de confusion Resnet50 .....	107
<b>Figure 6.36</b> : Matrice de confusion modèle Resnet50 pour la solution par structures.....	108

---

## Liste des Tableaux

---

<b>Tableau 1 :</b> Premier satellite mis en orbite par un lanceur national.....	22
<b>Tableau 2 :</b> La relation entre le sur apprentissage, Sous apprentissage et le bon apprentissage par rapport aux taux d'erreurs de l'entrainement et test.....	55
<b>Tableau 3 :</b> Matrice de confusion.....	106

---

## Liste des abréviations

---

- **AATSR** : Advanced Along Track Scanning Radiometer.
- **ADAM** : Adaptive Moment Estimation.
- **ANN** : Artificial neural network.
- **APT** : Automatic Picture Transmission.
- **ASAR** : Advanced Synthetic Aperture Radar.
- **AVHRR** : Advanced Very High Resolution Radiometer.
- **CCL** : conforme conique de Lambert.
- **CIS** : classification image satellitaire.
- **CNN** : Convolutional Neural Network.
- **CPU** : Central Processing Unit.
- **DMC** : Disaster Monitoring Constellation.
- **EM** : Espérance-Maximisation.
- **ERS** : European Remote Sensing Satellites.
- **ESA** : European Space Agency.
- **FN** : False Negative.
- **FP** : False Positive.
- **GPU** : Graphics Processing Unit.
- **GUI** : graphical user interface.
- **HRPT** : High Resolution Picture Transmission.
- **HS** : Harmony Search.
- **IA** : intelligence artificielle.
- **IHM** : Interface homme machine.
- **MIPAS** : Michelson Interferometer for Passive Atmospheric Sounding.
- **MNT** : modèles numériques de terrain.
- **MS** : Multi spectrale.
- **MSG** : Meteosat Second Generation.
- **MTU** : Mercator transverse universelle.
- **NOAA** : National Oceanic and Atmospheric Administration.
- **OpenCV** : Open Source Computer Vision Library.
- **PAN** : panchromatique.
- **PS** : pan-sharpened.
- **ReLU** : rectified linear unit.
- **ResNet** : Residual Network.
- **RMSProp** : Root Mean Square Propagation.
- **RNA** : Réseau de neurone artificiel.
- **RSO** : radar à synthèse d'ouverture.
- **SAR** : Synthetic Aperture Radar.
- **SCIAMACHY** : Scanning Imaging Absorption Spectrometer for Atmospheric Chartography

- **SIG** : Système d'information géographique
- **SPOT** : Screening of Passengers by Observation Techniques.
- **Tanh** : Tangente hyperbolique.
- **TN** : True Negative.
- **TP** : True Positive.
- **VHF** : Very high frequency.



# Introduction générale

## Contexte du travail

Une catastrophe naturelle est un événement soudain, qui peut provoquer la mort et la destruction des structures à grande échelle. Ces dernières années, le nombre de catastrophes naturelles dans le monde semble augmenter [1]. En 2018, le nombre de *catastrophes naturelles* dans le monde a augmenté de 13%. Il passe de 740 événements en 2017 à 850 une année plus tard. Avec 10 400 décès, le bilan humain reste lourd malgré une baisse de 20% [2], cette baisse peut s'expliquer probablement en raison de l'amélioration du niveau de vie et d'une meilleure gestion des risques de catastrophe. Le progrès de la gestion de ces phénomènes est sûrement dû aux informations post catastrophe collectées grâce à plusieurs technologies parmi lesquelles on trouve les images satellitaires.

Les images satellitaires sont des données collectées à partir des satellites d'observation mise en orbite autour de la terre qui fournissent de plus en plus des images à hautes résolutions spatiales et spectrales adéquates pour un paysage rural ou périurbain. Ces satellites peuvent couvrir la surface entière de la terre en moins de 24h. Une exploitation de telles données est possible grâce aux techniques d'apprentissage profond.

Ce type d'apprentissage permet de fournir des machines intelligentes qui traitent d'une manière automatique des données pour l'aide à la prise de décisions.

## Problématique

En Algérie, en 2018, on a estimé à 25 milliards de dinars, soit l'équivalent de 211 millions de dollars de perte causées par les catastrophes naturelles. A cela s'ajoutent les pertes en vie humaine et les conséquences sur la santé physique et morale des personnes. En Algérie, ces déficits sont principalement causés par des séismes et inondations

Devant la vivacité du problème, la gestion des dégâts engendrés par les catastrophes naturelles est une priorité. Cependant les systèmes destinés à répondre à ce genre de problèmes se font très rares. De plus, l'utilisation des technologies telles que les images satellitaires pour ce but précis se fait d'une manière non automatique. Pour la détection des zones et structures endommagées se fait toujours en se basant sur l'intervention humaine et cela malgré l'existence de nouvelles techniques qui permettent de réaliser des systèmes d'analyse automatique des lieux touchés par les catastrophes naturelles.

Dans ce travail, nous allons tenter de proposer un système de détection des zones et structures (bâtiments) endommagées par les catastrophes naturelles pour l'aide à la gestion de ces phénomènes. Notre système est basé sur la classification d'images et la localisation des formes pour l'extraction des caractéristiques visuelles et l'obtention d'une prédiction propre aux données d'entrées.

**Objectifs :**

- Lecture des images aériennes et satellitaires
- Exploitation des avantages de l'apprentissage profond pour permettre l'identification des changements dans les scènes observées.
- Conception d'un système qui permettra d'aider dans la prise de décision et la gestion de la situation post crise.

**Organisation du mémoire**

Pour mener à bien notre travail, nous avons organisé notre manuscrit comme suit :

Chapitre 1 : Satellites et Images Satellitaires

Chapitre 2 : Les Catastrophes naturelles

Chapitre 3 : L'apprentissage Profond

Chapitre 4 : Travaux connexes

Chapitre 5 : Conception

Chapitre 6 : Implémentations et Tests

Ce mémoire sera finalisé par une conclusion générale reprenant les principaux points abordés, et en exposant certaines perspectives d'amélioration de notre travail.

---

# **Partie 01**

## **Recherche bibliographique**

---

---

# **CHAPITRE 1**

## **Satellite et images satellites**

---

La majorité des satellites sont utilisés pour l'observation terrestre et non pour l'exploration spatiale, ils ont pour but de répondre aux besoins des habitants de notre planète. Ces engins servent le plus souvent à gérer les ressources naturelles et faciliter l'intervention des secours en cas de crise. Ils sont couramment utilisés pour recueillir des données qui permettent de prendre des décisions, mais aussi à transmettre des informations [3].

## 1. Définition Satellite

A la citation du mot satellite une image se forme dans notre esprit d'un engin ou d'une machine qui tourne au tour de la terre.

Cette notion représente un satellite artificiel qui est lui-même inspiré d'un corps céleste qui gravite autour d'un astre de masse plus importante appelé satellite naturelle, Par exemple, la lune est le satellite naturel de la Terre, qui est elle-même l'un des satellites naturels du soleil.

Un satellite artificiel est un engin construit par l'homme et placé en orbite autour d'un astre, en particulier la Terre, à l'aide d'une fusée ou un système de transport spatial. Apparus pour des motifs politiques, de nos jours les satellites artificiels sont devenus des outils nécessaires pour la science, la défense, les télécommunications et pour des applications telles que la prévision du temps, la lutte contre la pollution ou les sauvetages. Le tableau suivant représente chronologiquement la mise en orbite des premiers satellites [4].

<b>Pays</b>	<b>Année du lancement</b>	<b>Premier satellite (signification du nom)</b>
<u>Union soviétique</u>	1957	<i>Sputnik 1</i> (compagnon)
<u>États-Unis</u>	1958	<i>Explorer 1</i> (explorateur)
<u>France</u>	1965	<i>Astérix</i> (personnage de bande dessinée)
<u>Japon</u>	1970	<i>Ōsumi</i> (nom d'une province japonaise)
<u>Chine</u>	1970	<i>Dong Fang Hong 1</i> (Orient rouge)
<u>Royaume-Uni</u>	1971	<i>Prospero X-3</i> (personnage de Shakespeare)
<u>Inde</u>	1980	<i>Rohini</i> (personnage de la mythologie hindoue)
<u>Ukraine</u>	1992	<i>Strela</i> (flèche)
<u>Iran</u>	2009	<i>Omid 1</i> (espoir)
<u>Corée du Nord</u>	2012	<i>Kwangmyŏngsŏng 3 numéro 2</i>
<u>Corée du Sud</u>	2013	<i>STSAT-2C</i>

Tableau 1 : Premier satellite mis en orbite par un lanceur national.

## **Notions générales sur les orbites**

Les formes et orientations des orbites des satellites terrestres sont nombreuses:

Certaines sont en forme d'ellipse très allongée ou au contraire circulaires. Elles peuvent se situer à basse altitude juste au-dessus de l'atmosphère terrestre (250 km) ou dépasser 30 000 km. L'orbite d'un satellite artificiel est choisie pour répondre aux besoins de la mission [4].

## **2. Télédétection**

La télédétection spatiale ('Remote Sensing') est une science qui introduit un large éventail des compétences et des méthodes utilisées pour l'observation, l'analyse et l'interprétation des phénomènes atmosphériques et terrestres. Ses principales sources sont les mesures et les images obtenues à l'aide des plates-formes spatiales.

Comme son nom l'indique, la télédétection est l'acquisition de l'information à distance, sans contact direct avec l'objet étudié. L'acquisition d'information à distance implique l'existence d'un flux d'informations entre l'objet observé et le capteur [5].

Le porteur de cette information est un rayonnement électromagnétique, qui peut être émise par l'objet ou venir d'un autre organisme et avoir été réfléchi par celui-ci. Tous les corps (planètes, êtres vivants, objets inanimés) émettent un rayonnement électromagnétique, la quantité et le type de rayonnement émis.

Ainsi, il existe des systèmes de satellites opérationnels pour échantillonner pratiquement toutes les régions du spectre électromagnétique, avec une résolution spatiale de 0,5 à 5,000 m. Le grand intérêt de la communauté scientifique dans les études spatio-temporelles du changement global, surveillances environnementales et des impacts humains sur elle, implique nécessairement l'utilisation de données de télédétection [5].

Les systèmes de télédétection, offrent une vision répétitive et synoptique de la Terre de grande valeur dans le suivi et l'analyse de l'effet des activités humaines tel que l'estimation et la surveillance de l'environnement (croissance urbaine), l'exploration et la surveillance des changements globaux (appauvrissement de l'ozone atmosphérique, déforestation, réchauffement climatique), l'exploration des ressources non renouvelables (minéraux, pétrole, gaz naturel) et les ressources naturelles renouvelables (océans, forêts, terres), la météorologie (prévision météorologique, les processus dynamiques atmosphériques), la cartographie (topographie, utilisation des terres, génie civil),etc [5].

### **2.1.Définition Télédétection**

La télédétection est un outil indispensable pour acquérir des images de satellites d'observation Terrestre, convenant pour les multiples applications souhaitées.

Elle est aussi une technique aérospatiale qui utilise l'énergie électromagnétique pour obtenir de l'information de la surface de la Terre et de l'atmosphère environnante sans contact direct.

Elle permet d'élargir la connaissance de notre environnement et faciliter l'interprétation des multiples processus qui affectent notre planète [5].

## 2.2. Composants du processus de Télédétection

Les éléments qui composent le system habituel de Télédétection sont présentés dans la figure 1.1. La première exigence présume d'avoir une source d'énergie qui nourrisse l'objet d'intérêt (champ cultivé, forêt, mer, ville, etc.). Le plus courant est que cette source d'énergie soit le soleil lui-même (A). Le rayonnement solaire, sur son chemin vers la Terre, traverse et coopère avec l'atmosphère (B). Après avoir atteint la surface de la Terre, coopère avec les objets contenus dans celle-là. Le rayonnement réfléchi est en fonction des caractéristiques des objets, ce qui permet de les distinguer (C). Un senseur à bord d'un satellite recueille et enregistre le rayonnement réfléchi par la surface et l'atmosphère elle-même (D) [6].

L'énergie captée par le senseur est transmise à une station de réception et de traitement dans lequel les données fournies sont converties en images digitales (E). L'image traitée est visuelle et numériquement interprétée afin d'en sortir des informations sur les objets qui ont été illuminés (F). La dernière étape du processus de la Télédétection consiste à assimiler et à appliquer l'information extraite de l'image et la caractérisation des procédures d'évaluation de la zone d'étude, afin d'accroître les connaissances sur les mêmes et à supporter une meilleure planification et administration (G) [6].

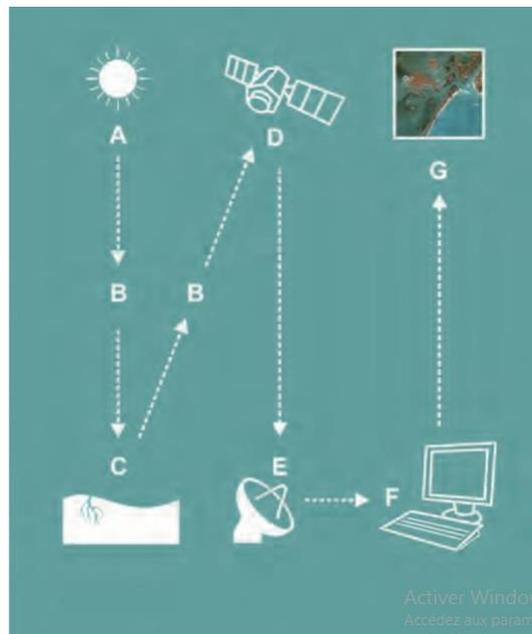


Figure 1.1 figure qui explique le system de télédétection [6]

## 2.3. Le spectre électromagnétique

Les yeux de l'homme peuvent être vus comme senseurs à distance qui permettent de détecter la lumière réfléchi par les objets qui les entourent. Cependant, l'œil humain ne peut traiter qu'une petite partie du spectre électromagnétique, le «visible».

La lumière visible n'est qu'une des nombreuses formes existantes du rayonnement électromagnétique ; les ondes radio, la chaleur, les rayons ultraviolets et les rayons X sont d'autres façons tout à fait communes. Dans la télédétection, il est courant de caractériser les ondes électromagnétiques par leur longueur d'onde en micromètres ( $\mu\text{m}$ ,  $10^{-6}$  m) ou

nanomètres (nm,  $10^{-9}$  m), en fonction de la position qu'elles occupent dans le spectre électromagnétique.

Les senseurs pour la Télédétection à bord des satellites sont capables de détecter et d'enregistrer des rayonnements non visibles du spectre électromagnétique, dès l'ultraviolet aux micro-ondes [6].

## 2.4. Résolution des senseurs à distance

Les senseurs installés dans les satellites pour la télédétection ont plusieurs particularités qui déterminent les caractéristiques des images qui résulteront de ce processus. Ces caractéristiques sont définies essentiellement par les différents types de résolution [6]:

### 2.4.1. Résolution spatiale

La résolution spatiale est une mesure de distance plus petite, linéaire ou angulaire qu'un senseur à distance peut capturer de la surface de la Terre et se représente par un pixel. Un pixel est l'unité minimale qui forme une image numérique.

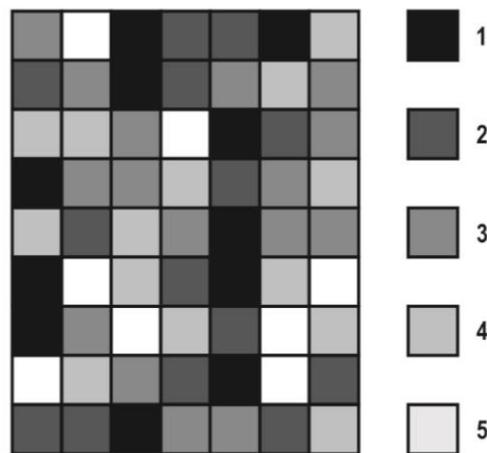


Figure 1.2: Format d'une image digitale (7x9 pixels). Chaque pixel représente une zone de la surface terrestre [6]

Il y a de nombreux facteurs qui déterminent la résolution spatiale d'un senseur à distance (distance senseur-surface de la surface, l'angle et champ de vision instantané). Dans le cas des senseurs à bord des satellites, ces facteurs sont quasiment fixes, ainsi la résolution spatiale peut être considérée comme constante, lorsque l'angle de vision n'est pas large. Par exemple, la résolution spatiale du senseur du satellite GEOEYE-1 est de 1,64 m de vision verticale mais à  $28^\circ$  augmente de 2 m, en d'autres termes 22% de moins.

Plus la résolution spatiale agrandit, c'est à dire la plus petite surface représentée par un seul pixel, plus petites sont les objets qui peuvent être distingués dans la zone d'étude. Par exemple, une image avec une résolution de 0,5 m/pixel permettra de distinguer des objets plus petits qu'une image de 2 m/pixel.

Pour qu'un objet homogène puisse être détecté, sa taille doit être généralement égale ou supérieure à la surface du terrain qui représente un pixel. Si l'objet est plus petit, il peut arriver qu'il ne soit pas détecté et le senseur va enregistrer une valeur correspondant à la moyenne de

tout ce qui existe dans la zone correspondant au pixel respectif. Toutefois, dans certains cas, de petits objets sont détectés par leurs réflectances qui sont dominante dans la surface du pixel [6].



Figure 1.3: Des images qui expriment une différente résolution spatiale: 2 m/pixel (à gauche) face à 0,5 m/pixel (à droite). Source: SATELMAC [6].

#### **2.4.2. Résolution Spectral**

En règle générale, dans les dispositifs de Télédétection, l'enregistrement du rayonnement se fait en prenant comme référence un intervalle de longueurs d'onde du spectre électromagnétique (Figure 13). Par exemple, un senseur sensible aux longueurs d'onde comprises entre 0,4 et 0,5  $\mu\text{m}$  pourra détecter la lumière bleue. Cet intervalle est appelé «bande spectrale» ou «canal des données» d'une image.

Résolution spectrale d'un senseur signifie le numéro et la largeur des bandes spectrales qui peuvent être discriminés.

Un agrandissement de la résolution spectrale donne comme résultat un plus grand numéro de canaux ou bandes spectrales. Cependant, cette résolution additionnelle implique également des coûts supplémentaires en termes de volume de données et de traitement accrue [6].

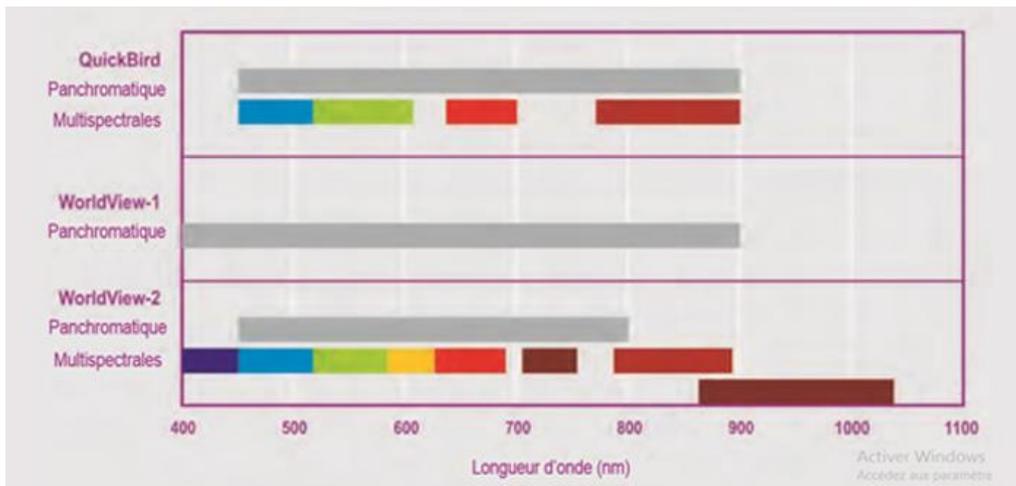


Figure 1.4: Bandes spectrales de différents senseurs pour la Télédétection [6].

### 2.4.3. Résolution radiométrique

La résolution radiométrique peut être définie comme la quantité minimale d'énergie nécessaire pour augmenter la valeur d'un pixel à un niveau numérique [6].

### 2.4.4. Résolution temporelle

La résolution temporelle est le cycle de répétition, à savoir l'intervalle de temps qui s'écoule entre deux acquisitions successives de la même partie d'image de la surface terrestre par le même senseur. Cette fonction dépend principalement des caractéristiques orbitales du satellite, souvent appelé «période de revisitations» [6].

## 3. Types d'images de la Télédétection

Le type le plus commun de produit fourni par les satellites d'observation de la terre est une image numérique du type raster dans laquelle chaque pixel est associé à une ou plusieurs valeurs numériques (niveaux numériques) résultant de l'énergie moyenne reçue à l'intérieur d'une bande spectrale donnée.

Bien que les images satellitaires soient comme toutes les autres images composées à la base d'une matrice de pixels, elles contiennent en plus des informations contextuelles ainsi que des traitements spécifiques à ce genre d'images qui augmentent leur utilité. Parmi les ajouts par rapport à une image normale, on retrouve le géoréférencement, la projection cartographique et le traitement des distorsions occasionnées par le système optique des capteurs suivie d'image soumise à une résolution spectrale [7].

### 3.1. Géo-référencement

Le géo-référencement est de situer spatialement un objet par rapport à un système de coordonnées connues. Dans notre cas, il s'agit donc d'attribuer des coordonnées géographiques aux zones contenues dans les images satellitaires. Pour ce faire, il est nécessaire de définir des points de repère dont les coordonnées sont connues et de référencer tous les pixels de l'image selon ces points de repère. Un système GPS peut être utilisé directement sur le terrain. Il est aussi possible de référencer une région à partir de données cartographiques déjà existant pour la région [8].

### **3.2. Projection cartographique**

Il s'agit de représenter la Terre dans un plan bidimensionnel. De nombreuses méthodes de transformation existent afin d'effectuer cette tâche. Les projections les plus répandues en imagerie satellitaire sont la projection de Mercator transverse universelle (MTU) et la projection conforme conique de Lambert (CCL). Chaque projection donne des résultats différents et chacune a ses applications particulières [8].

### **3.3. Image de base**

Ce type d'image est le plus simple qui soit. L'image est directement reçue du satellite et ne subit absolument aucun traitement avant d'être envoyée au client. À moins d'être un chercheur en traitement des images satellitaires qui désire explorer des nouvelles méthodes de filtrage ou d'avoir des besoins très précis, ce type de carte n'est pas souhaitable, car tout le travail de préparation doit être effectué [8].

### **3.4. Images Standard**

Ce type d'image satellitaire est sans doute le plus répandu. Avant d'être rendue disponible, une image standard sera géo-référencée à l'aide des points de repère connus et robustes. Une projection cartographique sera aussi appliquée afin d'avoir une carte en deux dimensions de la zone acquise. De plus, une série de filtres et corrections seront appliquées afin d'éliminer les distorsions causées par le jeu de lentilles du satellite ainsi que le bruit occasionné par le capteur lui-même. Finalement, il arrive aussi parfois que la couverture nuageuse soit enlevée ou atténuée [8].

### **3.5. Couples stéréoscopiques**

Les couples stéréoscopiques sont une paire d'images de la même région avec un léger déplacement entre les deux. Ce type de produit est de plus en plus disponible grâce aux satellites comme SPOT 5 équipés de paires de capteurs permettant l'acquisition d'un couple stéréoscopique en une seule passe [8].

Ce type d'image est utilisé pour générer des modèles numériques de terrain. Un MNT représente la dénivellation du terrain dans la zone captée. Il peut être utilisé pour effectuer une reconstruction tridimensionnelle du terrain. De plus, les paires stéréoscopiques sont utilisées pour déterminer la hauteur des bâtiments ainsi que des arbres et autres éléments contenus dans une image satellitaire [8].

Par la suite vient l'application des canaux spectraux utilisés dans la télédétection.

### **3.6. Image multi spectrale (MS)**

Ce sont les Images dont les pixels sont eux-mêmes associés à un certain nombre de valeurs numériques égal au nombre de bandes spectrales détectables par le senseur. A priori, c'est le type de produit plus pratique puisqu'il nous donne, dans un sens, la signature spectrale des différents éléments présents dans l'image. Par exemple, le satellite IKONOS fournit une image multi spectrale avec 4 bandes couvrant les régions spectrales correspondant au bleu, vert, rouge et proche infrarouge. Plus le nombre de bandes spectrales discriminés par le senseur, plus la capacité d'analyse des éléments présents dans l'image [6].

### **3.7. Images hyper spectrales**

Les images hyper spectrales sont moins fréquentes. Elles sont caractérisées par des informations associées à un grand nombre de bandes spectrales. Ces images sont obtenues, surtout, pour des études d'identification et de classification d'une grande précision, en particulier en minéralogie [6].

### **3.8. Image panchromatique (PAN)**

Ce genre d'image a une seule bande spectrale qui couvre une grande partie du début visible et du début de l'infrarouge, ce qui entraîne une image qui se représente, généralement, par un degré de gris (image noir et blanc). Son principal avantage réside dans le fait de présenter une plus grande résolution spatiale que les images multi spectrales du même satellite. Ces images ont un intérêt particulier en ce qui concerne la détection des éléments de petite surface qui ne sont pas distinguables dans une image multi spectrale [6].

### **3.9. Image fusionnée (PS)**

Ce type d'image est obtenu par fusion d'une image multi spectrale avec une image panchromatique. L'acronyme PS vient de l'expression anglaise «pan-sharpened». Fondamentalement, il consiste à associer chaque valeur de pixel d'image panchromatique à partir d'un algorithme qui combine l'image multi spectrale avec l'image panchromatique. Le résultat final est une image multi spectrale avec une résolution spatiale panchromatique. L'inconvénient de ce type d'images provient de la modification des algorithmes utilisés par l'information spectrale originale prise par des senseurs et qui sont normalement utilisés uniquement en tant qu'outils de photo interprétation et pas pour l'analyse spectrale [6].

### **3.10. L'image stéréo**

C'est un ensemble de deux images de la même zone prises sous des angles d'observation différents. De nombreux satellites ont la capacité de réorienter le senseur, ce qui leur permet de capter ces images dans une ou plusieurs passes. Ils sont généralement employés pour générer des modèles numériques de terrain [6].

## **4. Type des Satellites**

### **4.1. Satellite de Télécommunication**

Le satellite de télécommunication est un satellite artificiel orbital de la terre, il reçoit les émissions de la terre (lien montant) et les retransmis vers la terre (lien descendant) après translation de fréquence et amplification [9].

### **4.2. Satellites d'observation terrestre**

Les satellites d'observation de la Terre varient selon leur type d'orbite, leur charge utile, du point de vue des instruments d'imagerie, de la résolution spatiale des capteurs, de leurs caractéristiques spectrales et de la largeur de leur bande d'acquisition. Tous ces paramètres sont configurés au début de la phase de définition de la mission en fonction de l'application à laquelle est destiné le satellite.

Pour une surveillance météorologique à grande échelle et avec une fréquence élevée, une orbite géostationnaire est bien adaptée. Sur cette orbite, un satellite conserve en permanence dans son champ de vision un hémisphère presque entier. Toutefois, l'orbite étant très haute (environ 36 000 km au-dessus de la Terre), il est difficile d'obtenir une résolution spatiale

élevée. Mais pour des applications comme le suivi des nuages au-dessus des continents, une telle résolution est suffisante.

Pour les applications qui nécessitent des images à haute résolution d'une zone très spécifique, comme la surveillance d'un glacier ou la cartographie des habitations détruites par une catastrophe naturelle, un capteur à haute résolution est nécessaire. Généralement, ce type de capteur dispose d'une bande d'acquisition étroite et se trouve sur un satellite à basse orbite, appelé LEO1 (600 km au-dessus de la Terre, cas du satellite QuickBird). Or sur une telle orbite, il n'est pas possible de surveiller en continu la même zone en raison du mouvement relatif du satellite par rapport à la Terre. Les images d'une zone donnée ne peuvent être acquises que lorsque le satellite passe au-dessus d'elle.

Pour ce qui suis nous allons donner des exemple sur des satellite avec des information en relation avec leur orbite et leur mission [10].

## Exemples

- **ERS (European Remote Sensing Satellites)**

Les satellites ERS-1 et ERS-2 (European Remote Sensing Satellites) ont été construits par des industriels européens, sous la direction de l'ESA2.

Ils ont été lancés respectivement en 1991 et 1995. Ils sont équipés d'un système micro-ondes actif, capable d'acquérir des données à travers une épaisse couverture nuageuse ou durant la nuit. L'un des instruments embarqués à leur bord est le diffusomètre. Il mesure la direction et la vitesse du vent au-dessus des océans. Un autre capteur, l'altimètre, peut mesurer la hauteur des vagues. Enfin, un radar SAR (Synthetic Aperture Radar), produit une image de la surface, ses données sont ensuite utilisées en cartographie [10].

Cependant, l'interprétation d'une image SAR est très différente de celle d'une image acquise par un capteur optique. Les images SAR sont sans couleur. Elles donnent des informations relatives à la rugosité de la surface.

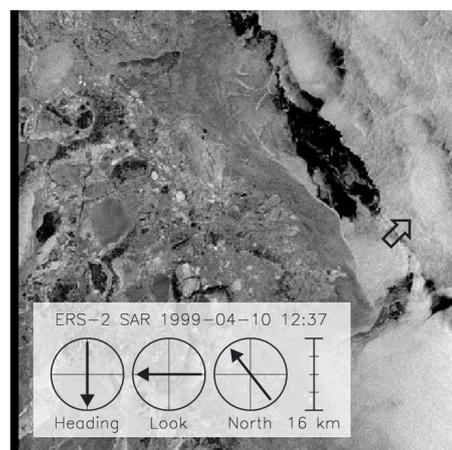


Figure 1.5: Image ERS 2 SAR d'un scénario en mer du Groenland [10]

ERS-2 image SAR d'un scénario dans la mer du Groenland avec des signatures prononcées des caractéristiques de convection, le 10 Avril 1999, 1237 UTC. Zone imagée = 100 km 100 km, pleine résolution = 25 m (taille de pixel = 12,5 m 12,5 m), 5,3 GHz, VV, angle d'incidence = 20 ° -26 ° (proches / extrêmes). Les intensités d'image ont été corrigées (empiriquement) pour tenir compte de la variation avec l'angle d'incidence [10].

- **Envisat**

Le 1er mars 2002, l'ESA lança Envisat, satellite évolué d'observation de la Terre placé en orbite polaire, appelé à fournir des mesures de l'atmosphère, de l'océan, de la Terre et de la glace. Les données produites par Envisat sont exploitées dans le cadre de la recherche scientifique sur la Terre et de la surveillance des changements environnementaux et climatiques.

Le radiomètre AATSR (Advanced Along Track Scanning Radiometer) établit la continuité des jeux de données ATSR-1 et ATSR-2 (de la série ERS) pour des mesures précises de la température de la surface des mers (0,3K ou mieux), en vue de contribuer à la recherche sur les climats et d'aider les utilisateurs opérationnels et scientifiques [10].

Un radar ASAR (Advanced Synthetic Aperture Radar) qui fonctionne dans la bande C, assure la continuité des données après ERS-2. Il comporte une fonctionnalité améliorée en matière de couverture, de plage d'angles d'incidence, de polarisation et de modes de fonctionnement. Ces améliorations permettent de piloter le niveau des rayons radar et de sélectionner différentes fauchées, d'une largeur de 100 ou 400 km [10].



Figure 1.6: L'image ASAR couvre la Péninsule Antarctique [10]

MERIS est un spectromètre d'imagerie qui mesure les rayons solaires réfléchis par la Terre, à une résolution spatiale au sol de 300 m, avec 15 bandes spectrales dans le visible et le proche infrarouge, programmables en largeur et en position [10].

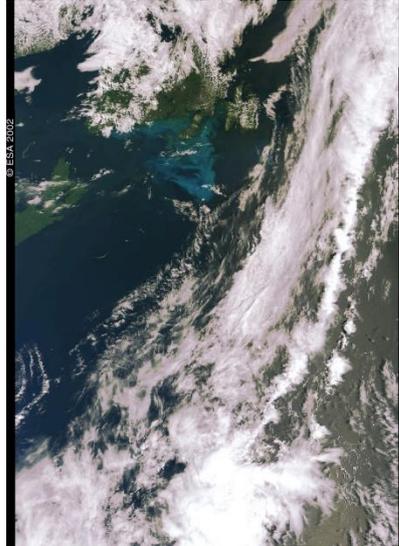


Figure 1.7: Capture d'un immense banc de phytoplancton le long des côtes mauritaniennes par MERIS

MERIS offre une couverture intégrale de la Terre tous les 3 jours. La mission principale de MERIS consiste à mesurer la couleur de l'eau dans les océans et les régions côtières. De la couleur de la mer, on peut déduire une mesure de la concentration en pigments de la chlorophylle et en sédiments en suspension, ainsi que les charges d'aérosol au-dessus des zones marines, qui sont autant d'éléments essentiels pour l'étude du cycle du carbone des océans et du régime thermique supérieur des océans. Ces données sont également utilisées pour la gestion des pêcheries et des zones côtières.

Pour bien comprendre les processus qui régissent le comportement physique et photochimique de l'atmosphère, des mesures détaillées, à l'échelle mondiale, de la quantité et de la distribution, horizontale et verticale, de l'ozone, ainsi que de nombreux autres gaz de trace atmosphériques, s'impose. Les capteurs suivants, embarqués à bord d'Envisat, en fournissent les données [10]:

- L'instrument de suivi planétaire par occultation stellaire (GOMOS).
- Le sondeur atmosphérique passif à interférométrie de Michelson (MIPAS).
- Le spectromètre d'absorption imageur à balayage pour la cartographie de l'atmosphère (SCIAMACHY)).

#### • SPOT

Lancé le 21 février 1986, ce satellite peut opérer dans trois bandes spectrales (vert, rouge et quasi-infrarouge) avec une résolution de 20 mètres.

En outre, SPOT est équipé d'un scanner panchromatique. Autrement dit, il balaye dans une bande qui comporte les plages verte et rouge de la lumière visible. La résolution spatiale de ce capteur est de 10 mètres, la résolution la plus élevée pendant des années pour un capteur non militaire [10].

SPOT comporte une fonctionnalité spéciale : il peut être programmé pour « regarder de côté » et balayer la même bande deux fois lors de deux survols consécutifs. Les deux angles visuels différents sur la même zone produisent un effet stéréoscopique, qui permet de cartographier les conditions de niveau.

Grâce à ses deux canaux visuels et son canal proche infrarouge, SPOT est l'outil idéal pour la cartographie de la végétation de petites surfaces locales. La détection stéréoscopique par SPOT est utilisée dans les calculs de niveau [10].

### **4.3.Satellites météorologiques**

Cinq satellites géostationnaires ont été placés en orbite autour de l'Equateur: Meteosat par l'ESA, GMS par le Japon, INSAT par l'Inde et, GOES E et GOES W par les Etats-Unis [10].

#### **Exemples**

- **Meteosat**

Les satellites Meteosat produisent, chaque demi-heure, une image entièrement à jour des conditions météo mondiales, à l'exception des régions polaires.

Meteosat tourne sur un axe, parallèle à celui de la Terre. Il effectue 100 tours par minute. A chaque rotation, il balaye une bande de 5km de large d'Est en Ouest. Cette bande est divisée en 2.500 zones de balayage. Pour chaque rotation, le miroir du scanner est réglé de manière à permettre le balayage d'une nouvelle bande [10].

Une image représentant la totalité du disque terrestre est constituée de 2.500 bandes, balayées en 25 minutes. Après une pause de cinq minutes, l'image suivante est entamée. Le flot continu de données est envoyé au centre de contrôle de Darmstadt, en Allemagne, pour y être traité. Le balayage est effectué à l'aide de trois canaux : un canal visible et proche infrarouge, un canal infrarouge moyen et un canal infrarouge thermique [10].

- **MSG (Meteosat Second Generation)**

MSG est appelé à générer une imagerie multispectrale de la surface de la Terre et des systèmes nuageux à un rythme deux fois plus rapide (toutes les 15 minutes et non pas toutes les demi-heures) que celui du Meteosat, en couvrant un nombre beaucoup plus important de canaux du spectre (douze, contre trois pour Meteosat). La résolution spatiale de MSG sera également nettement meilleure (1km pour le canal haute résolution visible, 3 km pour les autres) [10].

- **NOAA (National Oceanic and Atmospheric Administration)**

C'est en 1970 que la NOAA envoya en orbite le premier de toute une série de satellites. Ces derniers se déplacent en orbite solaire synchrone, environ 850 km au-dessus de la Terre, qu'ils balaient entièrement en vingt-quatre heures.

Les derniers satellites NOAA sont équipés d'un radiomètre AVHRR (Advanced Very High Resolution Radiometer ou Radiomètre Avancé à Très Haute Résolution) qui balaie dans cinq canaux. Le scanner de ce radiomètre permet de cartographier la végétation et les formations nuageuses et de mesurer la température et l'humidité dans l'atmosphère et sur la Terre [10].

Les satellites NOAA en orbite polaire utilisent de nombreuses techniques de transmission. Les données collectées par l'équipement AVHRR des satellites NOAA sont transmises en temps-réel vers la terre, sous deux formes différentes :

- le mode APT (Automatic Picture Transmission).
- le mode HRPT (High Resolution Picture Transmission).

Le mode HRPT transporte l'ensemble des données recueillies par les instruments à bord NOAA, sous forme numérique et en bande S. Le mode APT au contraire ne transporte que certaines données issues du seul équipement AVHRR, de manière analogique et en bande VHF [10].

Ainsi les radioamateurs peuvent recevoir par APT des images en faible définition avec un récepteur simple et peu onéreux, tandis que les plus exigeants et les institutions utilisent un récepteur HRPT plus complexe et coûteux.

#### **4.4. Les satellites radars**

Le radar à synthèse d'ouverture (RSO), dont certains satellites d'observation de la Terre sont munis, est défini comme un « radar à visée latérale pourvu d'un dispositif spécial de traitement des signaux rétrodiffusés, permettant d'améliorer la résolution géométrique de l'image selon l'axe parallèle à la route du vecteur ». Puisque les ondes radars sont polarisées et que différents matériaux réfléchissent les ondes radars de manières différentes, il est possible de faire une étude polarimétrique de la couverture terrestre afin d'en déterminer la nature. De plus, en utilisant deux antennes espacées, il est possible de déterminer la position tridimensionnelle d'un pixel grâce à ce qu'on appelle l'interférométrie.

##### **Exemples**

Bien que plusieurs satellites radars existent, seulement le plus récent radar canadien et le plus récent radar allemand seront présentés dans cette section.

Il s'agit de RADARSAT-2 et TerraSAR-X, bien qu'ils ne disposent pas de canaux spectraux il permet d'obtenir une résolution spatiale de 3m et 1m respectivement et il s'agit des meilleures résolutions présentement disponibles sur le marché pour des images radars satellitaires [10].

##### **Image satellitaire Radar**

Les possibilités d'utilisation des données radars sont multiples dans le domaine de la télédétection. De nombreux chercheurs ont d'ailleurs publié des articles forts pertinents pour diverses applications utilisant les images radars. Par exemple, les auteurs [11] utilisent les données d'amplitude et de phase interférométrique pour détecter les bâtiments à l'aide de leur ombrage.

Les résultats sont, à première vue, très intéressants, mais les auteurs mettent en garde contre l'utilisation de leur algorithme dans les zones de densité urbaine élevée.

Dans le même ordre d'idée, les auteurs [12] proposent une chaîne d'extraction de structures construites par l'homme à l'aide d'images RSO. Leur objectif pratique est d'extraire le réseau routier de leur image d'étude. Ils se basent sur la programmation dynamique pour

effectuer des recherches de candidats possibles pour les routes dans un arbre de tous les candidats.

Bien que l'intérêt de la télédétection soit souvent tourné vers le développement humain, il est aussi possible d'utiliser des données radars pour détecter et tracer les contours des rivages. Ainsi, les auteurs [13] ont exploité la transformée en ondelettes ainsi que la méthode des contours actifs pour obtenir des contours suffisamment précis des rives d'un lac.

#### **4.5.Satellites commerciaux à haute résolution optique**

- **IKONOS**

Le satellite IKONOS a été lancé le 24 septembre 1999 depuis la base militaire de Vandenberg en Californie. Ses capteurs panchromatique et multispectraux à très haute résolution peuvent différencier les objets avec une précision supérieure à un mètre carré au sol, soit suffisamment pour distinguer une voiture d'un camion.

Une telle performance réalisée à partir d'une altitude orbitale de 680 km représente un accroissement significatif de la résolution d'image par rapport à tous les systèmes commerciaux précédents de télédétection par satellite. IKONOS est exploité par la société GeoEye, dont la flotte de satellites comprend également les séries OrbView et GeoEye [10].

Les images produites par IKONOS comptent parmi les images satellite les plus détaillées qu'il soit possible de se procurer dans le cadre d'applications civiles.

A son bord, IKONOS transporte également un capteur multispectral d'une résolution de 4 m avec 3 canaux visibles et un canal proche infrarouge. Il permet ainsi de réaliser une cartographie de l'utilisation du sol [10].

- **QuickBird**

QuickBird est un satellite commercial de la société DigitalGlobe. Lors de son lancement depuis la base militaire de Vandenberg en Californie le 18 octobre 2001 [10], il bénéficiait d'une haute résolution.

Tandis que QuickBird fait le tour du globe à une altitude de 600 km au-dessus de la Terre, son capteur recueille des images de la surface de la Terre durant les heures du jour.

Le système recueille des données panchromatiques de 61cm et des données stéréoscopiques multispectrales de 2,5 m. QuickBird a été mis au point pour couvrir de vastes étendues avec efficacité et précision. Il est capable d'acquérir plus de 75 millions de km<sup>2</sup> de données d'imagerie par an (plus de trois fois la taille de l'Amérique du Nord). Ces données sont ensuite exploitées pour la cartographie, la planification agricole et urbaine, la recherche météo et la surveillance militaire [10].

- **DMC (Disaster Monitoring Constellation)**

Le DMC (Disaster Monitoring Constellation) est composé d'une constellation de satellites de plusieurs pays pour la Télédétection.

Initialement, il a été conçu pour la surveillance des catastrophes naturelles parce qu'il permet plus d'une couverture quotidienne de n'importe quel point du globe [10]. Cette courte

période de revisitations permet leur utilisation dans de nombreuses applications et champs technico-scientifiques.

Les images obtenues par cette constellation de satellites sont multi spectrales.

## 5. Classifications des images satellitaires

La classification est un processus de reconnaissance des formes. En télédétection, elle consiste à effectuer la correspondance entre une scène de l'image matérialisée généralement par leurs valeurs radiométriques et des classes connues a priori ou non par l'utilisateur. La correspondance est réalisée par des fonctions discriminantes sous forme de règles de décision ou des distances géométriques [14].

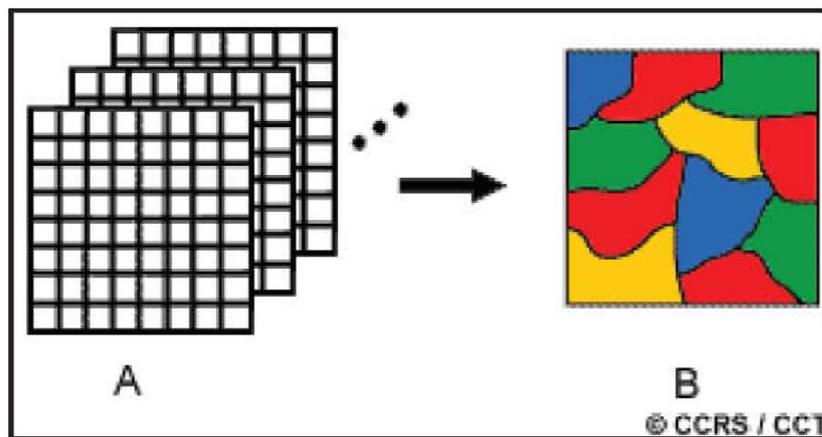


Figure 1.8: Principe de classification

### Méthodes de classification :

Les méthodes de classification proposées intègrent un grand nombre de données et l'application autour de la classification est une chaîne assez conséquente et complexe, points les plus importants sont décrits. Le fonctionnement général de l'application peut être résumé par la figure 1.9.

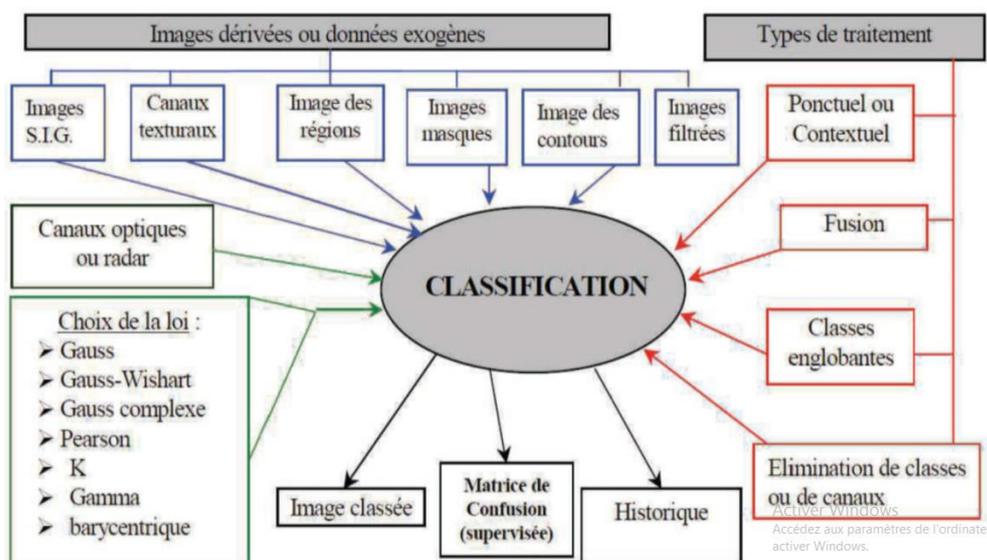


Figure 1.9: Représentation des méthodes de classification

Les images dérivées introduites dans la classification sont les :

- Images texturales : obtenues -1 par le calcul d'écart type ou de coefficient de variation sur les images sur un voisinage centré sur le pixel traité, -2 par les modules d'analyse du paysage.
- Image des régions: pour introduire la connaissance de l'expert par l'emplacement de certaines classes dans certaines zones, afin de faciliter la détection des classes.
- Image des contours : d'aiguiller la décision d'affectation du pixel à une classe en analysant son voisinage.
- Image « masque »: permettent d'établir des zones de l'image à ne pas classer en raison du recalage des images.
- Image du MNT (Modèle Numérique de Terrain).
- SIG (Système d'information géographique) : permettent de discriminer directement certaines classes à partir d'éléments contenus dans le SIG.
- Image du réseau routier et/ou hydrographique.

## 6. Conclusion

Afin de clore ce chapitre on peut dire que ses recherches nous ont amené à mieux comprendre le domaine d'étude et les ressources à utiliser dans notre travail.

L'étude des satellites, leurs types ainsi que la classification de leur image d'une manière globale nous a permis de connaître comment extraire et utiliser les différents ressources existante (types d'images satellitaires), les quelles sont les plus exploitées et les plus fiables pour notre travail, car une base de données crédible est l'un des piliers de notre projet de classification, grâce à ces informations nous aurons la possibilité d'avoir de bon résultat lors de notre implémentation dans le domaine de l'apprentissage profond.

Dans le prochain chapitre nous allons nous pencher sur les catastrophes naturelles et leurs dégâts.

---

# **Chapitre 02**

## **Les catastrophes naturelles**

---

Les catastrophes sont indissociables de l'histoire de notre planète. Elles représentent des événements subits et brutaux, qui provoquent des bouleversements importants et qui entraînent des dégâts immenses matériels et humains avec un impact gravement nuisible. Pour cela la gestion de ces phénomènes était marquée comme étant l'un des plus grands défis auxquels nous nous sommes confrontés au cours de l'histoire.

Ce chapitre montre les différents types de catastrophes ainsi que l'étude des changements structuraux lors du déroulement de ces phénomènes.

Nous nous focaliserons dans ce chapitre sur les risques naturels qui peuvent entraîner des dégâts sur les structures. On distingue principalement dans les catastrophes naturelles : les avalanches, les feux de forêt, les inondations, les mouvements de terrain, les cyclones, les tsunamis, les séismes et les éruptions volcaniques.

## 1. Quelques notions sur les catastrophes

Lorsqu'un événement potentiellement dangereux, appelé aléa, peut survenir dans une zone où des enjeux humains, économiques ou environnementaux sont présents, il devient un risque. Le risque constitue donc une potentialité ou une éventualité pour créer une catastrophe [15].

$$\text{Aléa} + \text{Enjeux} = \text{Risque} [15]$$

Donc une catastrophe se caractérise par :

- **L'aléa** : est la manifestation d'un phénomène naturel d'occurrence et d'intensité donnée.
- **L'enjeu** : les personnes et les biens susceptibles d'être affectés par des phénomènes naturels
- **Le risque majeur** : est la conséquence d'un danger naturel ou humain. Ces dangers résultent des dégâts volumineux qui dépassent les capacités de réaction des directions concernées
- **La vulnérabilité** : représente et mesure la prévisibilité de l'aléa sur les enjeux. Diverses actions peuvent réduire la vulnérabilité soit par la réduction de l'intensité de certains aléas ou bien par la limitation des dommages sur les enjeux [16].

## 2. Les Dégâts causés par les catastrophes naturelles

Un dégât est un ensemble de dommages causés par un événement violent. Ces dommages varient selon le type, l'intensité et le lieu de la catastrophe concernée. Les dégâts causés influencent directement l'environnement naturel mais aussi les habitations et aux structures à proximité.

Les dommages sur les structures peuvent provoquer de grandes fissures ou des chutes partielles des murs ou des toits, mais il existe des structures plus robustes qui résistent et qui ne montrent pas de grands signes de dommages causés par ces catastrophes. Nous allons nous concentrer sur les toits car une étude et une analyse de l'état de ces derniers va nous donner de bons résultats sur le degré des dommages causés [17].

Sur ce qui va suivre nous allons aborder quelques catastrophes et mentionner les dégâts causés par eux

## **2.1. Les éruptions volcaniques**

L'éruption volcanique est un phénomène géologique connu par l'émission de lave. Les dégâts causés par les éruptions volcaniques sont :

- elles détruisent des voies de communications, des habitats et des structures.
- Les glissements de terrain.
- l'éruption peut provoquer des vagues sur la mer qui se déplacent à 700-1000 km/h et prennent une amplitude gigantesque (quelques mètres à quelques dizaines de mètres) s'approchant de la côte parfois des centaines de kilomètres ou plus [18].

## **2.2. Séisme**

Le séisme est globalement défini par les manifestations de la tectonique des plaques. Ce phénomène est causé par la libération brusque d'énergie entreposée par les différentes plaques de la croûte terrestre lors de leurs mouvements relatifs à ces failles, les séismes sont parmi les phénomènes les plus dangereux.

Le risque des séismes est sur de nombreux niveaux dont : environnemental, structurel et naturel.

Les chances d'une liquéfaction, effet de site, tsunami et glissement de terrain augmentent après qu'un séisme soit produit [19].

## **2.3. Les glissements de terrain**

Un glissement de terrain est un phénomène géologique qui fait référence au déplacement d'une masse de sol vers le bas et à l'extérieur.

Il peut être défini comme étant le mouvement d'une masse du sol ou de roc tout au long d'une surface de rupture sous l'effet de la gravité qui s'amorce essentiellement ou il y a un talus. Généralement, ce déplacement est soudain et rapide l'épaisseur du glissement peut aller de quelques mètres à plusieurs dizaines de mètres tandis que leur surface peut atteindre quelques km<sup>2</sup> [20].

Les glissements de terrains ont plusieurs conséquences, ils peuvent entraîner une fermeture de routes ou une modification complète de la topographie d'une zone précise [20].

## **2.4. Les inondations**

Les inondations se réfèrent à la situation où la zone générale est submergée par l'eau. L'immersion peut se faire lentement ou brusquement, et se répète régulièrement.[21]

La vulnérabilité de la population est notamment due à sa situation géographique dans la zone inondée. Le danger se manifeste dans le risque d'être emporté ou noyé, ou bien d'être isolé. Aussi l'interruption des voies de communication peut gêner les secouristes à faire leur travail.

Il faut prendre en compte que les zones industrielles situées en zone inondable ont face à un risque de pollution et d'accident technologique [21].

## **2.5.Cyclones**

Un cyclone est une perturbation atmosphérique tourbillonnaire, de grande échelle, due à une chute importante de pression atmosphérique. Ce genre de phénomènes sont connus dans les régions tropicales. Ils sont caractérisés par des pluies diluviennes et des vents très violents (jusqu'à 360 km/h), qui tournent dans le sens des aiguilles d'une montre (hémisphère sud) ou dans le sens inverse (hémisphère nord) [21].

Les cyclones ont plusieurs conséquences on distingue qu'il y a des effets directs comme la destruction des forêts dues aux vents et des structures ainsi que la provocation de création de fortes inondations [21].

## **2.6.Les incendies de forêt**

Les incendies sont des catastrophes de type forestière (forêts de feuillus, de conifères ou mixtes), sub-forestière (maquis, garrigues ou landes) ou de type herbacée (prairies, pelouses...). Lorsque le feu prend une surface minimale d'un hectare d'un seul tenant nous nommons la catastrophe « les incendies de forêt » [21].

Les risques provoqués par les incendies peuvent être résumés dans des blessures liées à l'effondrement des structures et des risques d'explosion, des brûlures (la température des flammes peut aller de 600 à 1200°C) ce qui provoque des changements climatiques qui peuvent causer d'autres catastrophes naturelles, pour finir le manque de visibilité peut causer des difficultés dans la gestion de cette catastrophe [22].

## **3. Les besoins pour gérer la crise**

Les besoins varient au fil du temps après une catastrophe. Pendant et immédiatement après la crise, ce dont les équipes d'urgence et les différentes autorités ont le plus besoin est une estimation de l'ampleur de la crise, de sa situation géographique et de son étendue.

Les cartes les plus récentes possibles de la région touchée sont nécessaires pour aider à localiser les villes et leur densité de population, ainsi que les différentes infrastructures de la région. Les cartes montrant les zones touchées tiennent compte de la taille des ressources d'intervention. Les cartes des dégâts, faisant état d'une évaluation plus précise des dégâts, sont établies dans un deuxième temps, peu de temps après la catastrophe [17].

Il est nécessaire de connaître rapidement [17] :

- l'état des routes de la zone pour pouvoir guider les urgences.
- l'état des réseaux d'énergie et d'eau.
- les zones les plus affectées, afin de cibler les interventions des secours.

## **4. Evaluation des dégâts**

L'évaluation des dégâts peut être effectuée de deux manières :

- en temps de crise, aider les équipes de secours sur place à localiser les endroits où il est le plus urgent d'intervenir. Il est également utile par la suite d'informer les autorités sur l'état de tous les bâtiments et infrastructures critiques de la ville, il permettra ainsi de déterminer quels bâtiments peuvent continuer à être utilisés avec ou sans travaux, et lesquels devraient être détruits et reconstruits.
- dans un but préventif, afin d'estimer et comprendre les vulnérabilités des bâtiments, ainsi que les lieux qui pourraient être exposés à des dangers futurs.

## **5. Conclusion**

Nous avons présenté dans ce chapitre une vue globale sur les catastrophes naturelles.

Après l'étude fait dans ce chapitre nous pouvons conclure que les dégâts causés par les catastrophes naturelles peuvent faire des réformes géologiques sur différents sites. Ces réformes sont représentées par l'endommagement temporaire ou définitif des structures urbaines et des routes, ce qui va engendrer le blocage des voies d'évacuation et des chemins importants. Suite aux dégâts cités nous recevrons plusieurs problèmes lors de la gestion de la crise.

Dans le chapitre suivant, nous présentons les différentes techniques nécessaires pour notre étude.

---

**Chapitre 3**

**Les techniques**

**De**

**L'apprentissage profond**

---

L'intelligence artificielle est une discipline scientifique recherchant des méthodes de solution à des problèmes fortement complexe. L'apprentissage automatique (ou artificiel) (machine-learning) est un des champs d'étude de l'intelligence artificielle. Par conséquent, l'apprentissage profond est un ensemble de méthodes d'apprentissage automatique tentant de modéliser avec un haut niveau d'abstraction des données grâce à des architectures articulées de différentes transformations non linéaires.

Dans ce chapitre nous allons présenter tout d'abord les notions en relation avec l'apprentissage automatique ensuite nous allons introduire le deep learning qui est un nouveau domaine de recherche du machine learning qui a été introduit dans le but de rapprocher le Machine Learning de son objectif principal : l'intelligence artificielle. L'apprentissage profond concerne les algorithmes inspirés par la structure et le fonctionnement du cerveau.

Cette notion englobe toute méthode permettant de construire un modèle de la réalité à partir de données, soit en améliorant un modèle général, ou en créant complètement un nouveau modèle.

Dans ce qui suit et afin de mieux comprendre notre sujet nous allons présenter quelques notion et caractéristiques qui appartiennent au domaine de l'apprentissage automatique.

## 1. Qu'est-ce que l'apprentissage automatique

La faculté d'apprendre de ses expériences passées et de s'adapter est une caractéristique essentielle des êtres humains. Elle est essentielle à l'être humain dans les premières étapes de la vie pour apprendre des choses aussi fondamentales que reconnaître une voix, un visage familier, apprendre à comprendre ce qui est dit, à marcher et à parler [23].

L'apprentissage automatique est une tentative de comprendre et reproduire cette faculté d'apprentissage dans des systèmes artificiels. Il s'agit, très schématiquement, de concevoir des algorithmes capables, à partir d'un nombre important d'exemples (donnée, base de données, dataset...), d'apprendre afin de pouvoir appliquer ce qu'ils ont ainsi assimilé aux cas futurs

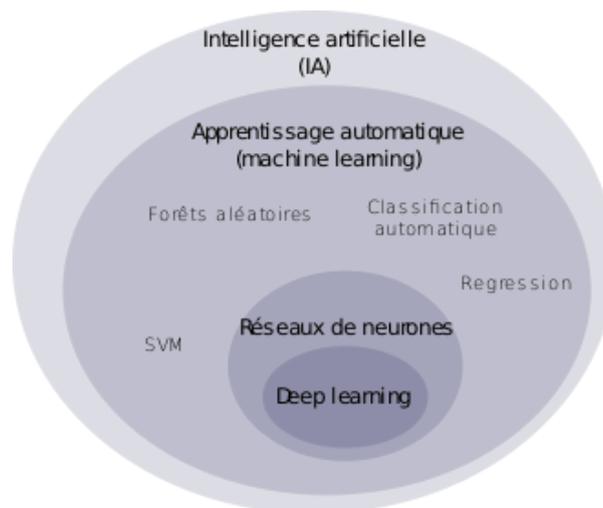


Figure 3.1: Schéma explicatif du domaine de l'IA [68]

## 1.1.Types d'apprentissage

Les algorithmes d'apprentissage peuvent se catégoriser selon le mode d'apprentissage employé :

### 1.1.1. Apprentissage supervisé

L'apprentissage supervisé a pour but d'établir des règles de comportement à partir d'une base de données contenant des exemples de cas déjà étiquetés. La base de données est en principe un ensemble de couples entrées / sorties  $\{(X, Y)\}$ . Le but est d'apprendre à prédire pour toute nouvelle entrée  $X$ , la sortie  $Y$  [24].

L'apprentissage supervisé utilise plusieurs méthodes tel que :

- Boosting
- Machine à vecteurs de support
- Mélanges de lois
- Les réseaux de neurones
- Méthode des  $k$  plus proches voisins
- Arbre de décision
- Classification naïve bayésienne

Ce type d'assimilation peut être appliqué dans plusieurs domaine on site :

- Vision par ordinateur
- Reconnaissance de formes
- Reconnaissance de l'écriture manuscrite
- Reconnaissance vocale
- Traitement automatique de la langue
- Bio-informatique

### 1.1.2. Apprentissage non-supervisé

Contrairement à l'apprentissage supervisé, le non supervisé traite le cas où on dispose seulement des entrées  $\{X\}$  sans avoir au préalable les sorties. L'apprentissage non supervisé ou le « clustering » vise à construire des groupes (clusters) d'objets similaires à partir d'un ensemble hétérogène d'objets [25].

On distingue plusieurs algorithmes de « clustering », comme [25] :

- **K-moyennes (KMeans)**. KMeans est un algorithme de partitionnement des données en  $K$  nombre de groupes ou clusters. Chaque objet sera associé à un seul cluster. Le nombre  $K$  est fixé par l'utilisateur.
- **Fuzzy KMeans**. Il s'agit d'une variante du précédent algorithme proposant qu'un objet ne soit pas associé qu'à un seul groupe.
- **Espérance-Maximisation (EM)**. Cet algorithme utilise des probabilités pour décrire qu'un objet appartient à un groupe. Le centre du groupe est ensuite recalculé par rapport à la moyenne des probabilités de chaque objet du groupe.
- **Regroupement hiérarchique**. Deux sous-algorithmes en découlent, à savoir d'une part le «bottom up» qui a pour fonction d'agglomérer des groupes similaires, donc en réduire le nombre (les rendre plus lisibles) et d'en proposer un ordre hiérarchique, et d'autre part, le

«top down» qui fait le raisonnement inverse en divisant le premier groupe, récursivement, en sous-ensembles.

- **Neural networks (Réseaux de neurones).**

## 2. Apprentissage profond

« L'apprentissage profond » est l'une des techniques utilisées dans l'intelligence artificielle, ces techniques ont permis des progrès importants et rapides dans plusieurs domaines en utilisant plusieurs méthodes, mais la plus intéressante se base sur les réseaux de neurones qui ont montré des résultats plus que satisfaisants avec leurs possibilités de générer des modèles intelligents grâce à la notion d'apprentissage.

Dans ce qui suit nous allons mentionner quelques notions de base relatives aux réseaux de neurones ainsi que son évolution, ses caractéristiques et son importance dans notre étude.

### 2.1. Réseau de neurones artificiels

Les réseaux de neurones artificiels **RNA** sont des systèmes de traitement fortement inspirés par la façon dont les systèmes nerveux biologiques fonctionnent. Ils représentent des modèles puissants non-linéaires de classification et de régression. Les RNA sont principalement composés d'un grand nombre de nœuds de calcul interconnectés appelés **neurones**, dont le travail s'entrelace de manière distribuée pour apprendre collectivement de l'entrée afin d'optimiser sa sortie finale. La structure de base d'un réseau de neurone est modélisée comme le montre la Figure 3.2.

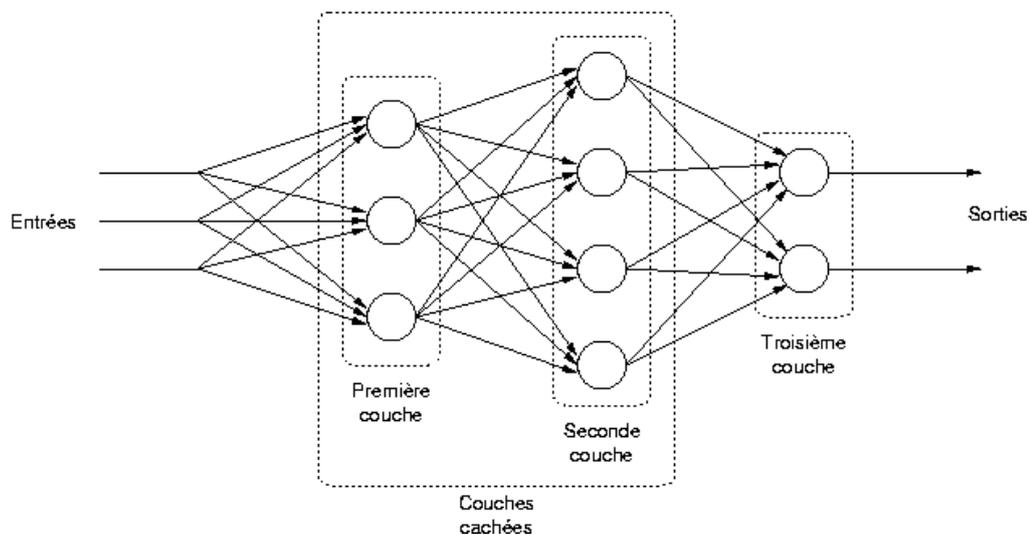


Figure 3.2: Représentation d'un Réseau de neurone artificiel

L'entrée est généralement sous la forme d'un vecteur multidimensionnel de la couche d'entrée qui en assurera la distribution pour les couches cachées. Les couches cachées prendront alors des décisions à partir de la couche précédente et évalueront comment un changement stochastique en lui-même améliore la sortie finale, ce qui est appelé le processus d'apprentissage. Avoir plusieurs couches cachées empilées les unes sur les autres est communément appelé apprentissage en profondeur. La puissance des **RNAs** par rapport aux perceptrons se montre dans le fait que le premier utilise plusieurs couches cachées contrairement au deuxième qui utilise une couche unique.

Les réseaux de neurone artificiels fonctionnent sur deux phases importantes : la propagation vers l'avant et la rétro propagation.

### **2.1.1. La propagation vers l'avant**

Cette phase comme l'indique son nom est dirigé vers l'avant en profondeur d'un réseau ou bien on peut dire de gauche à droite, sans aucune possibilité de retour à des couches précédentes. Le but est de récupérer une sortie S qui représente le résultat d'un travail [26].

Pour assurer le fonctionnement de cette phase, la propagation vers l'avant passe par quelques étapes. Ces étapes s'effectueront au niveau des couches cachées et la couche de sortie, tel que : la pré-activation et l'activation, ces deux étapes se font sur chaque neurone qui se place sur les couches cachées et la couche finale. Dans les prochaines sections ces étapes citées seront expliquées [26].

### **2.1.2. Pré-activation**

Elle représente la première étape de la propagation vers l'avant au niveau de chaque neurone. Elle consiste à assurer la multiplication des valeurs de chaque entrée reliée par une unité caché X avec le poids entre les deux (l'entrée et l'unité cachée). Après avoir multiplié toutes les entrées par leurs poids, la somme entre les résultats obtenus sera calculée en ajoutant une valeur statique appelé biais. Mathématiquement la fonction de pré activation est exprimée par ce qui suit [27] :

$$V = (\sum W_i * X_i) + \text{biais} [28]$$

### **2.1.3. La retro propagation**

La retro propagation est la phase responsable de l'apprentissage d'un modèle, d'une manière générale elle fonctionne comme suit [29]:

Comme la montre l'illustration prochaine, lorsque la propagation vers l'avant se termine, un taux d'erreur doit être calculé. Ce taux d'erreur dépend du résultat final du modèle et du résultat attendu. Par la suite, un parcours inverse du modèle est effectué (de la sortie jusqu'à l'entrée). L'objectif de ce parcours est d'ajuster les paramètres du modèle pour réduire le taux d'erreur calculé. Pour ajuster les paramètres, des méthodes d'optimisation basées sur les dérivés seront utilisées.

La section qui suit contient les fonctions d'erreurs, les méthodes d'optimisation et les changements des paramètres.

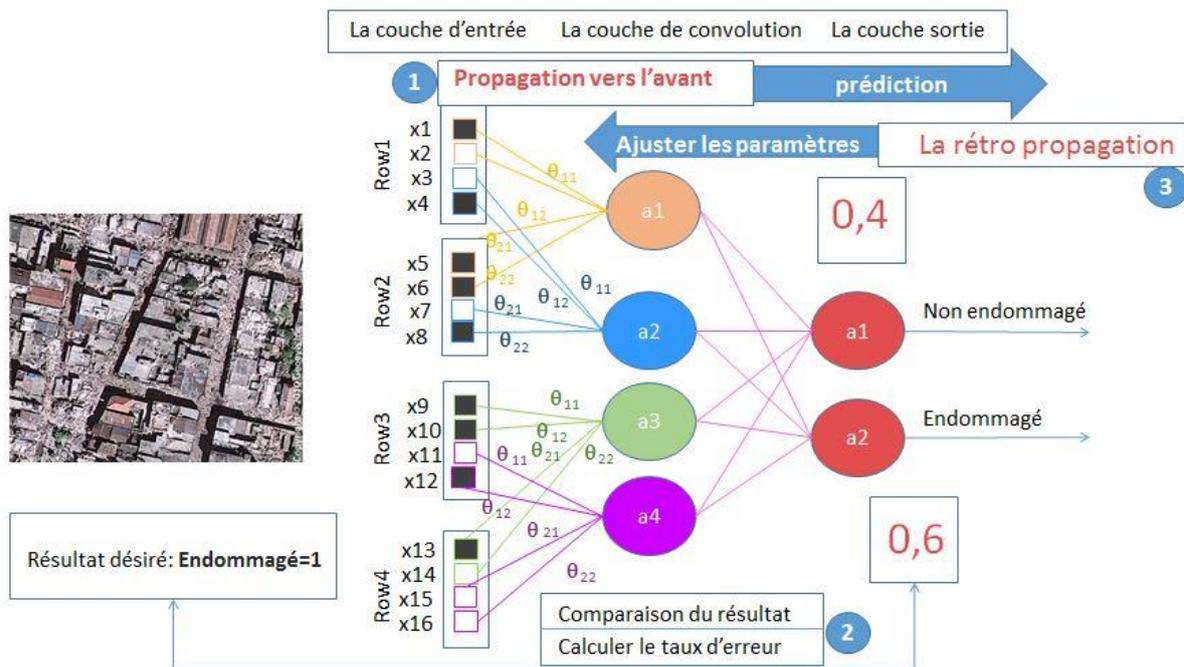


Figure 3.3: Le processus de la rétro propagation

### 2.1.4. Le taux d'apprentissage

Le taux d'apprentissage est un hyper-paramètre configurable utilisé dans l'entraînement des réseaux de neurones spécialement dans la rétro propagation il assure la manipulation de la vitesse d'apprentissage. Ce hyper-paramètre est en réalité une valeur trop petite souvent comprise dans la plage entre 0,0 et 1,0 [30].

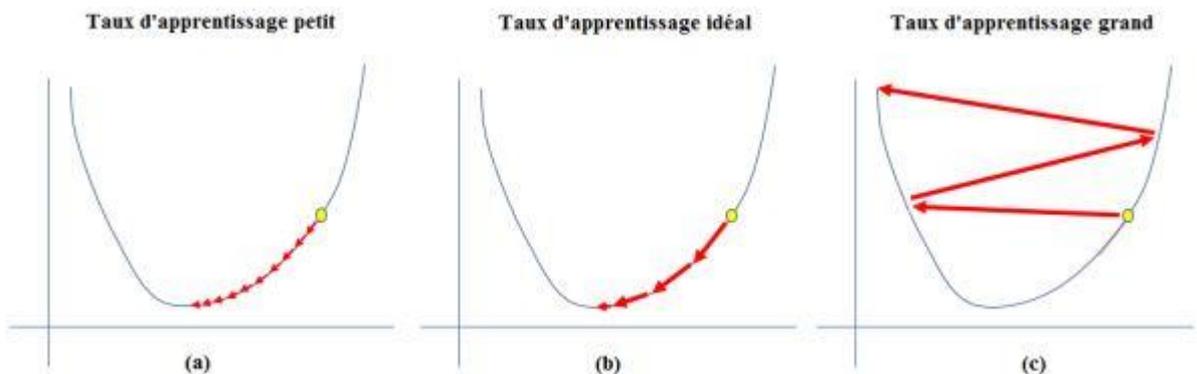


Figure 3.4: Les différents cas du taux d'apprentissage

### 2.1.5. Fonction d'activation

Les fonctions d'activation sont des équations mathématiques utilisées pour donner un sens à la classification faite par un modèle. Ces fonctions peuvent être activées ou non en dépendance de l'importance du neurone qui se caractérise par sa valeur calculée par la fonction de pré-activation, dans les deux cas (fonction activée ou non) la fonction d'activation donne en sortie le résultat final du neurone. Ce résultat se diffère par rapport à la fonction utilisée et la condition de cette dernière [31].

Les fonctions d'activation représentent un point clé dans le fonctionnement du neurone dans toutes ces phases, le choix d'une bonne fonction d'activation assure un bon résultat de prédiction, une correction rapide des paramètres d'un modèle et un entraînement plus rapide [31].

### 2.1.6. Type des fonctions d'activation

Les réseaux de neurones artificiels utilisent plusieurs types de fonctions d'activation, les fonctions suivantes sont les plus utilisées [31]:

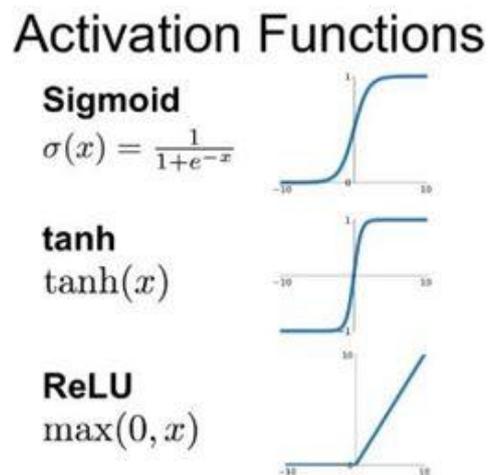


Figure 3.5: Quelques fonctions d'activations

#### 2.1.6.1. La fonction sigmoïde

Elle est la plus ancienne fonction d'activation non-linéaire, cette fonction est représentée mathématiquement par [32]:

$$\sigma(z) = \frac{1}{1+e^{-z}} \quad [32]$$

**Avec : z = le résultat de la pré-activation**

Cette fonction est représentée graphiquement par

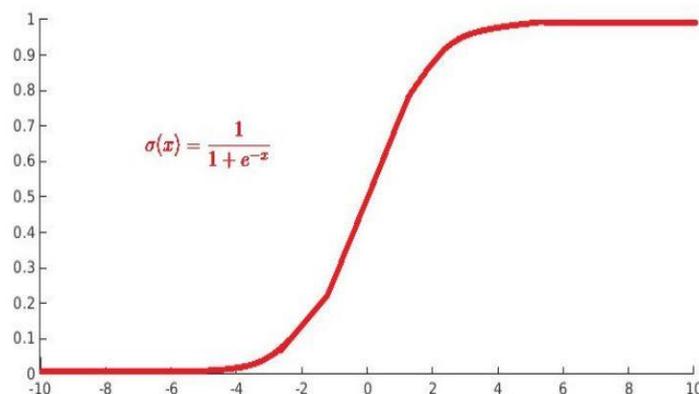


Figure 3.6: La représentation graphique de sigmoïde [27]

Dans le cas de la rétro-propagation la dérivée de la fonction sigmoïde sera utilisée cette dérivée est exprimée mathématiquement par :

$$F'(z) = F(z) \times (1 - F(z)) \quad [32]$$

### 2.1.6.2. La fonction Tangente Hyperbolique

La fonction tangente hyperbolique est une édition de la fonction Sigmoïde. La différence entre les deux c'est que la fonction Tanh produit un résultat compris entre  $[-1, 1]$  [32].

Cette fonction et sa dérivée sont représentées mathématiquement par :

$$F(z) = \frac{1 - e^{-2z}}{1 + e^{-2z}} \quad [32]$$

$$F'(z) = 1 - F(z)^2 \quad [32]$$

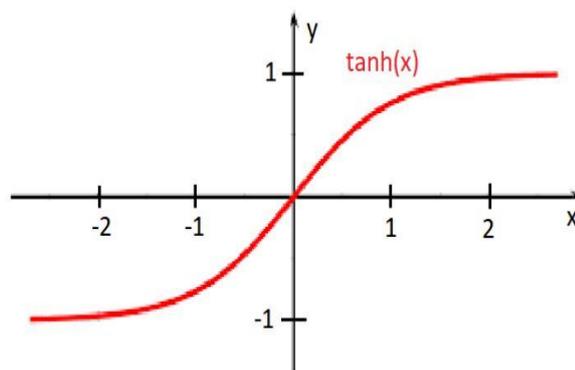


Figure 3.7: La représentation graphique de tanh [27]

Mais le même problème de la fonction sigmoïde est dans la fonction tangente hyperbolique. Cette dernière est couteuse en termes de temps d'apprentissage car sa dérivée converge vers 0 aussi [32].

### 2.1.6.3. La fonction ReLu

La fonction la plus utilisée ces jours-là. Proposée par [33], la fonction d'activation de l'unité linéaire rectifiée consiste à donner une sortie de valeur  $x$  aux entrées de valeurs positives  $x$ , ou une sortie de valeur 0 aux entrées de valeurs négatives [33].

ReLu contrairement aux deux fonctions précédentes offre un apprentissage plus rapide, comme le montre la représentation mathématique, la dérivée des nombres positifs égale à 1 ce qui est bien pour l'apprentissage. Par contre la dérivée de valeurs négatives donne une sortie de valeur 0 (comme les deux premières fonctions).

Cette fonction est représentée mathématiquement comme suit :

$$\mathbf{F}(z) = \max(0, x) \text{ [33]}$$

$$\mathbf{F}'(z) = \begin{cases} 0 & \text{Si } x < 0 \\ 1 & \text{Si } x \geq 0 \end{cases} \text{ [33]}$$

Et représenté graphiquement par :

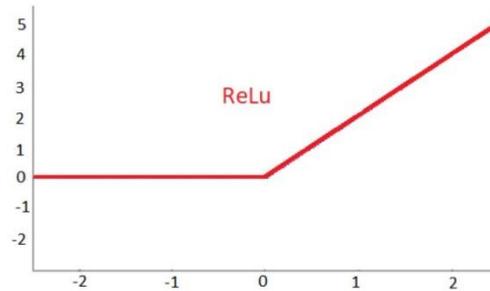


Figure 3.8: La représentation graphique de la fonction ReLu [27]

#### 2.1.6.4. La fonction Softmax

La fonction softmax est utilisée sur des données discrètes ou continues pour faire une classification. Elle donne comme sortie une probabilité de prédiction entre 0 et 1 à toutes les classes existantes de la sortie de tel sorte que la somme des probabilités est égale à 1 et la classe choisie est la classe qui a le plus grand pourcentage de probabilité [34].

Le bon point de la fonction Softmax c'est qu'elle est utilisée sur plusieurs classes contrairement à la fonction sigmoïde (cette dernière est utilisée dans la classification binaire).

La fonction Softmax est représentée mathématiquement comme suit :

$$\mathbf{F}(z_i) = \frac{e^{z_i}}{\sum_{j=0}^k e^{z_j}} \text{ [34]}$$

#### 2.1.7. La fonction de perte

La fonction de perte communique les performances d'un modèle, elle calcule le taux d'erreur en utilisant la valeur du résultat désiré et le résultat obtenu. Si les prédictions s'écartent trop des résultats réels, la fonction de perte donne un très grand nombre [35]. Par contre, plus la valeur de la perte est proche de zéro, plus le taux d'erreur se minimise et le résultat du modèle sera plus performant et réel.

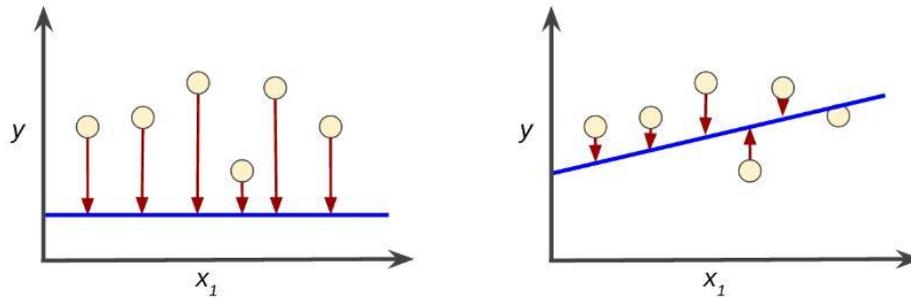


Figure 3.9: La représentation de la fonction de perte

Il existe plusieurs fonctions de perte classées en deux catégories (les fonctions de perte de régression, et les fonctions de perte de classification).

- **Perte d'entropie croisée**

La perte d'entropie croisée, ou perte logarithmique, mesure la performance du modèle de classification dont la sortie est une probabilité comprise entre 0 et 1. L'entropie croisée augmente à mesure que la probabilité prédite d'un échantillon diverge de la valeur réelle. [35]

Cette fonction est donnée par l'équation suivante :

$$CE = \sum_j y(j) \log \hat{y}(j) \text{ [35]}$$

### 2.1.8. Les fonctions d'optimisation

Les fonctions d'optimisation ont pour le but de minimiser les couts ou le taux d'erreur par l'assurance de la mise à jour des paramètres du modèle. Par conséquent, pour trouver la valeur optimale de ces paramètres, il faut faire la mise à jour éventuellement jusqu'à ce que le taux d'erreur soit le minimum possible en se basant sur une règle de mise à jour à cet effet. Différents algorithmes d'optimisation ont une approche différente pour calculer, mettre à jour et trouver la valeur optimale des paramètres du modèle.

#### 2.1.8.1. Descente de gradient

Il représente un algorithme qui assure des calculs mathématiques pour qu'on puisse connaître comment ajuster les paramètres d'un modèle. Le principe de descente gradient est de minimiser la fonction de perte en modifiant les poids et les biais par le calcul des gradients (dérivés) de la fonction de cout par rapport à chaque paramètre du modèle [36]. Ce processus se poursuit jusqu'à ce que le minimum atteigne.

Les paramètres seront ajustés comme suit :

$$W = W - e \frac{dC}{dW} \text{ [29]}$$

$$b = b - e \frac{dC}{db} \text{ [29]}$$

Avec :

- $W$  = le poids.
- $b$  = Biais.
- $e$  = le taux de l'apprentissage.

- $C$  = la fonction de cout.

## Les Algorithmes d'optimisation de la descente de gradient

Il existe plusieurs algorithmes d'optimisation qui implémentent la descente de gradient, les plus utilisées sont :

### • RMSPROP

RMSprop est une technique d'optimisation proposé par Geoffrey Hinton. Cet algorithme ne nécessite pas d'ajuster le taux d'apprentissage manuellement. Il choisit un taux d'apprentissage différent pour chaque paramètre automatiquement. Cela a pour effet d'équilibrer la taille de l'étape et de diminuer l'étape d'un grand gradient pour éviter d'exploser, et d'augmenter l'étape pour un petit gradient pour éviter de disparaître [37].

### • ADAM

Le nom Adam est dérivé d'Adaptive Moment Estimation. Il représente un algorithme d'optimisation présenté en 2015. Adam est une méthode qui assure le calcul du taux d'apprentissage adaptatif pour chaque paramètre. Adam assure le stockage d'une moyenne en décomposition exponentielle des gradients carrés passés, aussi il conserve également une moyenne en décomposition exponentielle des gradients passés [38]

## 2.1.9. Sous et sur apprentissage

Le but de l'entraînement d'un réseau de neurones est d'obtenir un résultat de prédiction optimal équivalent à la meilleure prédiction possible. Toutefois cette tâche peut être menacé par deux phénomènes souvent rencontrés en pratique qui sont le sous et le sur apprentissage [39].

### 2.1.9.1. Sous apprentissage

Le sous-apprentissage fait référence à un modèle qui ne peut pas modéliser les données ni généraliser à de nouvelles données cela veut dire que le modèle ne peut pas apprendre suffisamment de modèles à partir des données d'entraînement ce qui donne des mauvais résultats en termes de performance. Ce problème n'est souvent pas discuté car il est facile à détecter étant donné une bonne mesure de performance [40].

### 2.1.9.2. Sur-apprentissage

Le sur apprentissage fait référence à un modèle qui modélise bien les données d'apprentissage [41]. Ce modèle apprend les détails et les bruits dans les données d'entraînement, ces derniers affecteront négativement sur les performances du modèle.

### 2.1.9.3. Généralisation

La généralisation est la capacité d'assurer des prédictions correctes sur les données utilisées pour l'entraînement et sur de nouvelles données générées par un modèle [42]. Cette situation est la situation parfaite pour chaque réalisation.

### 2.1.9.4. Biais and variance

Le biais et la variance sont deux notions importantes pour exprimer la performance d'un modèle, ces deux notions peuvent causer le sur-apprentissage et le sous apprentissage [43].

Le biais représente la mesure dans laquelle la prédiction est loin d'être correcte. La grande valeur du biais causera un modèle pas performant avec un taux d'erreur élevé. Par contre la variance de grande valeur signifie le contraire, cette dernière provoque un modèle sensible aux bruits causé par trop de détails inutiles, ces détails influencent sur les résultats dans la phase de test [43].

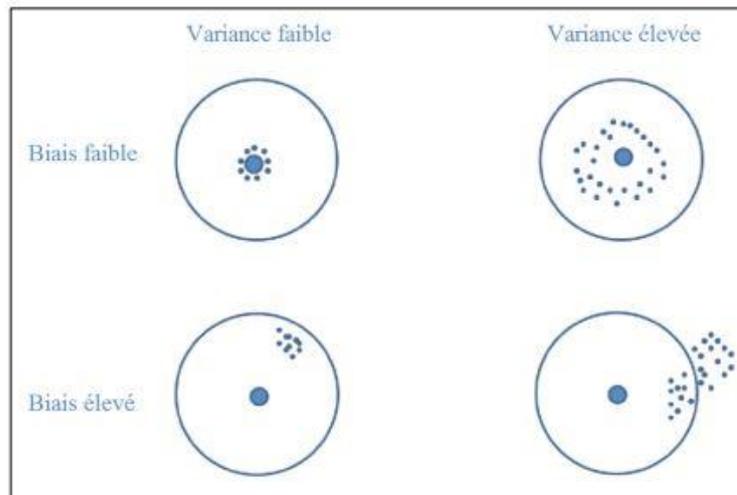


Figure 3.10: Compromis Biais-Variance [44]

Pour comprendre bien le biais et la variance la figure suivante représente la relation entre la grande valeur de variance et le sur-apprentissage, la grande valeur de biais et le sous-apprentissage, et l'équilibre des valeurs des deux avec un bon modèle.

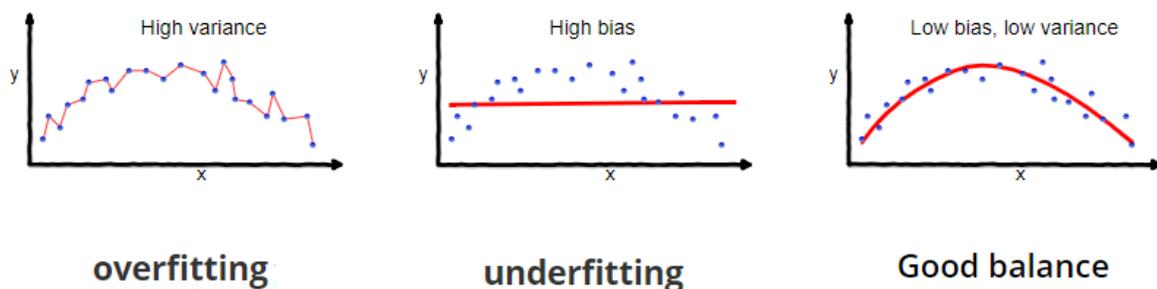


Figure 3.11: la relation entre la variance et sur apprentissage, le biais et le sous-apprentissage

### 2.1.9.5. La différence entre un problème de sur-apprentissage ou sous apprentissage

Pour connaître si un modèle est dans un problème de sur-apprentissage ou sous apprentissage il suffit juste de calculer la fonction d'erreur de l'ensemble de l'entraînement et de l'ensemble de test. Les deux problèmes sont caractérisés comme suit :

	Taux d'erreur d'entraînement	Taux d'erreur de test
<b>Sur-apprentissage</b>	Petit	Grand
<b>Sous-apprentissage</b>	Grand	Grand
<b>Un bon apprentissage</b>	Petit	Petit

Tableau 2 La relation entre le sur apprentissage, Sous apprentissage et le bon apprentissage par rapport aux taux d'erreurs de l'entraînement et test

### 2.1.9.6. Solutions de sous apprentissage (grande valeur de biais)

- Ajouter des données d'entraînement.
- Ajouter des couches cachées ou des neurones dans les couches actuelles car le problème qu'on doit le résoudre est causé par le manque d'entraînement.
- Ajouter plus d'itérations d'entraînement pour que le modèle peut extraire les bonnes caractéristiques.
- Penser à changer l'algorithme d'apprentissage car il se peut que le problème est le mauvais choix de ce dernier.
- Changer la structure du réseau.

### 2.1.9.7. Solutions de sur-apprentissage (grande valeur de variance)

Contrairement au sous apprentissage, le sur apprentissage pose un problème complexe. Heureusement que quelques méthodes ont déjà prouvé leurs performances pour éviter ou corriger le problème cité, on distingue [45]: dropout, l'augmentation des données et Arrêt précoce.

#### a) Dropout

Pour éviter le sur-apprentissage, dont le modèle entraîne trop. La méthode dropout consiste à désactiver des neurones d'une manière aléatoire à chaque itération d'entraînement. Cette désactivation sera durant les deux phases de l'itération (la propagation vers l'avant et vers l'arrière) [47]. Cela pour assurer que les neurones désactivés n'apprendront pas durant les périodes où ils sont inactifs.

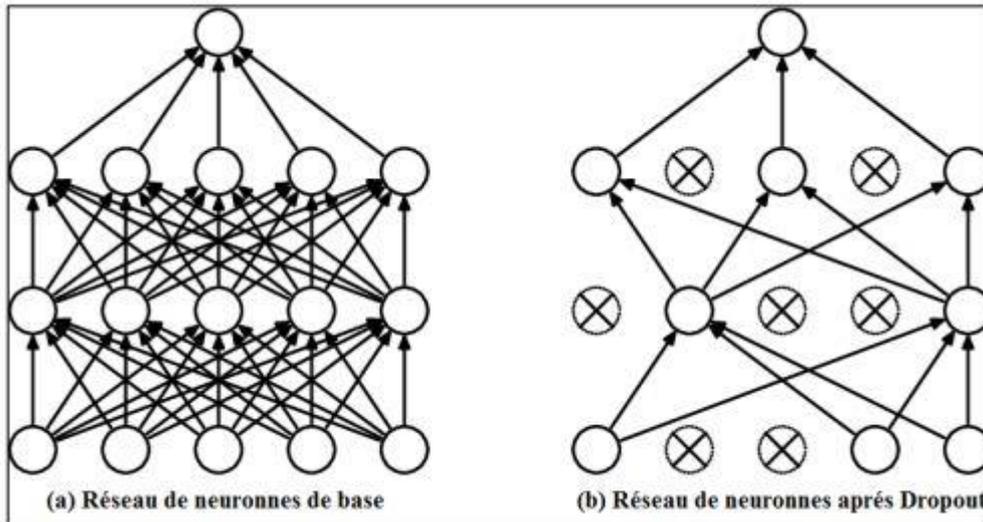


Figure 3.12: représentation d'un réseau de neurone avec la méthode dropout [47]

### b) Augmentation des données

Cette méthode consiste à utiliser de nouveaux ensembles de données afin d'entraîner la machine. Avec la variation des données d'entraînement le système peut généraliser les caractéristiques de son concept [46].

Cette méthode sera appliquée en déformant le premier ensemble d'entraînement pour créer d'autres ensembles. Il faut que les déformations soient réelles, où l'utilisateur du modèle est capable d'entrer ce genre d'ensemble déformé [46].

La solution de déformer les données donnera une performance moins que si on a utilisé un nouveau ensemble de donnée, mais ce dernier sera plus couteux.

### c) Arrêt précoce

Cette méthode consiste à contrôler la phase d'entraînement pour l'arrêter dans le bon moment avant d'entamer la phase de sur-apprentissage. Pour assurer cela un nombre d'itérations sera choisi pour le modèle afin de calculer le taux d'erreur de l'ensemble d'entraînement et l'ensemble de test pour vérifier qu'on n'a pas entamé la phase de sur-apprentissage. Le moment où le taux d'erreur de l'ensemble des tests devient plus grand la phase d'entraînement doit s'arrêter [43].

La figure suivante explique le moment où le processus d'entraînement doit s'arrêter :

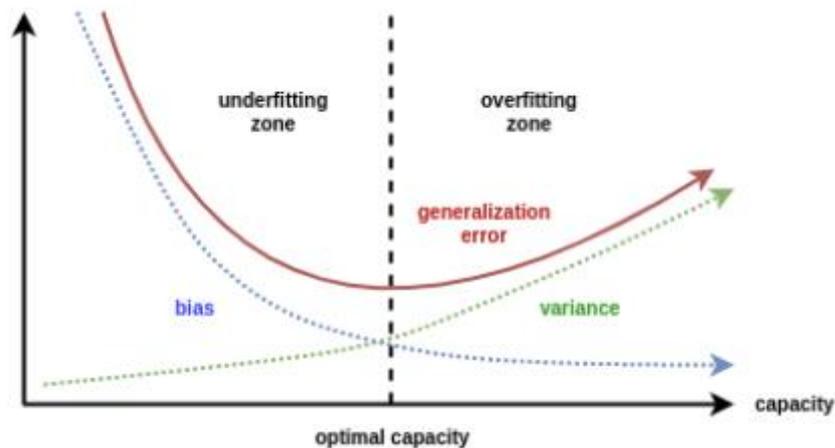


Figure 3.13: le point optimal pour arrêter le processus d'entraînement [43]

## 2.2. Réseaux de neurones convolutif (CNN)

Le CNN (Convolutional Neural Network) est une architecture d'apprentissage en profondeur (Deep learning) inspirée par le mécanisme de perception visuelle naturelle des créatures vivantes [48].

Le CNN est représenté par un réseau neuronal caractérisé par un bloc de convolution et des couches entièrement connectés. Le bloc de convolution contient des couches convolutifs, des fonctions d'activation et des couches de sous-échantillonnage (couche de mise en commun). Les réseaux de neurones convolutifs sont utilisés pour la reconnaissance de formes, la détection d'objets, la classification d'images, la segmentation sémantique et d'autres tâches.

L'aspect le plus bénéfique de CNNs est de réduire le nombre de paramètres dans les réseaux de neurone artificiel (ANN). Cette réalisation a incité les chercheurs à aborder des modèles plus larges afin de résoudre des tâches complexes, ce qui n'était pas possible avec les ANN classiques. L'hypothèse la plus importante sur les problèmes qui sont résolus par CNN ne devrait pas avoir de caractéristiques qui dépendent spatialement [49].

### 2.2.1. Filtre

[50] Définit un filtre, également appelé noyau ou masque. Comme étant matrice bidimensionnelle qui assure la suppression des hautes fréquences dans une image, c'est-à-dire le lissage de l'image, ou bien la suppression des fréquences basses, ce qui donne la détection des contours. Le filtrage comprend le traitement de l'image d'origine et au fur et à mesure que chaque pixel est traité, de nouvelles images basées sur ces valeurs apparaissent. La nouvelle image dépend du filtre utilisé et de l'image d'origine.

### 2.2.2. Stride

Stride est un composant des réseaux de neurones convolutifs, ou réseaux de neurones réglés pour la compression d'images et de données vidéo. C'est un paramètre du filtre du réseau neuronal qui modifie la quantité de mouvement sur l'image ou la vidéo [51].

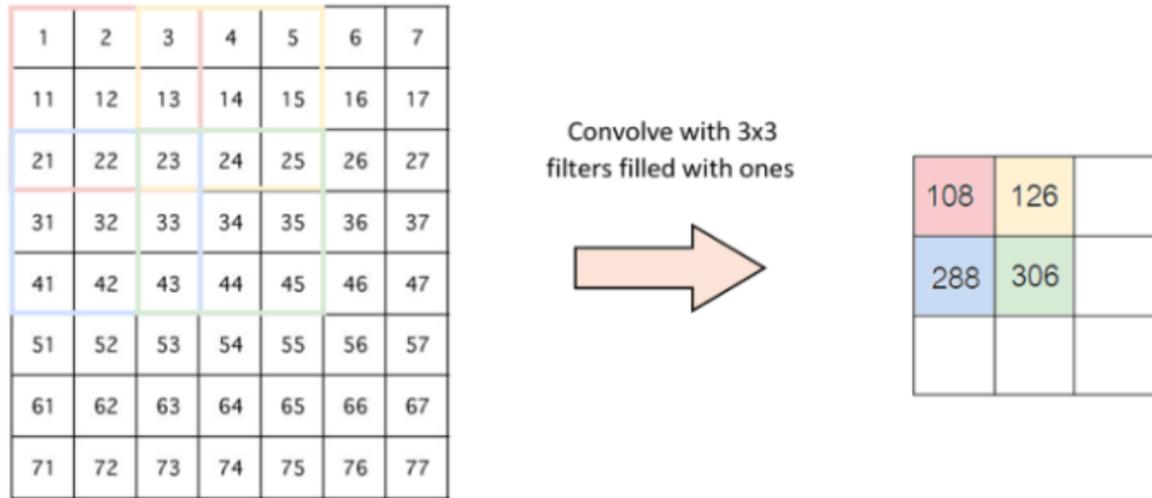


Figure 3.14: Stride de 2 Pixels [52]

### 2.2.3. Les couches des CNNs

Dans cette section les couches qui constituent et caractérisent le réseau de neurone convolutif seront présentées.

#### 2.2.3.1. La couche de convolution

La couche de convolution joue un rôle essentiel dans le fonctionnement des CNNs, cette couche permet d'assurer l'extraction des caractéristiques automatiquement en traitant les images en entrée.

Pour cela, un filtrage par convolution est réalisé, le principe de ce filtrage est de faire glisser la matrice du filtre sur la matrice de l'image, et de calculer le produit de convolution entre les deux. Le résultat de cette opération donne un ensemble de caractéristiques en sortie.

La couche de convolution reçoit plusieurs images en entrée, et calcule la convolution de chacune d'entre elles avec chaque filtre. Les filtres représentent les caractéristiques qu'on veut retrouver dans les images d'entrées. Plusieurs convolutions sur chaque entrée peuvent être effectuées, chacune en utilisant un filtre différent. Cette couche produit un regroupement d'ensembles de caractéristiques, ces derniers deviennent la sortie finale de la couche de convolution [53].

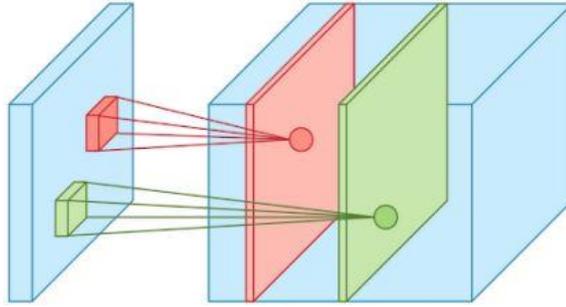


Figure 3.15: Application de plusieurs filtres sur une image d'entrée [47]

### 2.2.3.2. Couche Zero Padding

Après avoir procédé à une convolution, la taille de la matrice de caractéristiques se trouve réduite. Etant donné l'enchaînement des convolutions, cette taille ne cessera de diminuer ce qui engendrera :

- Une perte d'informations aux frontières après chaque couche de convolution.
- La diminution de la qualité d'apprentissage.
- La réduction de la taille de la carte de caractéristiques à 1x1 après un certain nombre de convolution.

Pour pallier ces problèmes, la technique de Zero Padding propose d'ajouter une couche de pixels de valeur zéro pour entourer la matrice d'image (Figure 3.16)

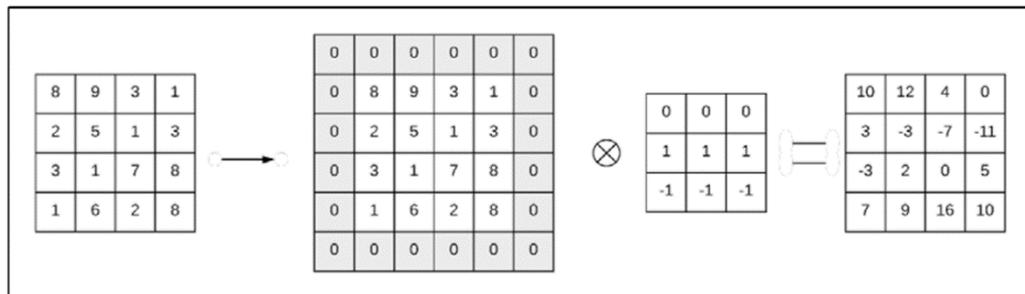


Figure 3.16: Utilisation de Zero Padding avant une convolution [47]

Ce procédé permet de conserver autant d'informations que possible sur le volume d'entrée d'origine afin de pouvoir extraire ses caractéristiques.

### 2.2.3.3. La couche ReLu

Juste après la création de la matrice des caractéristiques la fonction non-linéaire ReLu sera appliquée sur toutes les valeurs de la matrice. L'utilisation de cette fonction assure une rapidité dans l'entraînement et de bonnes précisions. La fonction ReLu rend les valeurs négatives dans la matrice égale à 0 [52].

#### 2.2.3.4. Couche de mise en commun

Cette couche est souvent placée entre chaque deux couches de convolution. Elle a pour le but de réduire progressivement la dimensionnalité de la représentation, et donc de réduire davantage le nombre de paramètres et la complexité de calcul du modèle tout en préservant leurs caractéristiques importantes, elle se fait en appliquant l'opération de l'union sur chaque vecteur en entrée [52].

#### 2.2.3.5. Couche aplanissement

Le rôle de la couche d'aplanissement est de rendre les matrices de caractéristiques sous forme d'un vecteur pour qu'il puisse passer à la couche entièrement connectée [52].

#### 2.2.3.6. La couche entièrement connectée

Après les couches précédentes, des couches entièrement connectées seront ajoutées pour envelopper l'architecture CNN [53]. C'est la même architecture des réseaux de neurone artificiel.

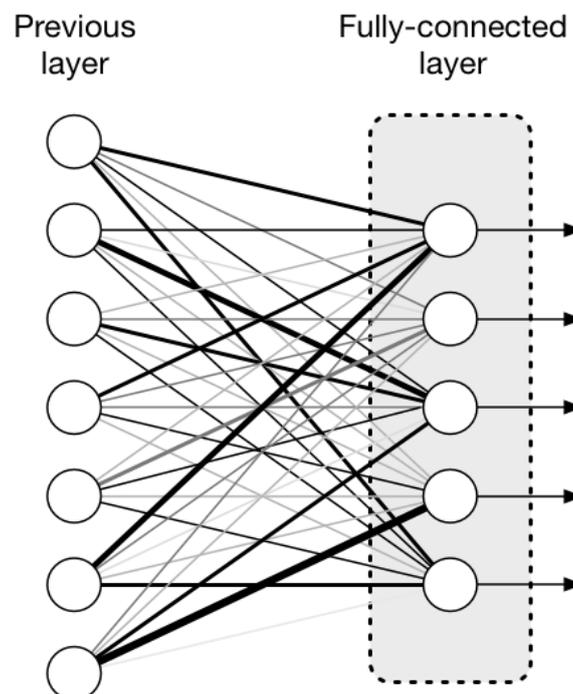


Figure 3.17: Couche entièrement connectée [53]

#### 2.2.4. Qu'est-ce qu'une Architecture d'un réseau neuronal convolutif

L'architecture CNN est inspirée par l'organisation et la fonctionnalité du cortex visuel et conçue pour imiter le modèle de connectivité des neurones dans le cerveau humain, aussi elle représente une formation de couche pré-entraîné qui appartient aux réseaux de neurones convolutifs.

Cette section présente les architectures les plus efficaces et les plus utilisées.

### 2.2.4.1. Réseau neuronal convolutif AlexNet

Le premier réseau de neurones qui a remporté le concours de classification d'images ILSVRC a été AlexNet, en 2012, atteignant une erreur de classement parmi les 5 premiers de 15,31%. À titre de comparaison, la méthode qui n'utilise pas de réseaux de neurones convolutifs a reçu une erreur de classification de 26,1%. AlexNet a collecté les dernières technologies de l'époque pour améliorer le réseau. L'architecture de ce réseau est illustrée à la Figure ci-dessous [54].

AlexNet est considéré comme la première architecture utilisant la fonction d'activation de l'unité linéaire rectifiée.

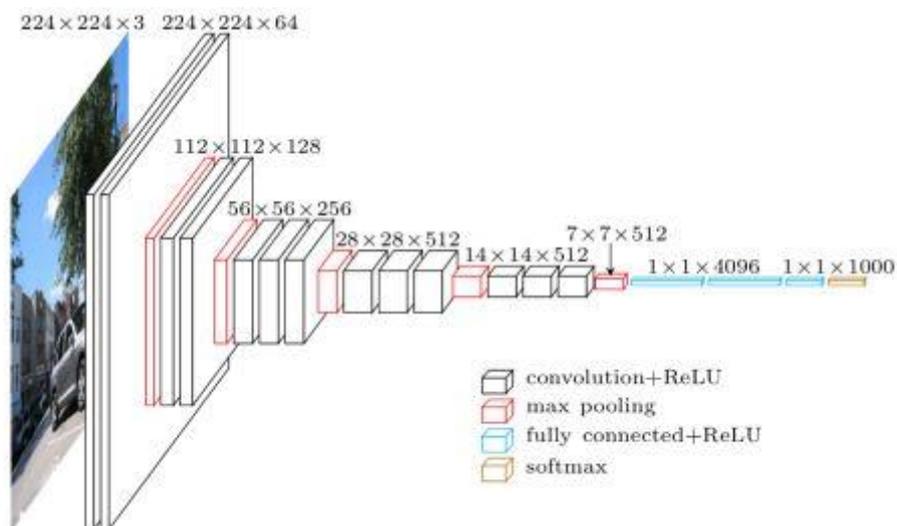


Figure 3.18: Schéma du réseau neuronal convolutif architecture AlexNet [47]

### 2.2.4.2. Réseau neuronal convolutif VGG Net

Vgg-16 est un type de réseau neuronal convolutif. En général, le nombre après le nom du réseau indique le nombre de couches convolutifs de l'architecture. L'idée était d'empiler des couches pour former un réseau neuronal convolutionnel très profond qui fonctionnerait extrêmement bien sur les tâches tel que la classification d'image. Le VGG-16 remporte l'un des prix du défi ImageNet 2014, dans ce réseau, ils ont refusé d'utiliser des filtres supérieurs à  $3 \times 3$ . Puisque les auteurs ont prouvé que la couche de filtre  $7 \times 7$  est équivalente à trois couches avec des filtres  $3 \times 3$ , et dans ce cas, 55% de paramètres en moins sont utilisés. De même, une couche de filtre  $5 \times 5$  équivaut à deux couches avec un filtre  $3 \times 3$ , ce qui économise 22% des paramètres réseau [55].

### 2.2.4.3. Réseau neuronal convolutif GoogleNet/Inception

Le réseau de neurones à convolution Inception-v1 est le gagnant du concours ILSVRC 2014 avec une erreur de top 6 de 6,7%, également connue sous le nom de GoogleNet. Les créateurs de ce réseau, dirigés par Christian Szegedy, sont partis du fait qu'après chaque couche du réseau, il fallait choisir si la couche suivante serait convolutif avec un filtre  $3 \times 3$ ,  $5 \times 5$ ,  $1 \times 1$  ou une couche de sous-échantillonnage. Chacune de ces couches est utile - un filtre  $1 \times 1$  révèle

une corrélation entre les canaux, tandis que des filtres plus grands répondent à des caractéristiques plus globales, et une couche de sous-échantillonnage réduit la dimensionnalité sans une grande perte d'informations. Au lieu de choisir la couche qui doit être la suivante, il est proposé d'utiliser toutes les couches à la fois, parallèlement les unes aux autres, puis de fusionner les résultats en un seul. Pour éviter une augmentation du nombre de paramètres, une convolution 1x1 est utilisée devant chaque couche de convolution, ce qui réduit le nombre de cartes d'entités. Un tel bloc de couches s'appelait un module Inception [56].

De plus, GoogleNet a abandonné l'utilisation d'une couche entièrement connectée à la fin du réseau, utilisant à la place la couche de regroupement moyen, ce qui a considérablement réduit le nombre de paramètres dans le réseau. Ainsi, GoogleNet, composé de plus d'une centaine de couches de base, possède près de 12 fois moins de paramètres qu'AlexNet (environ 7 millions de paramètres contre 138 millions) [50].

RMSprop : est un algorithme d'optimisation inédit conçu pour les réseaux de neurones, proposé pour la première fois par Geoff Hinton

#### **2.2.4.4. Réseau neuronal convolutif ResNet**

Le vainqueur du concours ILSVRC 2015 avec une erreur de 3,57% était un ensemble de six réseaux de type ResNet (Residual Network), développé par Microsoft Research. Les auteurs de ResNet ont remarqué qu'avec l'ajout de nouvelles couches, la qualité du modèle atteint une certaine limite, puis commence à chuter. Ce problème est appelé le problème de dégradation, une diminution de la précision sur l'ensemble de validation. Les créateurs de cette architecture ont pu trouver une telle topologie dans laquelle la qualité du modèle croît avec l'ajout de nouvelles couches [57].

### **3. Apprentissage par transfert**

L'apprentissage par transfert est une méthode d'apprentissage automatique dans laquelle un modèle déjà développé pour une tâche est réutilisé comme point de départ d'un autre modèle pour une seconde tâche, il s'agit d'une situation où ce qui a été appris dans un contexte est exploité pour améliorer la généralisation dans un autre contexte.

Cette pratique est motivée par les vastes ressources de calcul et de temps nécessaires pour développer des modèles de réseaux neuronaux, ainsi que l'indisponibilité des jeux de données volumineux et stimulants sur lesquels les modèles d'apprentissage en profondeur sont formés. Ainsi, l'apprentissage par transfert servira à améliorer les performances d'un modèle dans une nouvelle tâche par le transfert des connaissances déjà apprises d'une tâche connexe [58].

En ce qui concerne le domaine des réseaux de neurones, [59] expliquent que l'apprentissage par transfert se fait en formant d'abord un réseau (A) sur un jeu de données source pour effectuer une tâche source, puis les fonctionnalités et les caractéristiques apprises seront transférées vers un réseau (B) qui sera formé sur un jeu de données cible et une tâche cible qui peuvent être différents des sources. Ce processus aura tendance à fonctionner si les caractéristiques apprises du réseau (A) sont générales, c'est-à-dire adaptées aux tâches sources et aux tâches cibles, au lieu d'être spécifiques aux tâches sources.

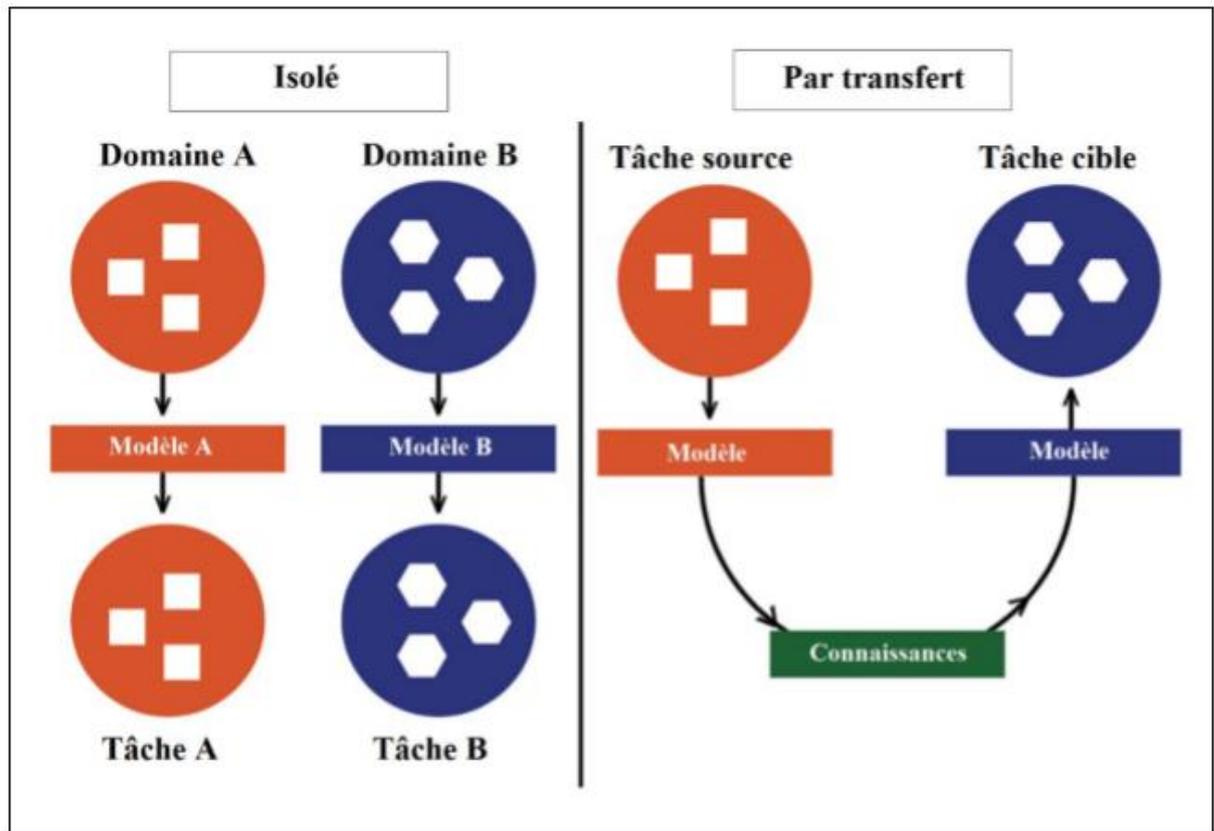


Figure 3.19: Apprentissage isolé et apprentissage par transfert [60]

## Impact de l'apprentissage par transfert

L'utilisation de l'apprentissage par transfert se fait essentiellement pour améliorer les performances d'un modèle et de ne pas souffrir du manque de données nécessaire pour son entraînement.

Plusieurs autres avantages peuvent être cités :

- **Départ plus élevé** : La performance initiale du modèle, sans avoir à le ré entraîner à nouveau, est supérieure que ce qu'elle serait sans transfert d'apprentissage.
- **Pente plus élevée** : Le taux d'apprentissage du modèle lors de l'entraînement est plus élevé ce qui rend sa convergence plus rapide.
- **Asymptote plus élevée** : L'entraînement converge vers des valeurs plus optimales.

Cependant l'apprentissage par transfert peut être néfaste, dans certains cas cette méthode serait un frein lors de l'entraînement et aurait pour effet de diminuer considérablement la performance du modèle. Ce phénomène est appelé « Transfert négatif ».

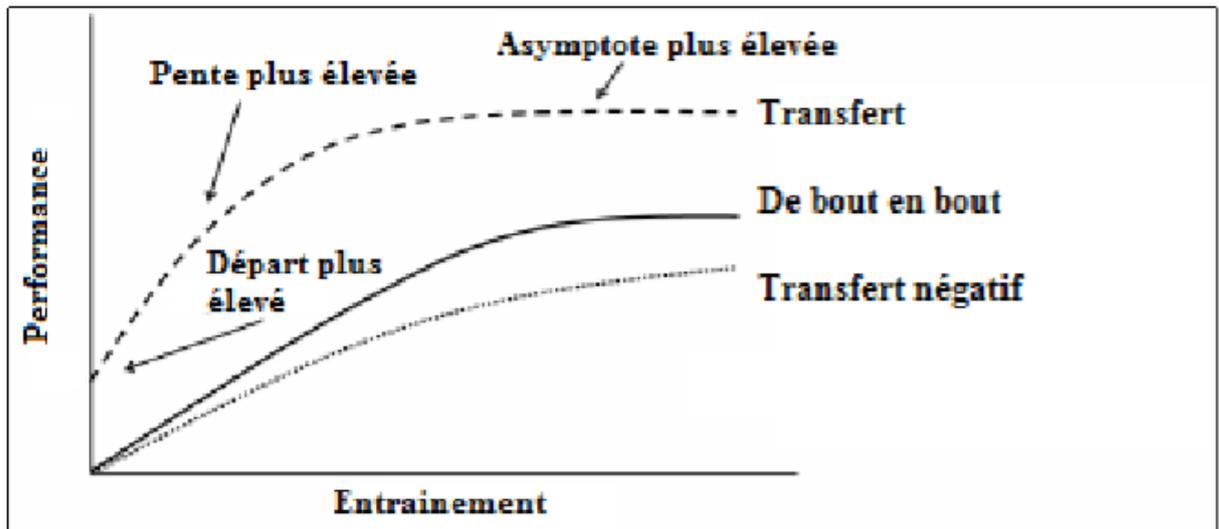


Figure 3.20: Les effets d'un apprentissage par transfert [61]

Ainsi, il est nécessaire de choisir avec soin la quantité de modèle pré-entraîné à utiliser dans le nouveau modèle.

Nous présenterons dans les prochains paragraphes les travaux faites dans le domaine de la gestion des catastrophes naturelles ainsi que les méthodes permettant de les prévenir.

#### 4. Revue sur quelques travaux connexes

Grâce à la précision de leurs informations les images satellitaires sont utilisées dans plusieurs domaines y compris dans la gestion des catastrophes naturelles, pour cela nous présentons quelques travaux Qui se sont intéressés à l'étude des dommages causés aux structures à la suite d'une catastrophe naturelle.

##### a) Détection et classification automatique de bâtiments endommagés à l'aide d'une imagerie satellite haute en utilisant un réseau neuronal artificiel

L'approche proposée par cette étude, consiste à utiliser des images satellitaire à haute résolution prise des satellites IKONOS et QuickBird et une carte vectorielle, afin d'avoir des informations précise et complète de l'état des différents bâtiments après un tremblement de terre. Dans ce travail, on obtient des images satellites pré-événement et post-événement des bâtiments. En mesurant et en comparant différentes caractéristiques texturales des bâtiments extraits dans les deux images en utilisant des algorithmes d'extraction de propriétés (features extraction), les conditions des bâtiments sont évaluées via un système d'inférence floue (fuzzy inference system). Une précision de classification globale de 74% est acquise [62].

**Fuzzy inference :** Un système d'inférence neuro-floue adaptative ou système d'inférence floue basé sur un réseau adaptatif est une sorte de réseau neuronal artificiel qui est basé sur le système d'inférence floue Takagi-Sugeno. La technique a été développée au début des années 1990.

## **b) Détection de dommages aux bâtiments en imagerie satellite à l'aide de réseaux de neurones convolutifs**

Dans ce travail, ils utilisent l'apprentissage automatique pour automatiser la détection des dommages aux bâtiments en imagerie satellite. Ils comparent les performances de quatre modèles de réseaux de neurones convolutifs différents dans la détection des bâtiments endommagés dans le tremblement de terre de Haiti. En utilisant une architecture AlexNet les résultats obtenus étaient peu concluant à cause d'un manque de données sur l'évènement choisi [63].

## **c) Quantification de dégâts sur les structures liés aux catastrophes majeures par images satellite multimodales très haute résolution**

Ce Travail est appliqué à différents types de catastrophes telles que tremblements de terre, explosions et plusieurs bombardements. Le résultat apparaît après une analyse visuelle des images qui montre les dommages liés à des catastrophes telles qu'un tsunami ou un cyclone. L'efficacité de ce travail n'est testée que sur les catastrophes mentionnées.

La méthode proposée résout le problème des changements d'angle d'acquisition. Cette méthode de recalage permet de faire correspondre les toits des bâtiments en deux images, et ainsi de donner un sens à une analyse de leur évolution. Enfin, à partir des caractéristiques extraites de la toiture, un degré d'endommagement est associé à chaque bâtiment afin de l'utiliser pour assurer une classification supervisée. Le résultat de ce travail permet un taux maximum de bonne classification de 89 % [17].

## **d) Contribution des Données Optiques au Traitement Multi-sources des Désastres Naturels**

Une méthode proposée dans ce travail, qui consiste à mettre en place un processus de classification automatique multi-source des images optiques pour faciliter la gestion des catastrophes naturelles. Ce travail contient quatre objectifs principaux

- Montrer la contribution des informations de télédétection dans la gestion des catastrophes naturelles.
- Choisir une nouvelle source d'information pour améliorer la classification purement spectrale.
- Choisir une méthode heuristique inspirée d'un système de classification naturel adapté à un système de classification d'images.
- Créer un processus de classification automatique, basé sur la méthode Harmony Search (HS), pour traiter cet ensemble de données multi-sources.

Les expériences faites sur cette thèse ont été testées sur deux types de catastrophes dont le premier est le tremblement de terre de Boumerdes Algérie et le deuxième est le tsunami de Sumatra Indonésie [15].

## **5. Conclusion**

Dans ce chapitre, nous avons exploré les différentes méthodes d'apprentissage ainsi que les principales notions qui gravitent autour des réseaux de neurones.

Les notions expliquées dans ce chapitre ne sont pas si récentes qu'on peut le croire car elles datent des années 90. Ce qui a rendu leur utilisation possible et de plus en plus fréquente cette

dernière décennie, est la disponibilité gigantesque de données, et le matériel de pointe pouvant effectuer des calculs de masse en un court laps de temps.

Par la suite, nous avons exposé les architectures type d'un Réseau de neurone convolutif en présentant chaque couche qui le compose et en expliquant soigneusement l'utilité de chacune. A travers nos recherches, nous avons déduit que ce qui fait la popularité des Réseaux de neurones convolutif est l'automatisation de la phase de détection des caractéristiques. Là où les méthodes conventionnelles de traitement d'images nécessitent des experts pour les extraire, les CNNs le font automatiquement grâce à leurs architectures.

Aussi, nous avons introduit la notion d'apprentissage par transfert, qui sera utilisé par la suite lors de ce projet.

Pour finir, Les lectures que nous avons faites concernant d'autres travaux qui se rapprochent de notre sujet, elles nous ont permis de nous immerger dans notre sujet, afin de mieux comprendre la problématique à résoudre, nos besoins en matière de ressources ainsi que les solutions déjà proposées par plusieurs chercheurs dans le monde.

Dans le prochain chapitre nous allons exploiter toutes les notions étudiées afin de réaliser notre projet.

---

# **Partie 02**

# **Contribution**

---

---

# **Chapitre 4**

# **Conception**

---

L'objectif principal du travail actuel est d'exploiter les images satellitaires en appliquant les techniques de l'apprentissage profond pour faire une classification qui aidera à la gestion des catastrophes naturelles.

Dans ce chapitre nous allons présenter les différentes méthodes de conception entreprise pour réaliser l'objectif déjà mentionné d'une manière explicite.

## 1. Démarche de conception

Une fois le système à concevoir délimité et les principales lignes directrices établies, nous devons nous baser sur une méthodologie pour pouvoir concevoir une solution adaptée pour ce dernier. La méthodologie choisie doit répondre à la nature du problème abordé et doit-nous faciliter l'approche avec laquelle nous entamons la conception de la solution.

Pour le système entrepris dans cette étude nous avons opté pour l'utilisation de la méthode CRISP-DM, celle-ci va être brièvement présentée dans ce qui va suivre.

## 2. CRISP-DM

La méthode CRISP-DM (Cross Industry Standard Process for Data Mining) conçue par IBM dont l'utilisation est très répandue dans les domaines présentant un usage de traitement de données. Elle se présente comme une méthode itérative offrant la possibilité de visualiser l'intégralité du cycle de vie des données [67].

La méthode CRISP-DM, se décompose en six étapes illustrées dans la Figure suivante.

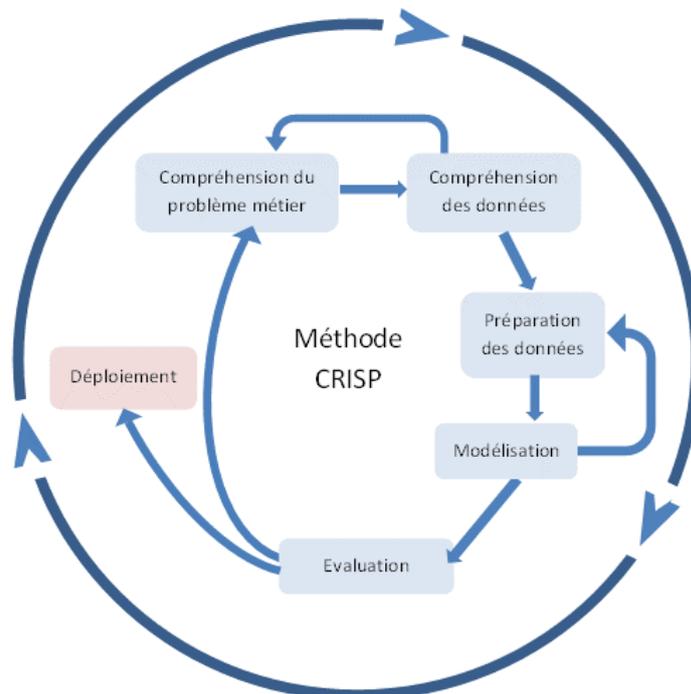


Figure 5.1: schéma représentant la méthode CRISP-DM [66]

- Compréhension du problème : Cette étape consiste à obtenir la meilleure compréhension possible des objectifs voulant être atteints.
- Compréhension des données : La phase de compréhension des données de CRISP-DM implique l'étude des données disponibles afin d'éviter toute complication liée aux données dans les prochaines opérations.
- Préparation des données : Cette partie consiste en la création d'un jeu de données en passant par leurs acquisitions, nettoyages, traitements et étiquetages, augmentation, normalisation.
- Modélisation : Ici, il est question des choix techniques et des configurations des modèles proposées. Souvent, cette étape s'effectue sur plusieurs itérations en revenant à la phase de préparation des données pour effectuer les modifications jugées nécessaires pour améliorer la performance des modèles.
- Evaluation : Durant cette étape, nous mesurons quantitativement les performances de chaque modèle réalisé en utilisant un nouveau jeu de données sur lequel il n'a pas été entraîné.
- Déploiement : c'est la phase finale de la méthode CRISP-DM, l'étape de déploiement consiste à employer notre système dans un cadre d'utilisation bien définie afin d'analyser les résultats obtenus et discuter les possibles perspectives et améliorations qui peuvent être apportées.

La méthode CRISP-DM nous a permis de structurer notre conception notamment en mettant à l'évidence les interactions qui peuvent exister entre les différentes étapes. Notamment entre la modélisation et la préparation de données, mais aussi l'étape d'évaluation et déploiement que nous allons voir dans le chapitre suivant.

## **2.1. Compréhension du problème**

Pour avoir une bonne étude du problème il faut qu'on établisse une relation entre notre objectif, le besoin du domaine d'application et nos ressources.

Comme nous l'avons indiqué précédemment notre objectif est d'exploiter les images satellitaires par les techniques d'apprentissage profond pour aider à la gestion des catastrophes naturelles.

D'après les informations acquises dans le chapitre des catastrophes naturelles, les besoins varient au fil du temps et selon le type de la catastrophe.

Pour cela trois points importants sont à connaître rapidement par les spécialistes. Ces points sont représentés dans l'état des réseaux routiers, l'état des réseaux d'énergie et d'eaux, et les zones les plus affectées afin de cibler l'intervention des secours. Donc notre contribution ira vers la résolution de l'un de ces trois points pour aider les spécialistes à gérer la catastrophe.

Dans ce qui suit nous allons voir les données dont nous disposons et la façon de les exploiter afin de proposer une solution optimale et efficace à ces problèmes.

## **2.2. Solution proposée**

Après avoir étudié la problématique nous sommes maintenant prêt à proposer une solution qui aidera à évaluer la situation dans les zones sinistrées.

Nous proposons un système qui se compose de deux sous-systèmes, le premier permet une classification des images satellitaires en utilisant un modèle de classification qui prend

comme entrée une image d'une zone affectée par une catastrophe naturelle, pour prédire si la zone est endommagée ou pas. Ce sous système est nommé « **analyse par zone** ».

Le second donne une analyse plus approfondie de la zone, cela se fait par une localisation de toutes les structures (bâtiments) à l'aide d'un modèle de segmentation, ces structures seront ensuite classifiées en quatre classes : Non endommagée, dommage mineur, dommage majeur, structures détruites. Ce sous système est nommé « **analyse par structure** ».

Dans les prochains paragraphes nous allons voir les différentes étapes de conception des deux solutions (sous-systèmes) qui composent notre logiciel.

### **2.3. Compréhension des données**

Afin de réaliser un système basé sur les technologies de l'apprentissage profond nous avons impérativement besoin d'une base de données volumineuse pour avoir un bon résultat et des prédictions précises qui nous permettront à la fin de classifier nos images.

Pour réaliser notre système nous allons utiliser deux bases de données. Nous allons utiliser ces deux bases de données pour leurs caractéristiques.

#### **a) Base de données « IEEE DataPort »**

Les données utilisées ici représentent des images satellites du Texas, état unis d'Amérique, après le passage des catastrophes naturelles.

La base de données contient plus de 23 000 images, ces images sont composées de structures (bâtiments, routes, ponts ...) divisées en deux catégories **endommagées et non endommagées**. Cette base de données mise à disposition dans le site web Kaggle tiré du site web IEEE DataPort qui met à disposition plusieurs bases de données dans différents domaines.

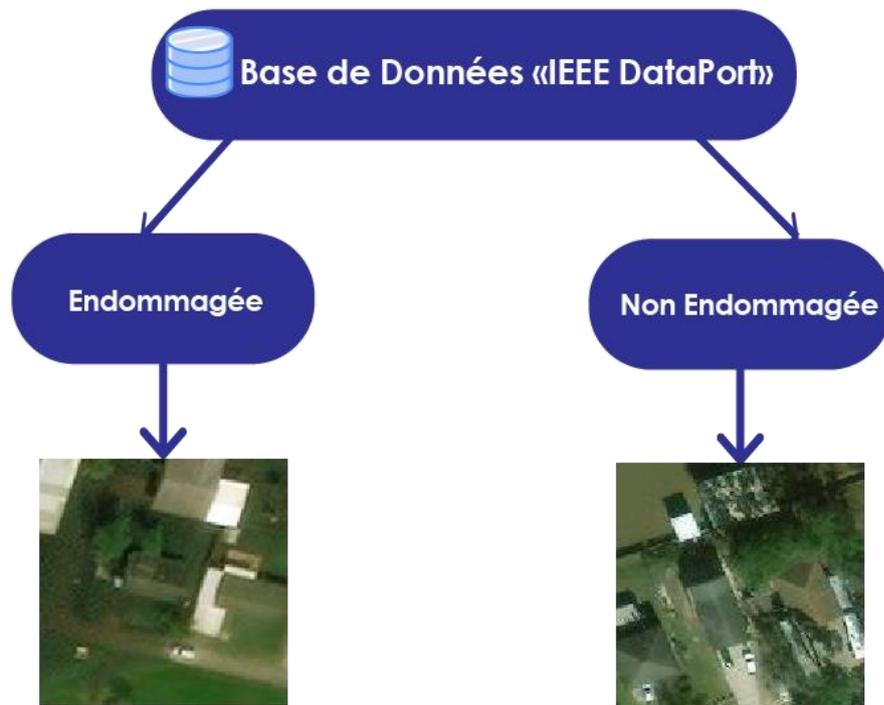


Figure 5.2: schéma représentant la base de données utilisée

### b) Base de données Xview2

« Xview2 » est un ensemble de données à grande échelle dédié pour la détection et l'évaluation des dommages des bâtiments après une catastrophe précise. Cet ensemble de données a été collecté en 2019 dans le but de donner les informations nécessaires sur les structures d'une zone précise.

Cette base de données est de taille «29.2 Go», elle contient un ensemble d'images paires de haute qualité pour des zones : pré et post catastrophe (sous format png) avec leurs annotations. Les images pré catastrophes sont les images capturées dans le cas où la zone a été intacte. Par contre les images post catastrophe sont les images capturées juste après que la catastrophe a endommagé la zone et ces structures.

Les images de la base de données sont présentées comme suit



Figure 5.3: deux images satellitaires représentant post et pré catastrophe prise de la base de données xview2

Ces images sont collectées dans des zones touchées par 6 types différents de catastrophes (inondation, volcan, hurricane, séisme, tsunami, incendie) avec une surface de 45 361 Km<sup>2</sup> qui contiennent 850 736 structures (bâtiments).

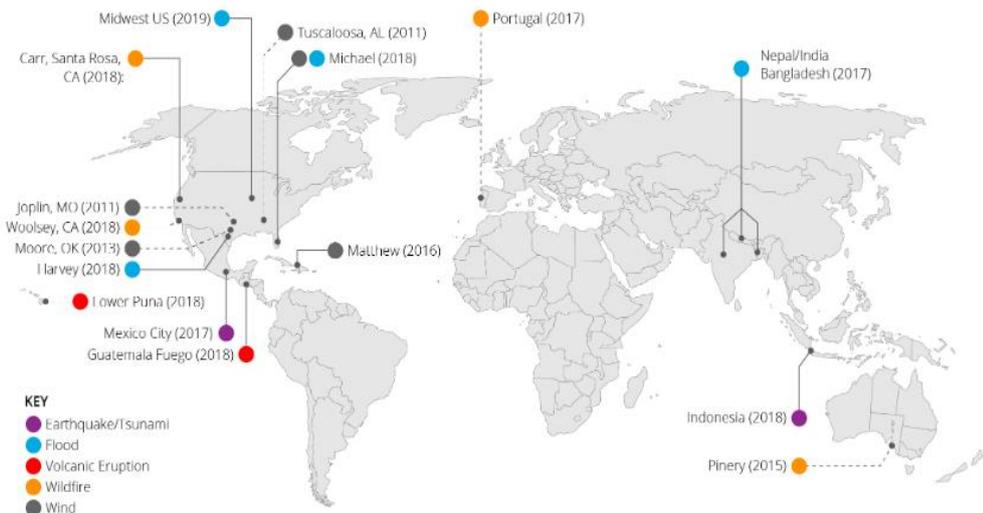


Figure 5.4: illustration montrant les lieux d'où les données de xview2 sont prises [67]

- **Les annotations (étiquettes)** définissent le degré d'endommagement des bâtiments (quatre classes : non endommagé, endommagement mineur, endommagement majeur, bâtiments détruits), les coordonnées de chaque structure (des polygones sous format wkt) et des métadonnées pour la vue donnée dans l'image.

Voici un exemple des informations situées dans les annotations

```

{"features":
  {"lng_lat":
    [{"properties":
      {"feature_type": "building",
    {"subtype": "no-damage",
    {"uid": "8c96d587-4802-4fe9-8820-4d9bdbeccfee"},
    {"wkt": "POLYGON ((-79.04684729170944 33.61651853664
  
```

Figure 5.5: les annotations des données

Les annotations sont représentées par des fichiers texte chaque fichier contient les informations d'une image. Nous allons expliquer les informations numérotées comme suit:

- **feature-type** : représente si l'objet qui le décrit est une structure ou pas.
- **subtype** : représente la classe d'endommagement d'un bâtiment.
- **uid** : représente l'identifiant du bâtiment.
- **wkt** : représente les coordonnées du bâtiment

**Remarque :** L'annotation contient ces informations pour chaque structure dans l'image.

## 2.4.Préparation des données

### 2.4.1. Nettoyage des données

Lors de cette étape, il est question d'épurer les deux bases de données utilisées auparavant. Souvent il s'agira d'élire les données à garder dans notre jeu de données et celles qui seront supprimées. Pour ce faire, nous allons établir des conditions de sélection qui sont :

- Eviter le maximum d'images qui ne contiennent aucune structure même si elle est soumise au phénomène étudié ici (catastrophe naturelle)

- L'image doit être claire c'est-à-dire qu'on peut distinguer les différentes structures dans l'environnement ou la zone choisie.
- Eliminer toutes images qui manquent de visibilité causée par une interférence naturelle (tel que l'apparition de forme nuageuse ou un écran de fumé ...)

## **2.4.2. Traitement des données**

Dans cette étape nous cherchons à préparer et optimiser nos données pour que notre modèle puisse non seulement avoir accès aux images, mais puisse aussi tirer les meilleurs résultats possibles. Dans ce qui va suivre nous allons voir la conception de cette phase pour les deux bases de données utilisées ici.

### **a) Traitement des données « IEEE DataPort »**

En premier lieu est afin de bien exploité nos données nous avons opté pour un fractionnement qui nous permettrons de les utilisées dans l'étape d'entraînement et test.

Comme présenté dans le chapitre 3, afin d'obtenir des modèles pouvant être capables de se généraliser aux nouvelles données et présenter de très bonne performance de prédiction ou de classification, il est primordial de disposer d'un jeu de données riche et volumineux. Pour assurer ces critères, nous avons utilisé une augmentation de données. Il sera question d'appliquer des transformations à nos données qui nous permettront d'accroître leurs nombres sans pour autant fausser la classification des nouvelles données générées.

A la fin de cette étape nous allons obtenir des données bien organisé utilisable pour la phase d'entraînement et test.

### **b) Traitement des données « Xview2 »**

Dans cette section nous allons traiter les données de « xview2 » afin de les utilisées pour créer la deuxième solution « analyse par structure » déjà mentionné dans ce chapitre. Pour cela nous devons passer par plusieurs étapes pour assurer le bon déroulement du processus.

Pour assurer la localisation des bâtiments en exploitant la base de données « xview2 » nous devons l'organiser d'une manière ou nous ferons un ensemble des images pré-catastrophes et un autre ensemble de post catastrophe appart. Après cette étape nous devons fractionner l'ensemble des images post catastrophe en trois pour que nos données soient prêtes. Ensuite nous allons opter pour faire une augmentation de données pour qu'on puisse traiter plus de cas de notre étude.



Figure 5.6: Processus de traitement des données pour la localisation

Concernant la classification des bâtiments nous allons créer une base de données en exploitant les images de la base de données « xview2 » et leurs annotations pour générer une base de données qui contient seulement des images des bâtiments étiquetés. Enfin nous allons augmenter les données pour qu'on peut traiter des cas en plus dans l'étude.

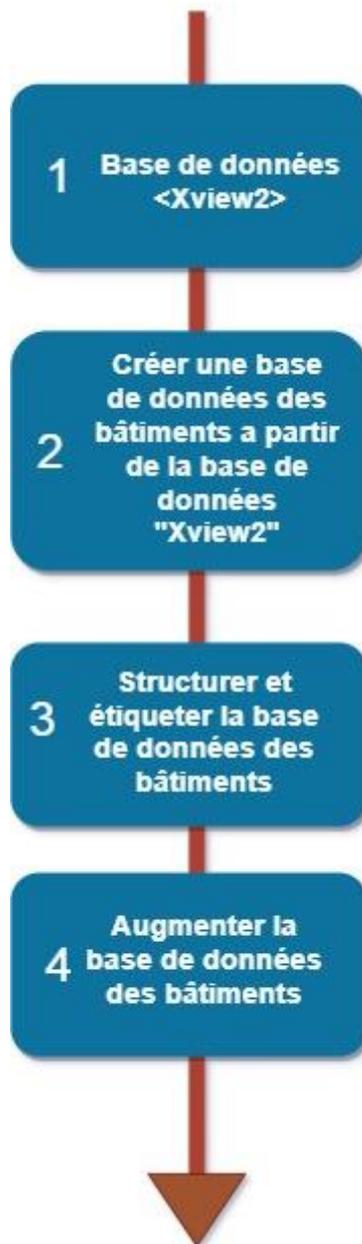


Figure 5.7: Processus de traitement des données pour la classification

**Remarque :** Les étapes réalisées dans le traitement des deux bases de données peuvent sembler similaires, cependant elles se feront d'une manière différente. Ainsi ces étapes seront détaillées dans le chapitre implémentation.

## 2.5. Entraînement des modèles

Les modèles de l'apprentissage profond qu'on doit créer représentent le noyau de notre système. Pour que ces modèles soient prêts à assurer leurs travaux dans notre système, il faut qu'ils se développent au fur et à mesure en utilisant les données jusqu'à ce que leurs résultats soient satisfaisants.

Lorsque les résultats des modèles soient dans le niveau d'assurer le travail nous pouvons dire que la phase de l'entraînement est passée avec succès.

Dans cette partie nous allons voir les modèles adaptés à nos deux Solution.

### **2.5.1. Modèles utilisés dans la solution par zone**

Comme nous l'avons déjà mentionné la solution par zone a pour but de classifier une donnée (image) en deux classes endommagée ou non endommagée, en utilisant une image satellitaire en entrée et un modèle de classification qui va assurer la prédiction sous forme de classes mentionnées précédemment.

Avant de procéder à l'entraînement d'un modèle, il faut au préalable définir son architecture. Nous allons utiliser des architectures des réseaux de neurones convolutifs répondue dans la classification des images telles que VGG et Resnet.

Ces architectures vont être personnalisées pour qu'elles soient adaptées à nos données préalablement préparé.

### **2.5.2. Modèles utilisés dans la solution par structure**

Le fonctionnement de la solution par structure est récapitulée dans le fait d'appliquer un modèle de segmentation sur une image satellitaire pour détecter les bâtiments et les extraire afin de les classifié en quatre classes : non endommagé, dommage mineur, dommage majeur, structure détruite.

Donc d'après ce qu'on a vu nous allons utiliser un modèle de segmentation et un autre de classification.

#### **a) Modèle de segmentation**

Pour pouvoir localiser les structures (bâtiments) dans une image de zone nous allons adapter une architecture adéquate à notre situation nommé Unet, cette dernière qui fait partie des architectures des réseaux de neurone entièrement convolutif, elle est utilisée pour assurer la segmentation sémantique dans nos images.



Figure 5.8: illustration qui représente la segmentation sémantique en utilisant Unet

## **b) Modèle de classification**

Pour ce qui est de la classification des images nous allons utiliser le modèle Resnet de la même manière que celle citée dans le système de classification par zone sur la base de données des bâtiments que nous avons généré dans la section traitement de données (2.4.2), hormis que les sorties proposées ici se divisent en quatre classes bien distinctes (Non endommagés, Dommage Mineur, Dommage Majeur, bâtiments détruits).

### **2.6.Évaluation du modèle**

Une fois le modèle entraîné, il sera question d'évaluer ses performances sur un nouveau jeu de données dit « Jeu de test ». Ces données-là n'ont pas été incluses lors de l'entraînement, et seront utilisées pour pouvoir affirmer qu'un modèle se généralise bien ou au contraire souffre de sous apprentissage ou de sur apprentissage.

Les outils utilisés lors de l'évaluation sont principalement les matrices de confusion qui servent à décrire les performances d'un modèle de classification sur un ensemble de données de test pour lequel les valeurs vraies sont connues. Utilisée souvent pour une classification binaire sous la forme matricielle.

Au terme de cette évaluation, nous pouvons considérer qu'un modèle est performant et ainsi l'exporter et l'archiver, ou bien insatisfaisant et dans le cas échéant réitérer l'étape d'entraînement avec une nouvelle architecture du réseau ou une autre configuration.

### **2.7.Exportation du modèle**

Une fois que nous sommes assurés que le modèle entraîné répond à nos attentes, nous serons en mesure de l'exporter et l'archiver pour une utilisation ultérieure ou bien pour être déployé dans un système afin d'être utilisé par les personnes concernés. L'exportation d'un modèle consiste en la sauvegarde dans un fichier de son architecture ainsi que de tous ses poids et paramètres.

## **3. Conclusion**

Dans ce chapitre nous avons expliqué tout ce qui concerne la conception de notre système, les méthodes utilisées et les résultats voulus.

Nous avons présenté les étapes de conception qui vont nous permettre de réaliser les deux solutions différentes qui traitent notre sujet et répond à ses exigences. Ces deux solutions ont des méthodes de réalisation différentes et donnent des résultats distincts.

Dans le prochain chapitre nous allons voir les démarches d'implémentation de notre système et discuter les résultats obtenus par ces solutions.

---

# **Chapitre 5**

## **Implémentation et Tests**

---

Après avoir achevé la conception de notre système. Il est temps de concrétiser notre contribution en implémentant notre système pour qu'il soit prêt à être utilisé par les acteurs concernés.

Le but de notre système est de donner les informations nécessaires aux personnes qui doivent assurer les secours afin qu'il puisse préparer un plan d'intervention le plus rapidement possible.

Dans ce chapitre nous allons présenter les outils utilisés dans le développement, les fonctionnalités incluent dans le prétraitement des données et la modélisation de nos modèles ainsi que l'implémentation de ces derniers. Nous allons aussi présenter le système final et leurs interfaces afin d'introduire la méthode d'utilisation du logiciel. Pour finir nous allons voir et discuter les résultats obtenus et mesurer leurs fiabilités grâce aux tests réalisés.

## **1. Matériels et outils**

Pour développer notre système nous avons utilisé le matériel et les logiciels suivants :

### **1.1. Matériels utilisés**

Nous avons travaillé sur nos ordinateurs personnels. Les informations suivantes représentent la configuration du matériel utilisé.

#### **a) Ordinateur personnel 1**

Processeur: Intel(R) Core(TM) i5-5200 CPU @ 2.20 GHz 2.20 GHz

RAM: 8,00 Go

#### **b) Ordinateur personnel 2**

Processeur: Intel(R) Core(TM) i3-4005U CPU @ 1.70 GHz 1.70 GHz

RAM: 4,00 Go

### **1.2. Outils de développement**

Pour la mise en œuvre des différentes étapes discutées, nous avons opté pour des outils répandus, des technologies reconnues et des versions stables. Dans l'ensemble, nous nous sommes basés sur l'utilisation des technologies nous permettant de concevoir, d'implémenter et de tester nos réseaux de neurones convolutifs. Nous parlons aussi des outils que nous utilisons pour la réalisation des IHM et des interfaces graphiques. Nous évoquons les services en ligne qui nous permet l'échange de nos états d'avancement.

### a) Langage Python

Python est un langage de programmation interprété, multi-paradigme et multiplateformes. Il favorise la programmation impérative structurée, fonctionnelle et orientée objet. Il est doté d'un typage dynamique fort, d'une gestion automatique de la mémoire par ramasse miettes et d'un système de gestion d'exceptions. Python est un langage qui peut s'utiliser dans de nombreux contextes et s'adapter à tout type d'utilisation grâce à des bibliothèques spécialisées. Pour le développement de notre système nous avons utilisé la version 3.7 du python.

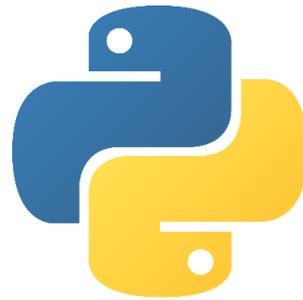


Figure 6.1: Logo Python

### b) Anaconda

Anaconda est une distribution libre et open source des langages de programmation Python et R appliqué au développement d'applications dédiées à la science des données et à l'apprentissage automatique (traitement de données à grande échelle, analyse prédictive, calcul scientifique), qui vise à simplifier la gestion des paquets et de déploiement. Les versions de paquetages sont gérées par le système de gestion de paquets conda



Figure 6.2: Logo Anaconda

### c) La bibliothèque OpenCV

OpenCV (Open Source Computer Vision Library) est une bibliothèque de logiciels open source de vision informatique et d'apprentissage automatique. Elle a été conçue pour fournir une infrastructure commune aux applications de vision par ordinateur et pour accélérer l'utilisation de la perception de la machine dans les produits commerciaux.

La bibliothèque contient plus de 2500 algorithmes optimisés, qui incluent un ensemble complet d'algorithmes de vision par ordinateur et d'apprentissage automatique. Nous avons utilisé la version 4.0.0 d'OpenCV.



Figure 6.3: Logo OpenCV

### d) Tensorflow

TensorFlow est une bibliothèque de logiciels Open Source, développée à l'origine par Google Brain Team pour l'apprentissage automatique et la recherche sur les réseaux neuronaux profonds. TensorFlow regroupe une multitude de modèles et d'algorithmes d'apprentissage automatique et d'apprentissage profond. Il utilise Python pour fournir une API frontale pratique permettant de créer des applications structurées. Nous l'avons utilisé pour la conception de nos réseaux neuronaux. La version utilisée est '2.0.0'.



Figure 6.4: Logo Tensorflow

### e) Keras

Keras est une API de réseaux de neurones de haut niveau, écrite en Python et capable de s'exécuter sur TensorFlow. Elle a été développée pour permettre une expérimentation rapide, pouvoir faire de la recherche de qualité est essentiel pour pouvoir passer de l'idée au résultat le plus rapidement possible; Parmi les avantages de l'utilisation de Keras :

- Un prototypage simple et rapide (convivialité, modularité et extensibilité).
- Prendre en charge les réseaux convolutionnels et les réseaux récurrents, ainsi que les combinaisons des deux.
- Fonctionne de manière transparente sur le processeur et le processeur graphique.

#### f) NumPy

NumPy est un projet open source visant à permettre le calcul numérique avec Python. Il s'agit d'une bibliothèque Python qui fournit un objet de tableau multidimensionnel, divers objets dérivés (tels que des tableaux et des matrices masqués) et un assortiment de routines pour des opérations rapides. La version utilisée ici '1.19.1'.

#### g) Scikit-Learn

Scikit-learn est une bibliothèque d'apprentissage automatique gratuite pour Python. Elle comporte divers algorithmes tels que la machine vectorielle de support, les forêts aléatoires et les k-voisins, et elle prend également en charge les bibliothèques numériques et scientifiques Python comme NumPy. Son utilisation ici peut être résumée par le besoin de test grâce à la matrice de confusion. Nous avons utilisé la version '0.23.1'.

#### h) Google Drive

Google Drive est un service de stockage gratuit dans le cloud qui permet aux utilisateurs de stocker et d'accéder à des fichiers préalablement chargés en ligne. Le service synchronise les documents qui sont présents sur tous les appareils de l'utilisateur, ce qui permet un accès plus facile peu importe la plateforme. Nous l'avons utilisé pour y sauvegarder nos différents jeux de données créés ainsi que l'avancement de notre projet.

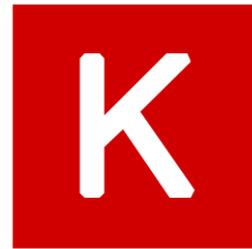


Figure 6.5: Logo Keras

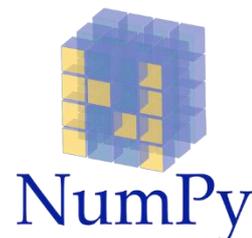


Figure 6.6: Logo NumPy



Figure 6.7: Logo Scikit-Learn



Figure 6.8: Logo Google Drive

### i) Colaboratory

Colaboratory, souvent raccourci en "Colab", est un produit de Google Research. Colab permet à n'importe qui d'écrire et d'exécuter le code Python de son choix par le biais du navigateur. C'est un environnement particulièrement adapté à l'apprentissage profond, à l'analyse de données et à l'éducation. En termes plus technique, « Colab » est un service hébergé de « notebooks Jupyter » qui ne nécessite aucune configuration et permet d'accéder gratuitement à des ressources informatiques, dont des GPU. Il offre un espace de plus de 76 gb en mode CPU et un espace de 36GB en mode GPU avec une durée de 12 heures.



Figure 6.9: Logo Colaboratory

### j) Qt

Qt pour Python est le projet qui fournit l'ensemble officiel de liaisons Python qui surchargeront vos applications Python. Qt est utilisé pour développer des interfaces utilisateur graphiques (GUI) et des applications multi-plateformes qui s'exécutent sur toutes les principales plates-formes de bureau et la plupart des plates-formes mobiles ou intégrées. La plupart des programmes GUI créés avec Qt ont une interface native, auquel cas Qt est classé comme une boîte à outils de widget. Comme son fonctionnement l'indique nous avons utilisé Qt pour développer notre interface graphique à l'aide de PyQt5 et Qt Designer.



Figure 6.11 Logo Qt

## 2. Implémentation du système

### 2.1. Préparation des données

Pour pouvoir entraîner notre modèle de réseau de neurone convolutif (CNN) plusieurs algorithmes de préparation de données ont été réalisés. Afin de mieux comprendre le côté pratique de notre projet, nous allons présenter dans ce qui suit plusieurs fonctionnalités qui composent l'étape de notre pré entraînement.

Pour la préparation des données nous allons traiter les deux bases de données qu'on a abordé dans le chapitre précédent.

#### 2.1.1. Traitement des données « IEEE DataPort »

##### a) Fractionnement des données

Cette étape consiste à créer trois ensembles différents de données entraînement, validation et tests, qui vont par la suite être utilisé dans plusieurs étapes au cours de la réalisation de notre système.

Les dossiers entraînement et validation qui contiennent des images satellitaire des zones endommagées et non endommagées séparément vont être utilisés pour l'entraînement de notre modèle de réseau de neurone, celle dans le dossier tests vont être utilisés pour évaluer les résultats obtenus lors de l'entraînement.

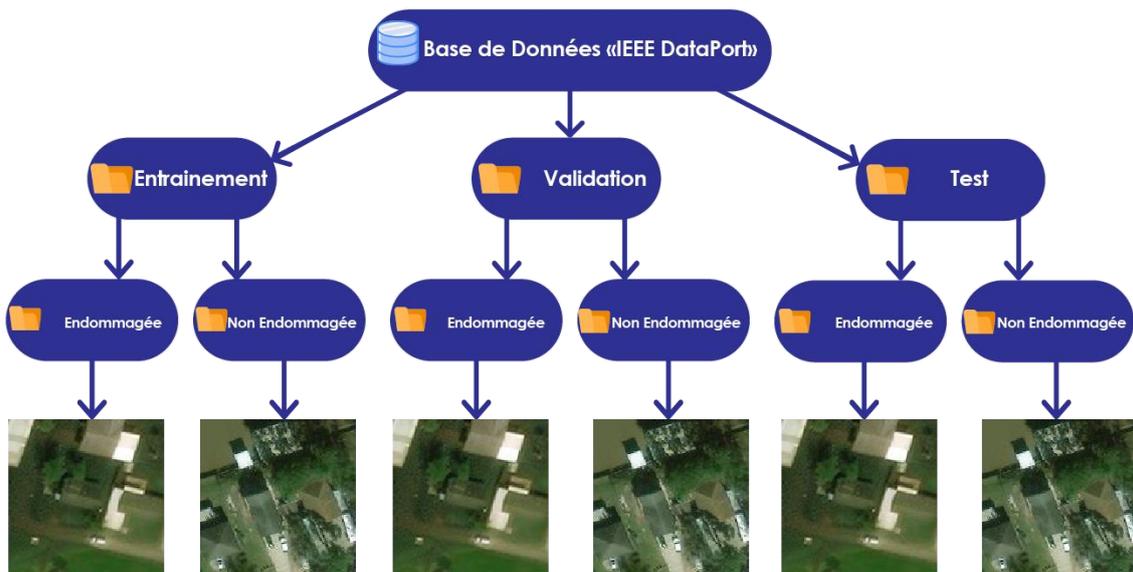
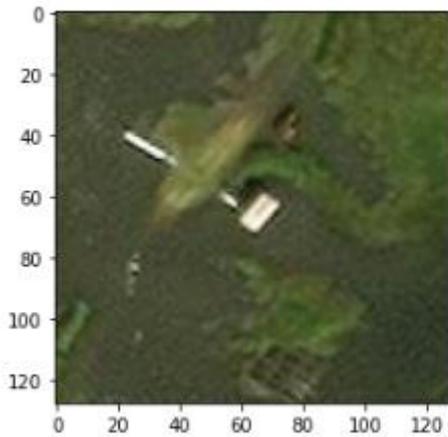


Figure 6.12: schéma représentant la fragmentation de la base de données

Afin d'effectuer ce travail nous allons fractionner la base de données originale sur les différents dossiers utilisés, ensuite nous intégrons les chemins de chaque dossier dans les étapes qui requièrent leurs utilisations (entraînement modèle, test d'évaluation).

```

Nombre D'images pour l'entrainement : 10000
Nombre D'images pour validation: 2000
Nombre de classe: 2
  
```



```

Nombre D'images pour Test: 2000
  
```



Figure 6.13: représentant les différents dossiers et leur contenu

### 2.1.2. Traitement des données « xvview2 »

Dans cette section nous avons effectué le traitement des données qui composent la base de données « xvview2 ». Comme mentionné dans le chapitre de conception cette phase a pour

but de préparer le terrain pour exploiter les données de la meilleure façon possible. Pour arriver à ce stade nous devons passer par plusieurs étapes. Ces étapes vont assurer le bon déroulement du processus.

Le traitement de cette base de données est réalisé pour deux objectifs :

- Préparation des données pour qu'elles soient prêtes à être utilisées par le modèle de localisation.
- Préparation des données pour qu'elles soient prêtes à être utilisées par le modèle de classification.

Dans les prochaines sections nous allons présenter l'implémentation des méthodes citées dans le chapitre précédent pour réaliser les objectifs attendus en utilisant des bibliothèques déjà expliqués dans ce chapitre.

## a) Préparation des données pour la localisation

### • Etape 01

Au début et comme première étape nous avons divisé la base de données en deux parties :

- L'ensemble des images pré catastrophe avec leurs annotations.
- Un autre ensemble qui contient les images post catastrophe avec leurs annotations.



Figure 6.14: schéma de la première étape de fractionnement des données

**Rappel :** La base de données « xview2 » contient des images pré catastrophes avec leurs annotations, et des images post catastrophes avec leurs annotations.

**Remarque :** Le but derrière cette fragmentation c'est qu'on va utiliser la partie post-catastrophe seulement pour reconnaître les structures dans la partie de localisation et la partie d'entraînement de classification. Les images pré-catastrophes contiennent seulement les bâtiments non endommagés ce qui n'assure pas un bon entraînement par contre les annotations des images post-catastrophe contiennent des bâtiments non-endommagés, avec endommagement mineur, majeur et structures détruites ce qui fait que notre modèle va être entraîné sur tous les types de structures.

- **Etape 02**

Ensuite comme deuxième étape nous avons organisé les résultats de la première étape de la même manière faite dans la base de données utilisée pour la première solution (création d'emplacement : entraînement, validation, test). Chacun d'entre eux contient trois autres dossiers (Images, Annotations, Masques) comme montré sur la figure ci-dessous.

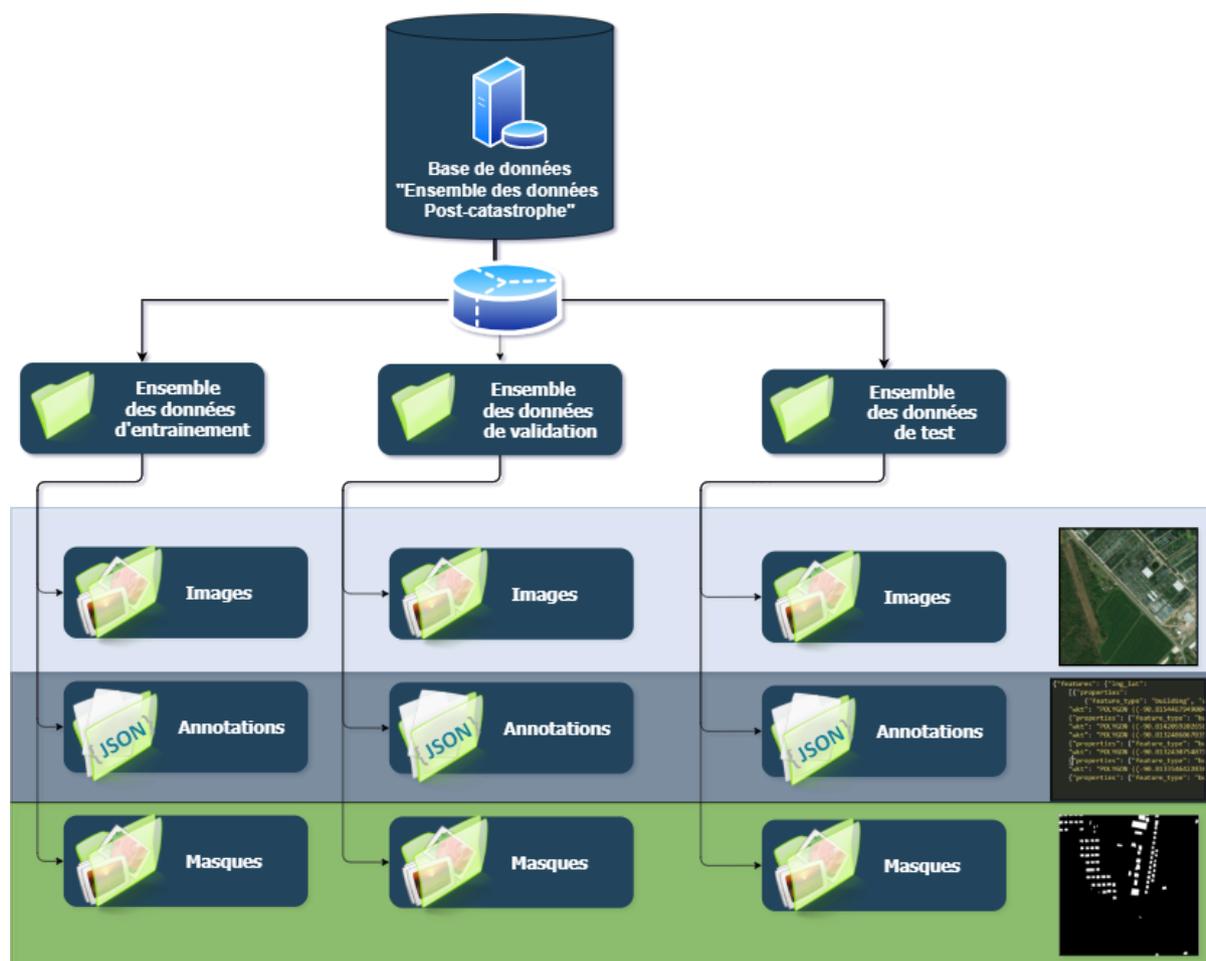


Figure 6.15: schéma de l'étape finale de fractionnement des données

- **Etape 03**

Enfin pour la dernière étape dans la préparation de la base de données nous avons rempli les dossiers « masque » en créant à partir des annotations présentes dans la base de données « xview2 » des images qui contiennent seulement les objets qu'on veut localiser dans l'image principale (bâtiments dans des images satellitaires). Comme nous avons déjà cité dans la partie bibliographique pour que le réseau de neurone améliore ses résultats il faut qu'il fasse une prédiction et compare son résultat obtenu avec le vrai résultat pour qu'il s'assure qu'il est dans le bon chemin ou bien il doit modifier les poids qui définissent ce résultat par la rétro-propagation. Dans la localisation le réseau de neurone va comparer le résultat obtenu avec les masques créés dans cette partie. Donc cette étape est très essentielle pour qu'on puisse entraîner notre modèle de localisation.

Les images du dossier « masque » sont représentées dans la figure suivante

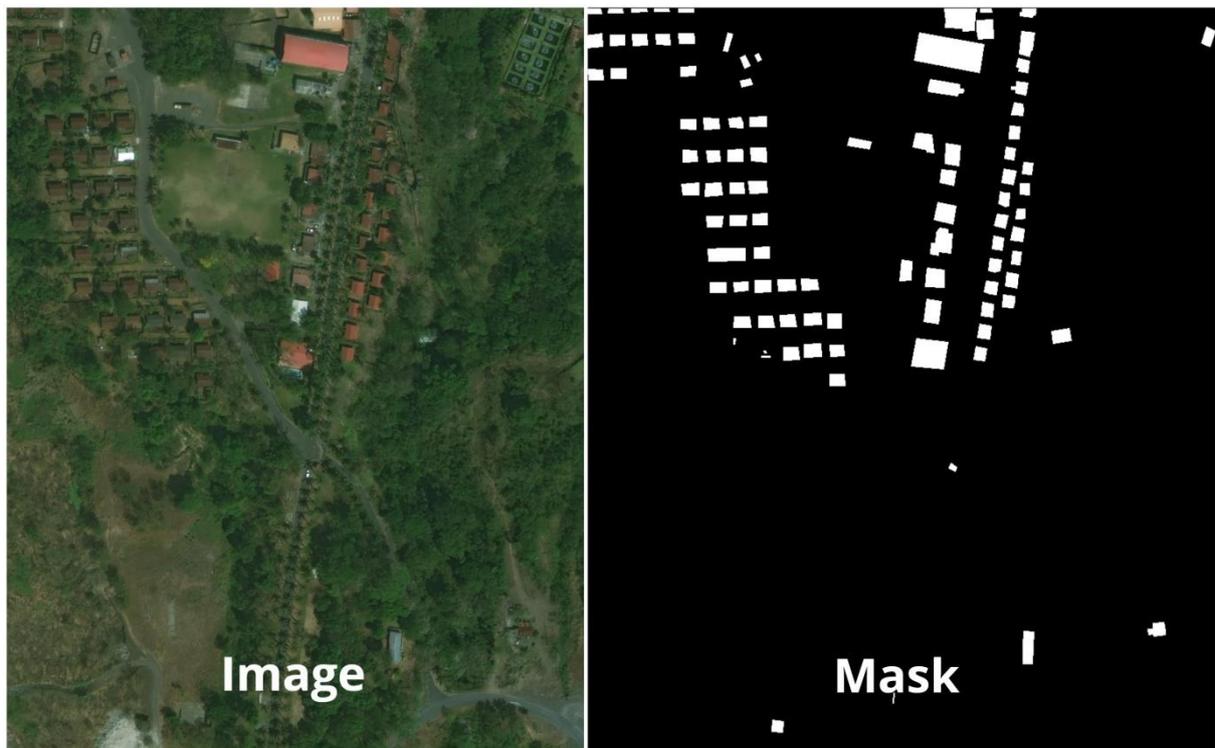


Figure 6.16: illustration qui représente une image et son masque.

**Masque :** Image qui contient seulement les objets qu'on veut les localiser dans l'image principale. Le masque est utilisé pour vérifier si le modèle a fait une localisation juste ou non dans l'image.

### **b) Préparation des données pour la classification**

Pour que nos modèles de classification soient performants dans la détection des endommagements liés aux bâtiments il faut les entraîner avec des images et des annotations qui définissent des bâtiments et leurs classes d'endommagement. Comme nous l'avons déjà

mentionné notre base de données contient des images des zones avec les informations des bâtiments dans chaque image (fichiers annotations).

Donc nous avons créé une nouvelle base de données étiquetée en utilisant la base de données « xview2 ». Dans cette étape nous avons procédé comme suit :

- Création de quatre emplacements (dossiers) chaque emplacement doit contenir les images d'une classe parmi les quatre classes utilisées pour la classification.
- Fractionner chaque image de zone en assurant l'extraction de chaque bâtiment dans une image séparée à l'aide des informations présente dans les annotations de la base de données « xview2 ».
- Le même algorithme utilisé dans l'opération précédente nous a assuré la sauvegarde de chaque image créée dans l'emplacement qui lui convient.

La structure sera comme le montre la figure suivante :

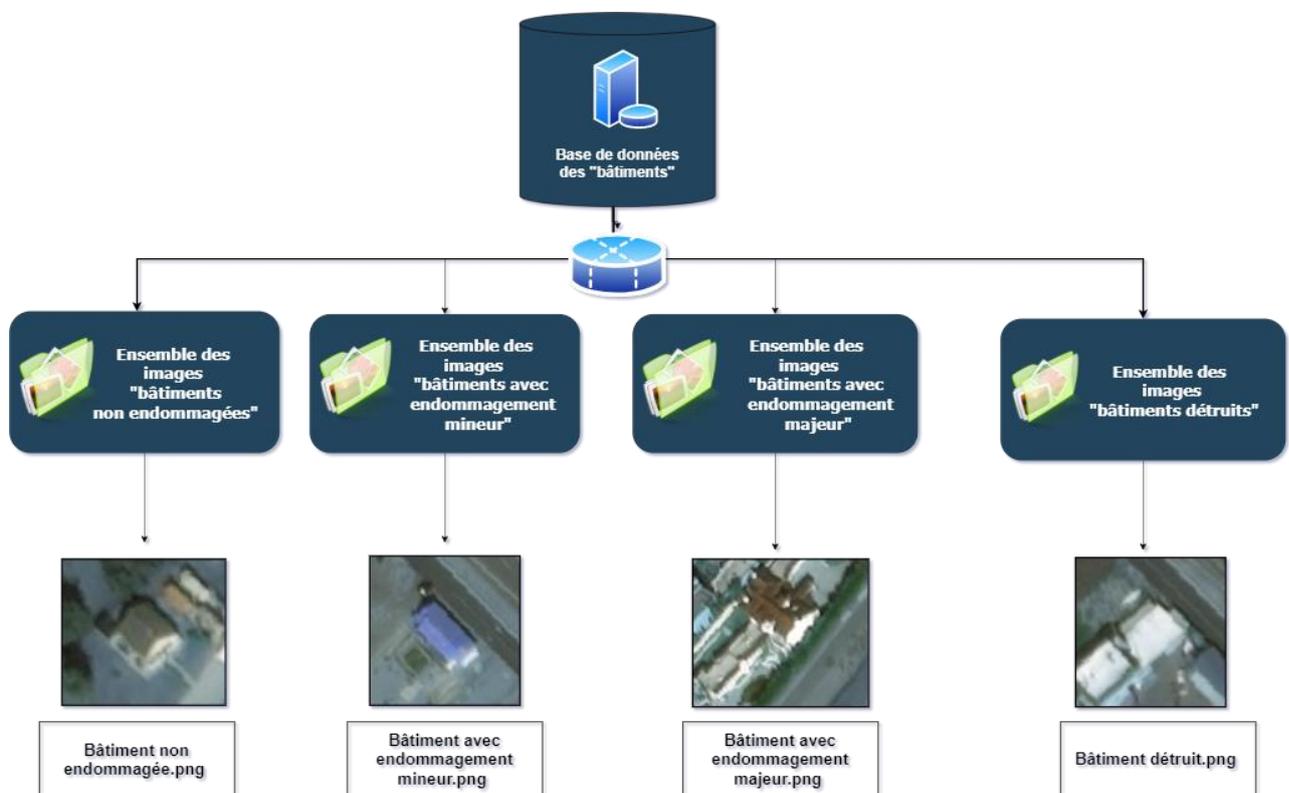


Figure 6.17: schéma qui représente la première étape dans la fragmentation des images post catastrophe pour la classification

Pour finir nous avons organisé notre base de données telle que nous l'avons fait auparavant en créant trois emplacements : entraînement, validation, test. Chaque emplacement doit contenir les quatre classes citées dans l'étape précédente (non endommagée, endommagement mineur, endommagement majeur, bâtiments détruits).

L'emplacement final des données sera comme montre la figure suivante

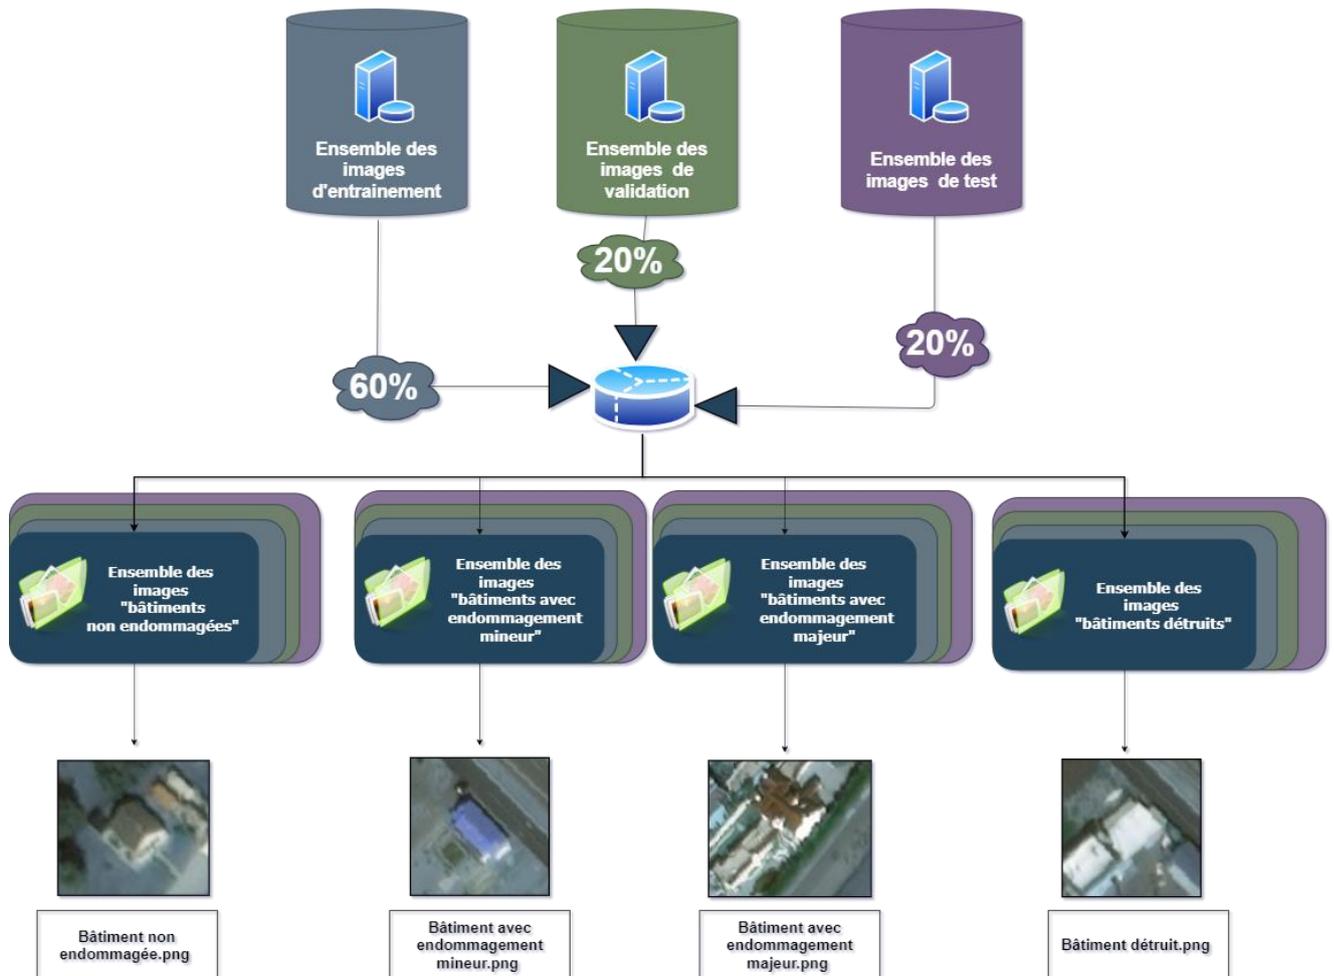


Figure 6.18: schéma qui représente l'étape final dans la fragmentation des images post catastrophe pour la classification

Avec cette étape nous pouvons dire que la structure de la base de données est prête. Dans les prochaines sections nous entamons le traitement des données pour une bonne efficacité des résultats.

### 2.1.3. Redimensionnement des données

L'une des étapes les plus importantes du processus de pré-entraînement est le redimensionnement d'image entrante. Cette étape va nous permettre de rendre toutes les images homogènes, nous avons appliqué un algorithme pour désigner une taille de 128\*128 pixel pour toutes les images destinées à l'entraînement de nos modèles.

### 2.1.4. Augmentation des données

Comme précisé dans le chapitre précédent pour réaliser une augmentation, il faut appliquer des transformations. Nous avons plusieurs paramètres tels que la rotation, décalage en largeur, décalage en longueur, cisaillement, retournement horizontal et verticale en utilisant les fonctions de pré-entraînement de la bibliothèque Keras introduite auparavant.

## 2.2. Modélisation des réseaux de neurones

Pour répondre aux besoins de nos solutions avec les meilleurs résultats possibles nous avons entraîné plusieurs modèles de réseaux de neurones.

Plusieurs paramètres ont été modifiés, afin d'optimiser cette phase et avoir de bons résultats. Les informations suivantes représentent les modifications appliquées.

### a) Modèle de classification VGG16

Déjà cité dans le chapitre précédent, le modèle VGG16 nous a permis de classer les images satellitaires par zone en deux classes **endommagée et non endommagée**. Ces deux classes représentent les sorties proposées par notre modèle de réseau de neurone convolutif.

Aussi nous avons modifié la couche d'entrée (input layer) pour qu'elle soit adaptée à nos données et ajouter des fonctions telle que :

- la fonction d'optimisation Adam avec un taux d'apprentissage de 0.00001 qui permet de rendre les résultats du processus d'apprentissage plus précis.
- La fonction de perte qui a pour but de calculer la valeur de perte qu'un modèle doit chercher à minimiser pendant l'entraînement.
- Ainsi que la fonction de métrique qui est similaire à la fonction de perte mais elle permette de calculer le taux de précision d'un modèle.

D'autres paramètres tels que le nombre d'époques parcouru dans l'entraînement du modèle qui est de 150 itérations, la taille de chaque lot d'époque d'entraînement et validation ont été ajoutés (312 par itération).

Une fonction point de contrôle a été programmée afin d'enregistrer les meilleurs modèles avec un taux de perte minimal au cours de l'entraînement.

### b) Modèle de classification Resnet

Comme nous avons déjà mentionné « Resnet » est l'une des architectures les plus performantes qui nous assure de très bons résultats dans la classification des images. Cette architecture a plusieurs conceptions possibles. Nous avons choisi d'implémenter Resnet50 cette dernière utilise 50 couches convolutives dans le traitement des images afin de les classer. Aussi nous avons abordé dans le chapitre 3 (techniques d'apprentissage profond) que l'utilisation de l'apprentissage par transfert nous assure des résultats nettement meilleurs que l'utilisation du réseau de neurone directement.

Pour cela nous avons implémenté l'architecture resnet50 en utilisant l'apprentissage par transfert pour que nos résultats soient bons. Et nous avons implémenté un réseau de neurone artificiel (ANN) de douze couches dans la partie entièrement connectée qui va nous assurer la classification.

Dans l'implémentation de cette architecture nous avons utilisé les paramètres suivants :

- Dropout : nous avons utilisé une régularisation d'un 0,3 pour qu'on évite le sous-apprentissage comme nous avons déjà expliqué dans la partie bibliographique
- Fonction d'activation : ReLu.

Comme nous avons déjà mentionné dans la partie bibliographique la fonction ReLu est parmi les meilleures fonctions d'activation utilisable maintenant.

- Fonction de sortie : Softmax.

Dans notre cas nous voulons savoir le pourcentage de chaque classe. C'est pour ça nous avons utilisé la fonction softmax comme fonction de sortie.

Nous avons utilisé la même architecture pour deux travaux différents.

- Le premier travail est représenté par la classification des zones. Dans ce travail nous avons donné deux sorties à notre réseau de neurone.
- Le deuxième travail est représenté par la classification des bâtiments. Pour cette classification nous avons implémenté le modèle pour qu'il nous donne quatre sorties.

Après la phase d'implémentation du modèle nous avons passé à la phase d'entraînement.

Pour entraîner notre modèle nous avons utilisé les paramètres suivants :

- Fonction de perte : l'entropie croisée binaire.
- Fonction d'optimisation : Adam.
- Taux d'apprentissage : 0.00001.

Ce taux d'apprentissage a ralenti l'entraînement mais les résultats obtenus étaient satisfaisant. Un taux d'apprentissage petit va servir à ne pas manquer la valeur minimale de la fonction de perte.

- Nombre d'itération : 150.

Nous avons passé notre modèle pour classifier nos données 150 fois afin qu'il puisse extraire le maximum des caractéristiques nécessaires.

- La taille du lot de chaque itération : 100.

### **c) Modèle de Segmentation Unet**

Pour l'entraînement de notre modèle de localisation nous avons utilisé les images post catastrophe et les masques générés, les résultats attendus à la fin de cet entraînement sont représentés par un modèle capable de nous générer les coordonnées de chaque polygone qui indique un bâtiment dans l'image traitée.

Les paramètres utilisés pour l'entraînement de ce modèle sont des attributs tel que le nombre d'époque (100 itérations), le nombre de lot dans une époque (16 par itération), ainsi que quelques fonctions tel que celle de perte (entropie croisée), de métrique, d'activation ('Relu' présentée dans le chapitre 3) et celle d'optimisation Adam.

## **2.3.Déploiement du système**

Dans cette section nous allons présenter les interfaces graphiques du système réalisé afin de rendre notre concrétisation prête à l'utilisation.

Nous avons trois interfaces essentielles à expliquer: Menu d'entrée, Solution d'analyse par zone, Solution d'analyse par structure.

### **a) Menu d'entrée**

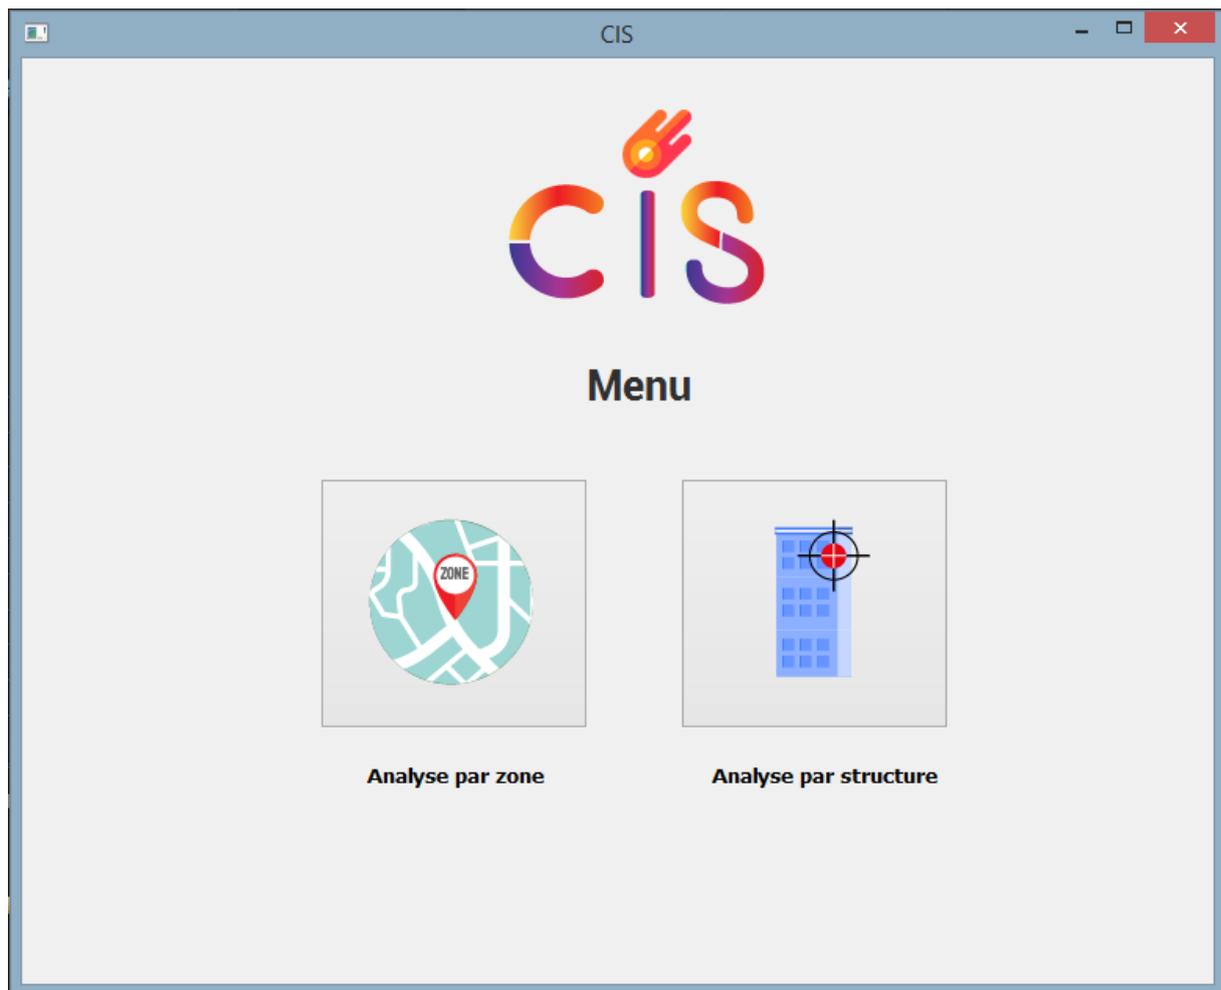


Figure 6.19: Interface graphique du menu d'entrée

Comme montre la figure précédente cette interface graphique nous donne deux possibilités :

- Choisir le sous-système qui traite une image d'une zone et la classifier.
- Choisir le sous-système qui traite une image d'une zone et classifier chaque bâtiment dans cette image.

Nous avons créé cette interface dans le but de donner à l'utilisateur le choix qui lui convient « analyse par zone » ou « analyse par structure ».

### **b) Solution d'analyse par zone :**

La figure suivante représente l'interface principale de la solution d'analyse par zone.

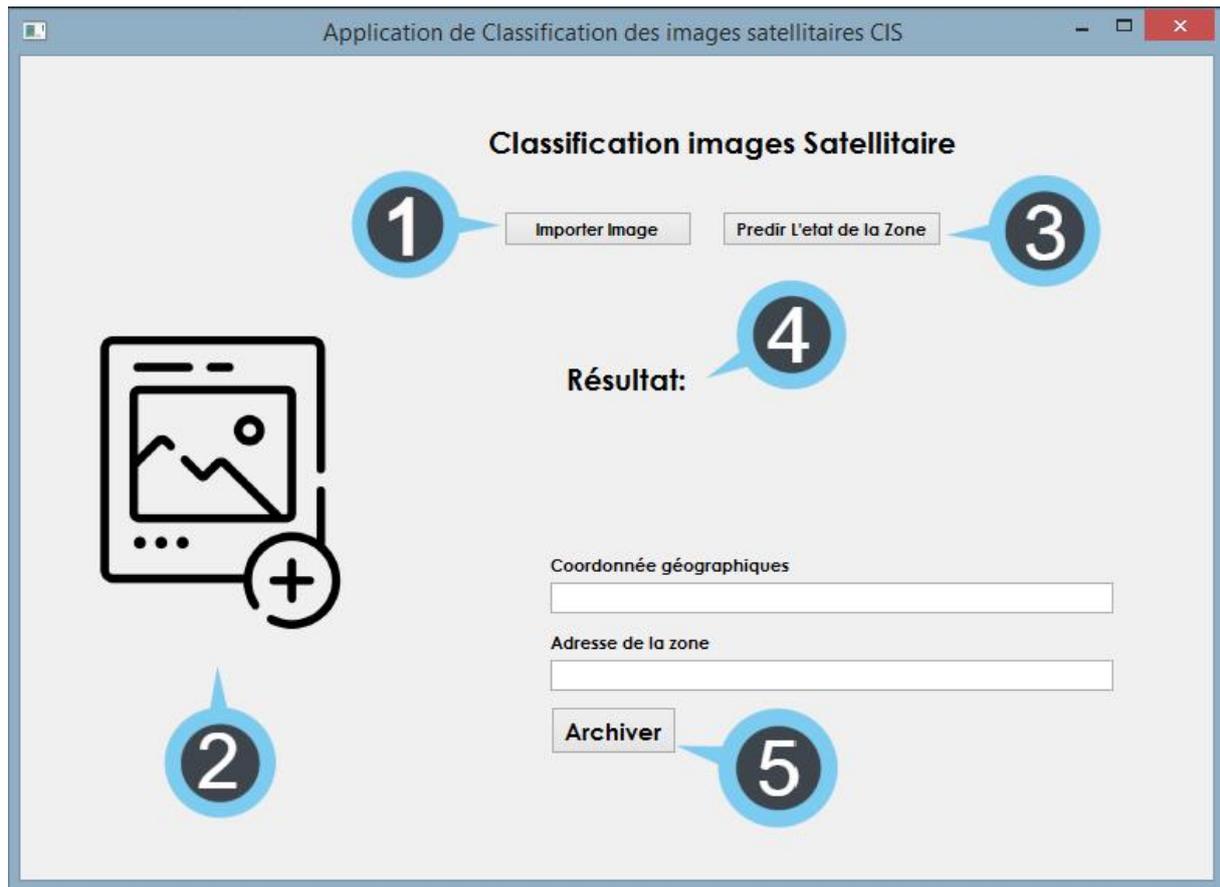


Figure 6.20: Interface graphique principale de la solution d'analyse par zone

Nous allons expliquer chaque élément dans l'interface précédente dans ce qui suit :

- **Élément 1** : Nous sommes en train de classifier les images satellitaires. Pour cela nous devons utiliser une image satellitaire comme entrée pour la traiter. Le bouton « importer » nous donne la main à ajouter l'image satellitaire de la zone que nous voulons traiter. L'image importée va être affichée dans l'emplacement numéro 2 dans la figure précédente.
- **Élément 3** : Après avoir importé l'image nous passerons à son traitement et classification. L'étape 3 se déclenche juste après un clic sur le bouton « prédire l'état de la zone ». L'objectif derrière cette étape est de créer le résultat final de notre système. Le résultat sera affiché dans l'emplacement numéro 4.

Voici un exemple du résultat

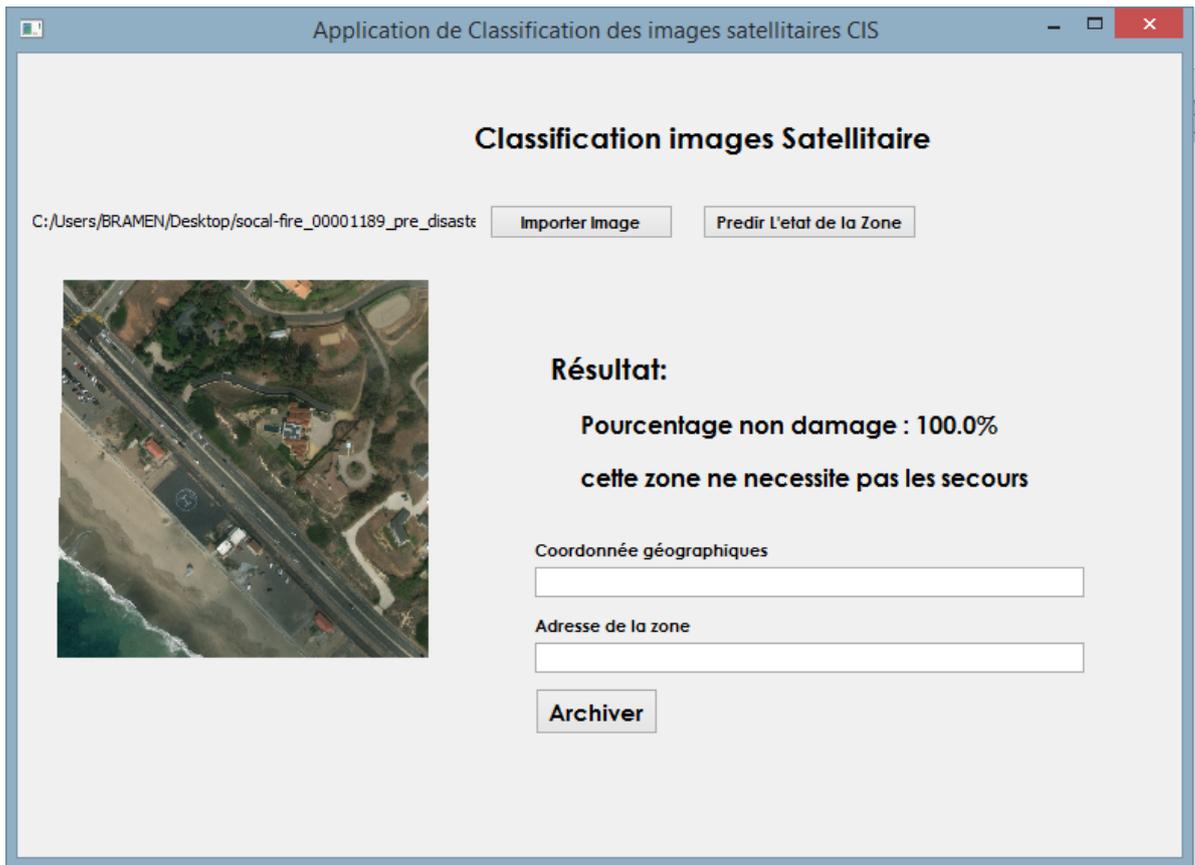


Figure 6.21: Interface graphique qui aborde le résultat final de la solution d'analyse

- **Élément 5 :** Après avoir passé par tous les éléments précédents. Le système donne la possibilité d'enregistrer l'image dans un dossier selon la classe de prédiction (soit le dossier des images endommagées ou bien le dossier des images non endommagées). Cela se fait en remplissant les champs de texte (coordonnées géographiques et adresse de la zone) ensuite en cliquant sur le bouton « archiver ».

**c) Solution d'analyse par structure:**

La figure suivante représente les éléments globaux qui composent l'interface principale de la solution d'analyse par structure.

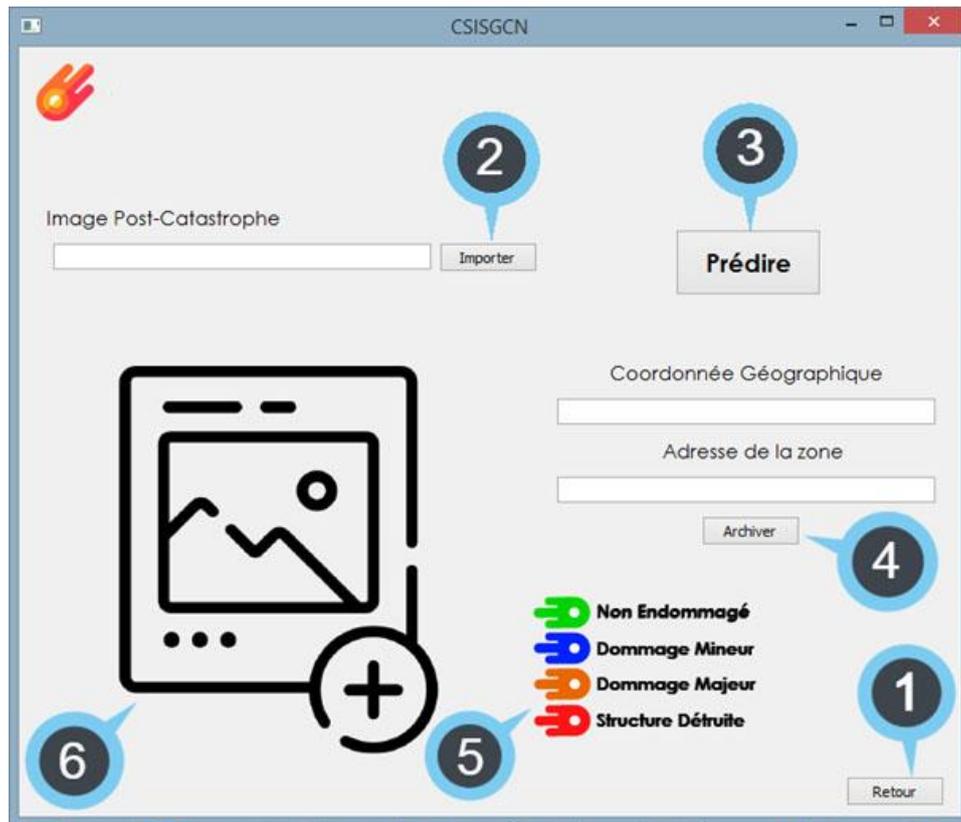


Figure 6.22: Interface graphique principale de la solution d'analyse par structure

Dans ce qui suit nous allons expliquer chaque élément dans l'interface :

- **Elément 1:** représente le bouton « retour » qui va nous retourner vers le menu principal.
- **Elément 2:** Cette étape consiste à importer une image satellitaire en cliquant sur le bouton « importer » on pourra ainsi accéder à une boîte de dialogue qui va nous permettre de choisir une image.  
Ceci est clair dans la figure suivante

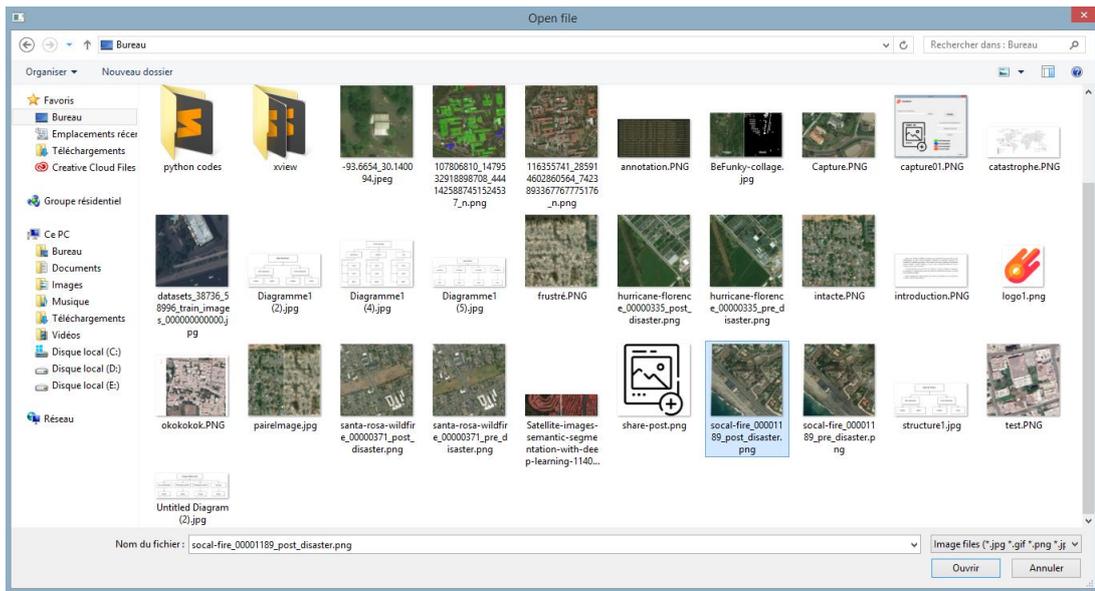


Figure 6.23: Image qui illustre la phase d'importation d'image

Voici l'image importé



Figure 6.24: Figure qui représente l'image satellitaire qu'on va l'utiliser comme entrée dans le système

- **Élément 3** : Après avoir importé l'image nous passerons à son traitement. L'étape 3 se déclenche juste après le clic sur le bouton « prédire ». L'objectif derrière cette étape est de créer le résultat final de notre système. Pour cela nous passerons par plusieurs étapes. Nous les citerons élément par élément comme suit:
  - Appliquer le modèle de localisation sur l'image importée par l'utilisateur.
  - Créer un fichier texte contenant l'emplacement des bâtiments et leurs identifiants dans l'image satellitaire à l'aide du résultat de la première opération.
  - Extraire chaque bâtiment dans l'image à l'aide du fichier créé dans la deuxième opération, afin de les sauvegarder dans un emplacement (dossier destination). Chaque image va être nommée en utilisant l'identifiant du bâtiment concerné.
  - Appliquer le modèle de classification sur chaque image créée dans la troisième opération afin de les classer en quatre classes.
  - Modifier le fichier texte créé dans la deuxième opération afin de lui rajouter les valeurs de la classification de chaque bâtiment.
  - Créer une image segmentée qui contient dessous chaque bâtiment la couleur de sa classe prédite dans la cinquième opération.

Le résultat de ces étapes va être affiché dans **l'élément 5** et **l'élément 6**. Le nombre des bâtiments prédit par chaque classe va être affiché dans l'élément 5, et l'image segmentée va être affiché dans l'élément 6.

Voici le résultat final de l'interface après la prédiction

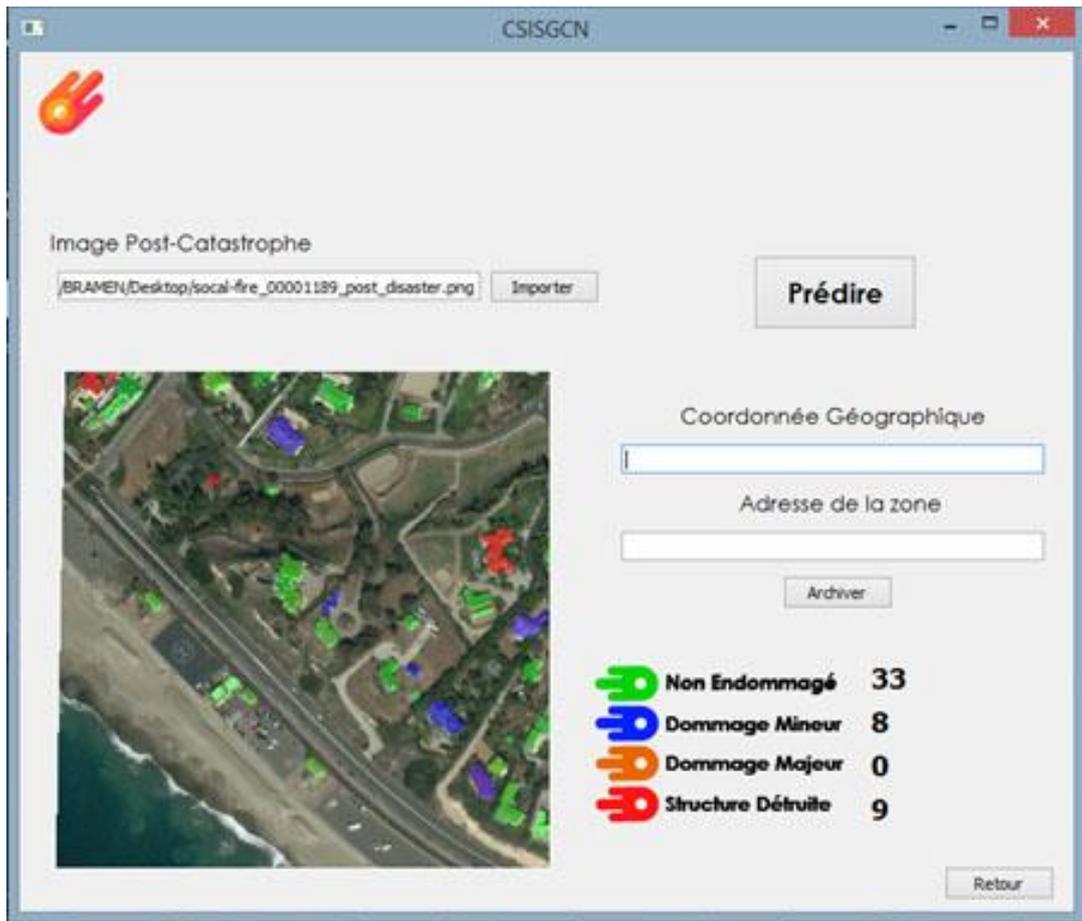


Figure 6.25: Interface graphique qui représente le résultat final du système

Dans cet exemple nous avons pu détecter 33 bâtiments non endommagés, 8 bâtiments qui ont des endommagements mineurs, 9 bâtiments détruits.

- **Élément 4 :** Après avoir passé par tous les éléments précédents. Nous pouvons archiver l'image créée dans l'élément 6 en remplissant les champs de texte (coordonnées géographiques / adresse de la zone) ensuite en cliquant sur le bouton « archiver ». Cela a pour but d'archiver le résultat final et le nommée par son adresse et ces coordonnées.

### 3. Résultats et tests

Dans cette phase nous allons visualiser les résultats obtenus lors de l'entraînement de nos modèles de réseau de neurone convolutif, et voir la fiabilité de ces derniers en réalisant des tests adaptés à cette étude.

#### 3.1. Test de robustesse des modèles

Durant cette expérimentation, nous nous intéressons uniquement aux métriques suivantes :

- La précision du modèle sur le jeu d'entraînement.
- La précision du modèle sur le jeu de validation.
- L'erreur commise par le modèle sur le jeu d'entraînement (calculée en entropie croisée)

- L'erreur commise par le modèle sur le jeu de validation (calculée en entropie croisée)

### a) Résultat de la classification par zone

Pour cette solution nous avons utilisé les deux d'architectures réalisés dans la partie implémentation pour la première solution (VGG16 et Resnet50). Les résultats obtenus sont les suivants :

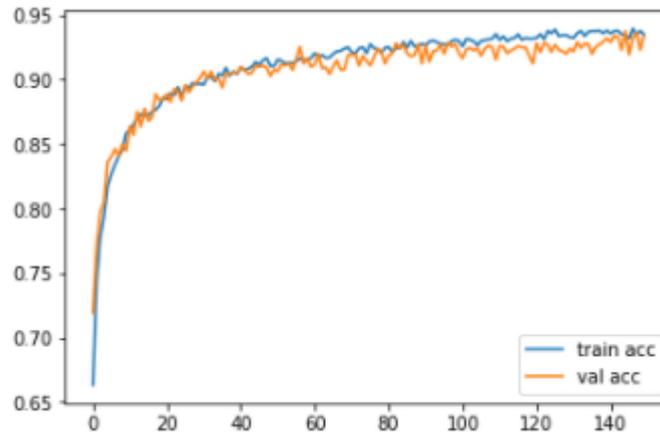


Figure 6.26: graphe représentant la valeur de précision lors de l'entraînement et validation du modèle VGG16

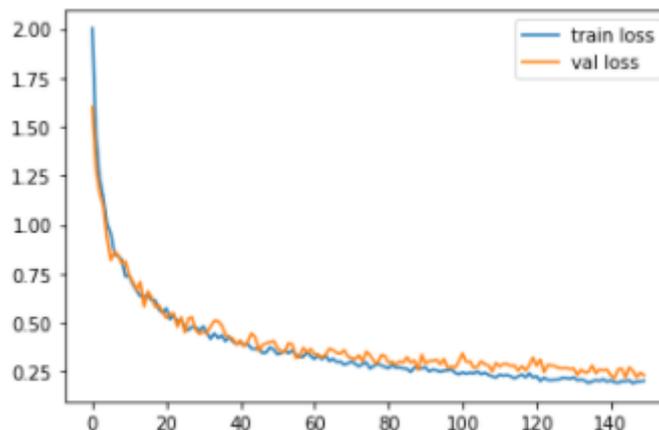


Figure 6.27: graphe représentant la valeur de perte lors de l'entraînement et validation du modèle de VGG16

Les graphes précédents représentent l'allure de chaque courbe métrique et nous permet de tirer des conclusions. Les courbes enregistrées sont illustrées dans les Figure 6.26 et Figure 6.27.

Une première analyse de ces courbes ne montre pas d'écart entre la performance du modèle VGG16 quand il s'agit des données d'entraînement ou bien des données de validation.

Cela s'explique par le fait que nous disposons d'une base de données volumineuse ce

qui permet au modèle de se généraliser. Un autre point à remarquer est la précision et le taux de perte du modèle sur les deux jeux (entraînement et validation), nous remarquons que la précision augmente et l'erreur diminue jusqu'à un certain point, aux environs de l'époque 130. Après cela, les performances se stabilisent, avec un taux de précision principale de 94% pour l'entraînement et plus de 92% en phase de la validation, pour le taux de perte (taux d'erreurs) on a 20% pour l'entraînement et 33% pour la validation. En d'autres termes, notre modèle c'est bien adapté à nos données et ne souffre ni de sous apprentissage ni de sur-apprentissage.

La conclusion retenue de cette expérimentation est que la base de données est suffisante pour le cas étudié.

Pour notre deuxième modèle nous avons obtenu les résultats suivants :

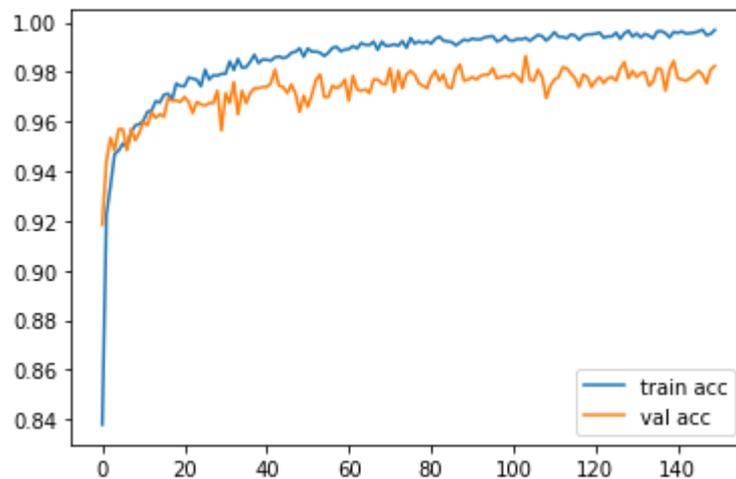


Figure 6.28: graphe représentant la valeur de précision lors de l'entraînement et validation du modèle Resnet50

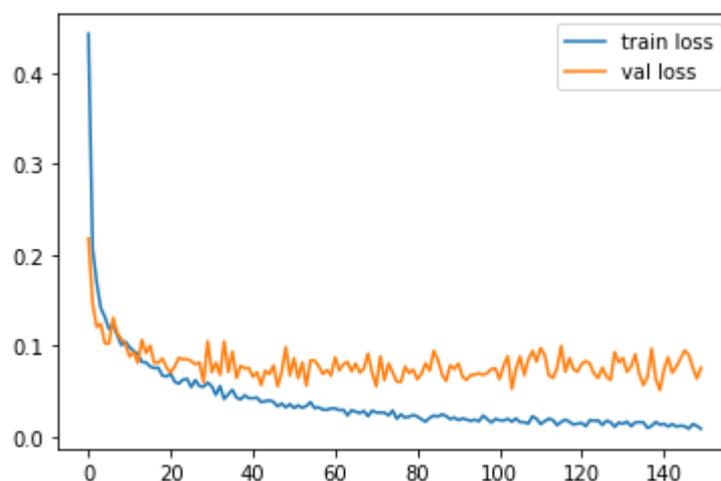


Figure 6.29: graphe représentant la valeur de perte lors de l'entraînement et validation du modèle de Resnet50

Comme pour le modèle précédent nous avons effectué l'entraînement du réseau sur 150 époques pour représenter chaque courbe métrique et pour pouvoir tirer des conclusions d'un point de vue comparatif entre les deux modèles qui représentent notre première solution la classification par zones des images satellitaires. Les courbes enregistrées sont illustrées dans les Figure 6.28 et Figure 6.29.

En analysant ces courbes on observe aucun grand écart entre la performance du modèle quand il s'agit des données d'entraînement ou bien des données de validation. Cela peut s'expliquer par le fait que dans le modèle précédent, notre base de données est satisfaisante dans cette phase et pour ce modèle. Ce qui permet au modèle de se généraliser. Un autre point à remarquer est que la précision augmente et l'erreur diminue jusqu'à un certain point, aux environs de l'époque 140. Après cela, les performances se stabilisent, avec un taux de précision principale de 99,6% pour l'entraînement et plus de 98,4% en phase de la validation, pour le taux de perte (taux d'erreurs) on a 1,3% pour le jeu d'entraînement et 5% pour celui de validation.

La conclusion retenue de cette expérimentation est que toutes les étapes de préparation de données et paramétrage du modèle utilisés ont permis un entraînement optimal pour notre réseau de neurone convolutif. Aussi on observe une nette amélioration dans ce modèle au niveau des performances et du taux de perte comparé au premier modèle « vgg16 ».

## b) Résultats de la classification par structure

Pour cette solution nous avons utilisé deux types de modèles

- Modèle de Segmentation et localisation Unet
- Modèle de classification Resnet50

Les résultats pour le modèle de Segmentation Unet obtenus sont les suivants :

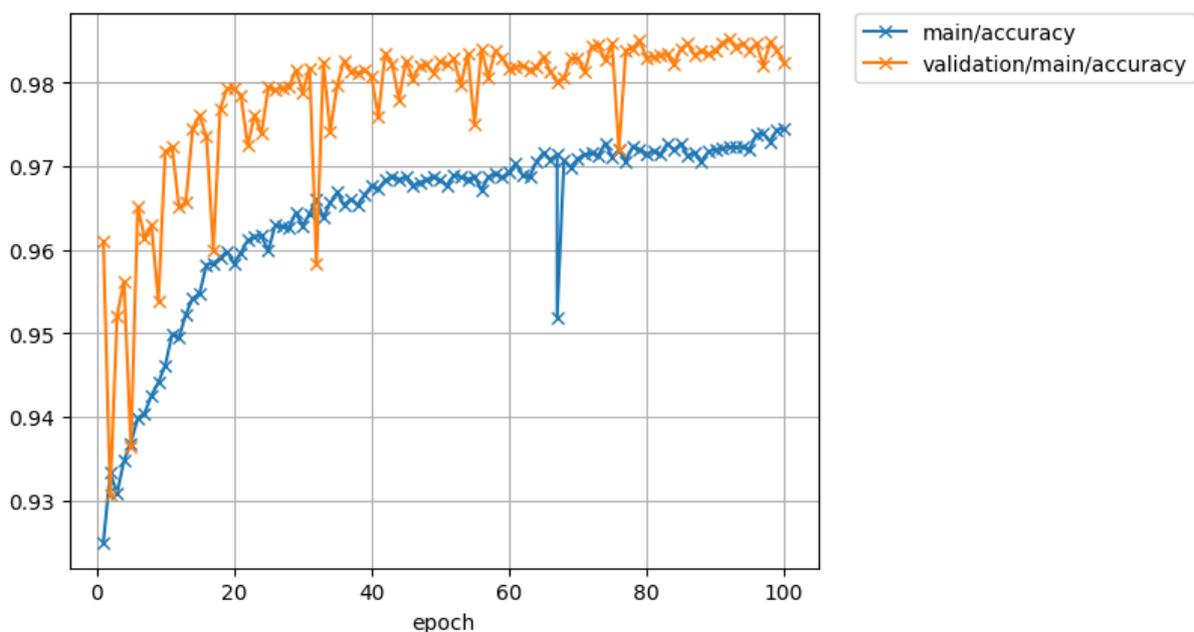


Figure 6.30: graphe représentant la valeur de précision lors de l'entraînement et validation du modèle d'Unet

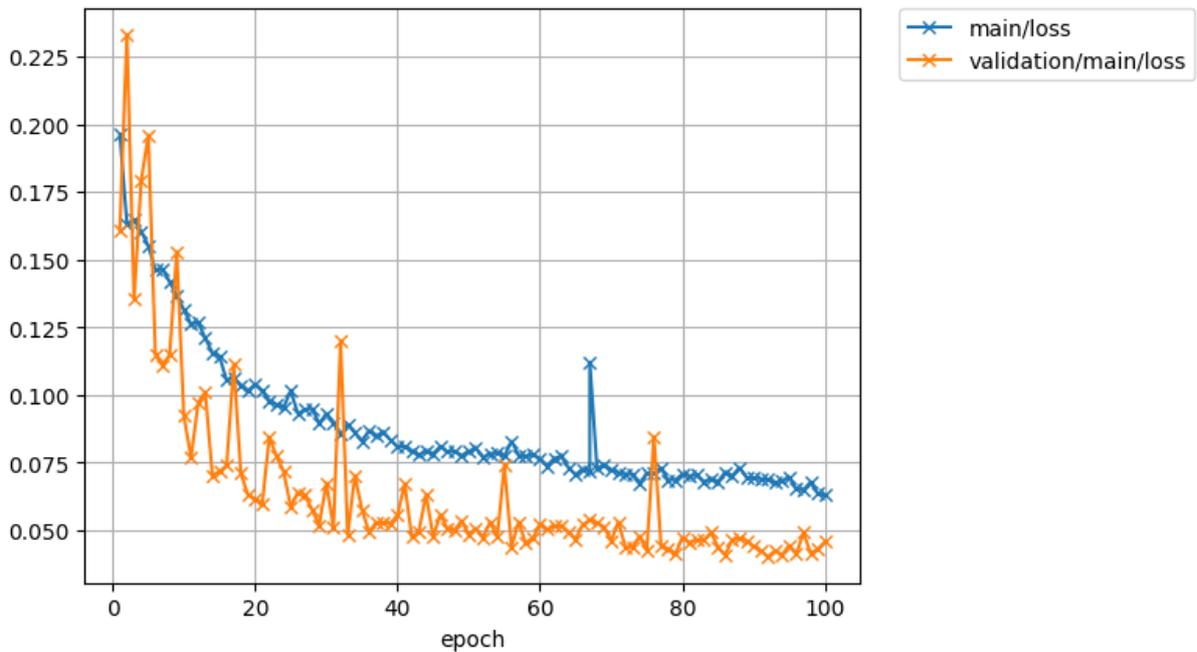


Figure 6.31: graphe représentant la valeur de perte lors de l'entraînement et validation du modèle d'Unet

Nous avons effectué l'entraînement du réseau sur 100 époques pour représenter les courbes métriques illustrées dans les Figure 6.31 et Figure 6.30.

Aucun écart entre la performance du modèle Unet quand il s'agit des données d'entraînement ou bien des données de validation. Cela s'explique par le fait que la base de données « xview2 » s'avère suffisante. D'une autre part nous remarquons que la précision augmente et l'erreur diminue jusqu'à l'époque 80 sur les deux jeux (entraînement et validation). Après cela, les performances se stabilisent, avec un taux de précision principale de plus de 98% pour l'entraînement et plus de 97% en phase de la validation, pour le taux de perte (taux d'erreurs) on a 4% pour l'entraînement et 6% pour la validation. En d'autres termes, notre modèle a bien traité nos données.

On peut conclure qu'une autre augmentation ou manipulation de données n'est pas nécessaire pour ce cas de figure.

Les résultats pour le modèle de classification des structures Resnet50 obtenus sont les suivants :

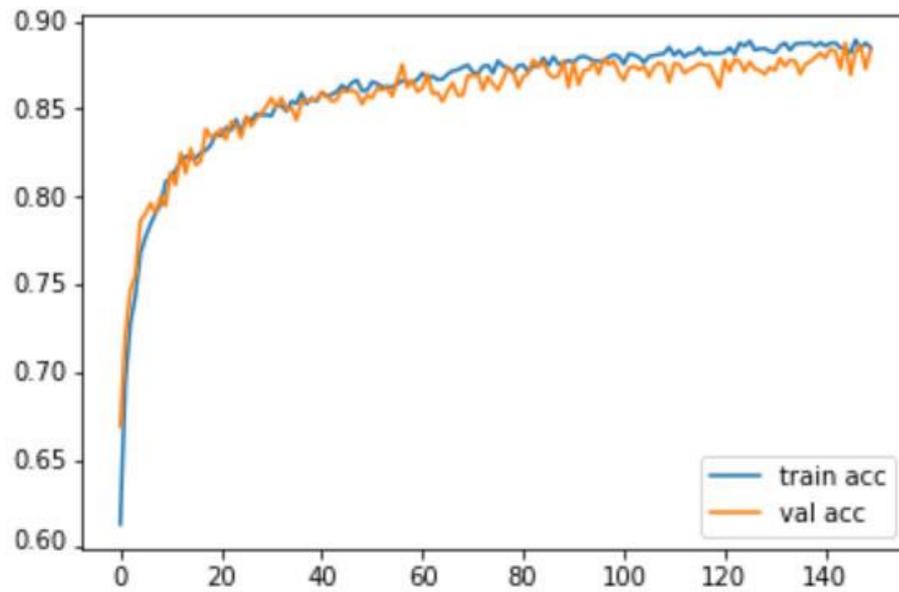


Figure 6.32: graphe représentant la valeur de précision lors de l'entraînement et validation du modèle de classification par structures Resnet50

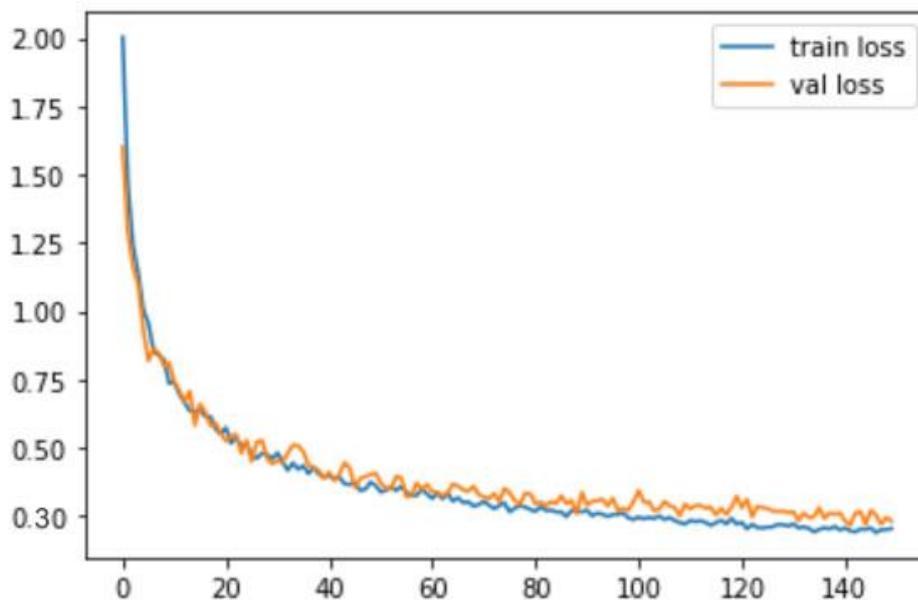


Figure 6.33: graphe représentant la valeur de perte lors de l'entraînement et validation du modèle de classification par structures Resnet50

Pour ce modèle de classification (Resnet50), nous avons effectué un entraînement sur 150 itérations, afin de représenter les courbes métriques du modèle destiné à notre deuxième solution. Les courbes enregistrées sont illustrées dans les Figure 6.32 et Figure 6.33.

On n'observe aucun écart entre la performance du modèle quand il s'agit des données d'entraînement ou bien des données de validation en analysant ces courbes. Cela s'explique par

la présence d'une base de données volumineuse (entraînement : 32 828 images de structures, validation : 10 948 images de structures). On peut voir que :

- Le taux de précision augmente jusqu'à 89,8% pour l'entraînement et 88,7% en phase de la validation.
- Le taux de perte (taux d'erreurs) diminue jusqu'à 30,3% pour le jeu d'entraînement et 32% pour celui de validation.

La conclusion retenue de cette expérimentation est que les performances de ce modèle sont au-dessous des réseaux de neurones précédents cela peut s'expliquer par la différence de base de données et le nombre de sorties possibles, cependant les résultats restent satisfaisants.

### 3.2. Tests d'évaluation

Dans un test de classification, nous classons les éléments selon deux classes : positive ou négative, le résultat peut être correct ou incorrecte. Pour cela, nous distinguons quatre combinaisons de résultats possibles :

- **Vrais positifs « TP » (True Positive):** Un résultat est dit vrai positif lorsqu'un élément positif est correctement classé.
- **Faux positifs « FP » (False Positive):** Un résultat est dit faux positif lorsqu'un élément est classé positif, alors qu'il ne l'est pas.
- **Vrais négatifs « TN » (True Negative):** Un résultat est dit vrai négatif lorsqu'un élément négatif est correctement classé.
- **Faux négatifs « FN » (False Negative):** Un résultat est dit faux positif lorsqu'un élément est classé négatif, alors qu'il est positif.

Pour pouvoir s'assurer de la précision reçue des valeurs précédentes nous utilisons la mesure suivante :

- a) **Précision :** Correspond à la qualité de la classe. On divise le nombre d'éléments bien classés dans la classe par le nombre total d'éléments attribués à la classe.

La précision peut être définie comme suit :

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive}$$

- b) **Rappel (Sensibilité):** Correspond à la qualité d'une classe. Il y en a une par classe donc, on va diviser le nombre d'éléments bien classés dans la classe par le nombre total d'individus appartenant réellement à la classe.

Mathématiquement, le rappel est défini comme suit :

$$Rappel = \frac{True\ Positive}{True\ Positive + False\ négative}$$

**Note :** Dans le cas où il y a plusieurs classes à prédire, la sensibilité correspond à la somme des sensibilités de chacune des classes divisé par le nombre de classe. Il s'agit donc d'une moyenne des sensibilités. Même raisonnement pour la précision en multi-classes.

Afin d'évaluer ses mesures nous utilisons la matrice de confusion, chaque colonne de la matrice représente le nombre d'occurrences d'une classe estimée, tandis que chaque ligne

représente le nombre d'occurrence d'une classe réelle (ou de référence). Un des intérêts de la matrice de confusion est qu'elle montre rapidement si un système de classification parvient à classifier correctement.

		Classe réelle	
		-	+
Classe prédite	-	True Negatives <i>(vrais négatifs)</i>	False Negatives <i>(faux négatifs)</i>
	+	False Positives <i>(faux positifs)</i>	True Positives <i>(vrais positifs)</i>

Tableau 3: Matrice de confusion

Nous avons appliqué la matrice de confusion pour nos données tests qui non jamais servi, ni dans l'entraînement ni dans la validation. Ceci afin de s'assurer des résultats obtenus pour tous les modèles de classification des deux solutions réalisées.

Les résultats étaient les suivants :

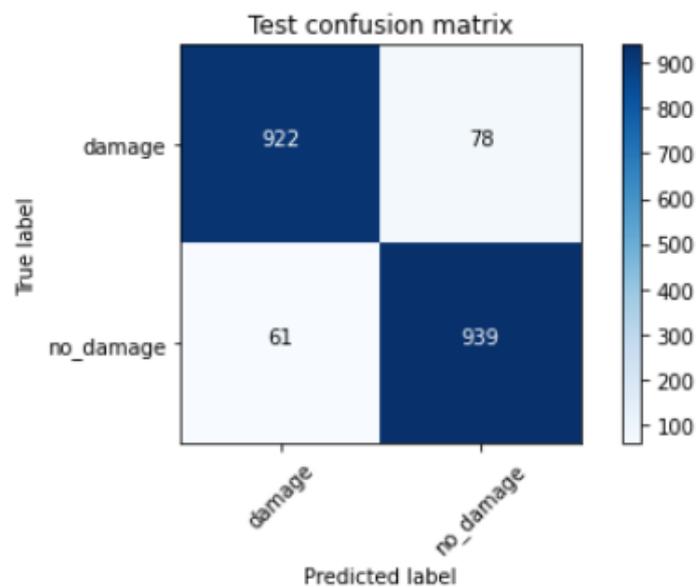


Figure 6.34: Matrice de confusion VGG16

Cette matrice de confusion représente la performance du Modèle VGG16 sur les données tests de la base de données « IEEE DataPort » destinée à la première solution.

Ce jeu de données se compose de 2000 images satellitaires étiquetées la moitié endommagées et l'autre moitié non endommagées, comme on peut l'observer notre modèle a pu détecter 939 images non endommagées et 922 images endommagées.

Par exemple, si on applique les fonctions de précision et de rappel sur une des classes on peut conclure que :

- Notre modèle a une précision de 0.94. En d'autres termes, quand il prédit qu'une image est endommagée, sa prédiction est dans 94 % des cas.
- Notre modèle a un rappel de 0,92. En d'autres termes, il identifie correctement 92 % des images endommagées par les catastrophes naturelles.

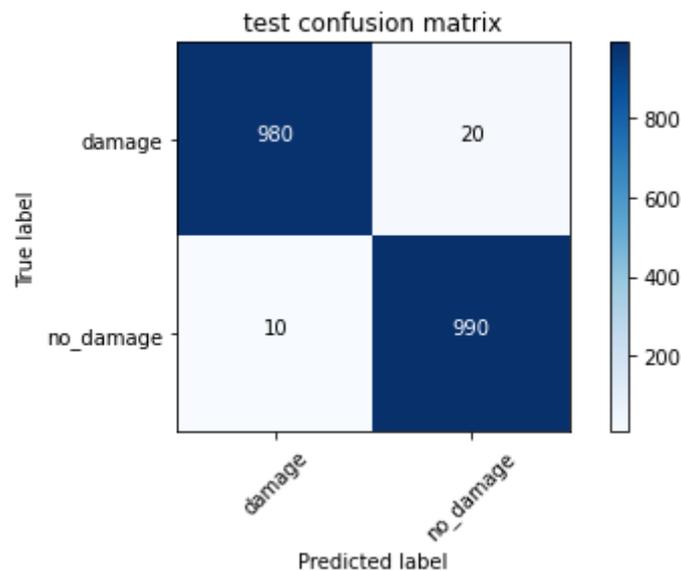


Figure 6.35: Matrice de confusion Resnet50

Cette matrice de confusion représente la performance du Modèle Resnet50 sur les données tests de la base de données « IEEE DataPort » destinée aussi à la première solution.

Ce jeu de données est similaire à celui utilisé dans le modèle VGG16, comme on peut l'observer notre modèle a pu détecter 990 images non endommagées et 980 images endommagées.

Si on prend un exemple, et on applique les fonctions de précision et de rappel sur une classe on peut conclure que :

- Notre modèle a une précision de 0.98. En d'autres termes, quand il prédit qu'une image est non endommagée, sa prédiction est dans 98% des cas.
- Notre modèle a un rappel de 0,99. En d'autres termes, il identifie correctement 99 % des images endommagées par les catastrophes naturelles.

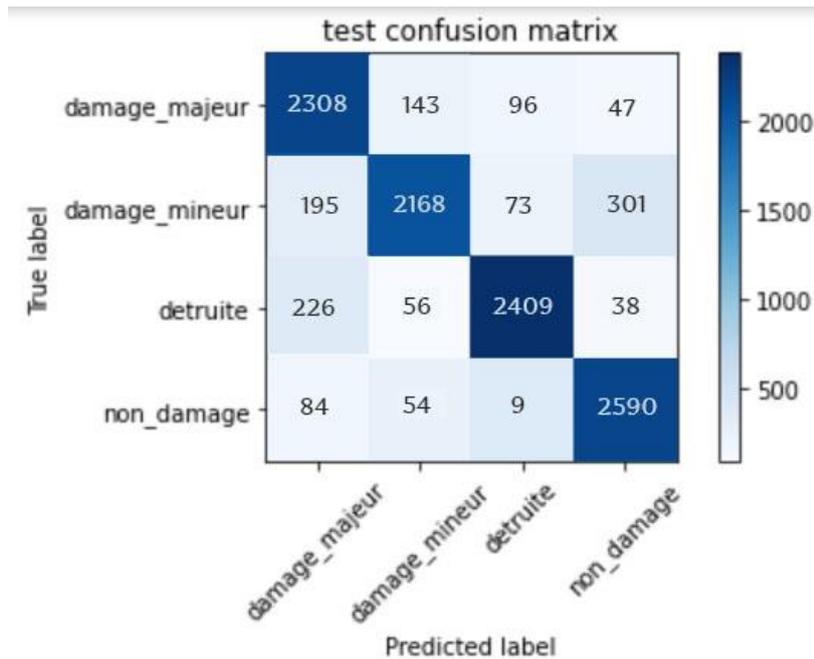


Figure 6.36: Matrice de confusion modèle Resnet50 pour la solution par structures

Cette matrice de confusion représente la performance du Modèle Resnet50 sur les données tests de la base de données des bâtiments générée à partir de la base de données « xvview2 » destinée aussi à la deuxième solution.

Ce jeu de données est constitué de 4 sorties avec un total de données de 10 940 images et 2737 images dans chaque classe, comme on peut l'observer notre modèle a pu détecter 2590 bâtiments non endommagés et 2409 images de bâtiments détruits, 2168 bâtiments avec des dommages mineur et 2308 avec des dommages majeur.

Si on prend un exemple, et on applique les fonctions de précision et de rappel sur une classe on peut conclure que :

- Notre modèle a une précision de 0.89. En d'autres termes, quand il prédit qu'une image a des dommages mineurs, sa prédiction est dans 89% des cas.
- Notre modèle a un rappel de 0,81. En d'autres termes, il identifie correctement 81 % des images avec des dommages mineurs causé par les catastrophes naturelles.

#### 4. Conclusion

Dans ce dernier chapitre nous avons présenté le système qu'on a construit ainsi que les résultats obtenus. Ce système est en fait un outil d'aide à la décision qui permettra de donner les informations nécessaires sur le taux d'endommagement des zones et leurs structures aux secouristes.

Dans notre réalisation nous avons étudié une autre partie d'apprentissage profond qui est nommée la segmentation sémantique. Cette partie a été abordée pour qu'on puisse faire une classification plus approfondie des zones en classifiant leurs structures, ainsi l'utilisateur pourra visualiser les résultats finaux d'une façon plus claire.

Les résultats obtenus par nos modèles représentés dans ce chapitre ont été très satisfaisants et les tests effectués les prouvent. Ces résultats ont été obtenus après plusieurs tentatives non concluantes ainsi que plusieurs modifications dans l'implémentation des modèles.

# Conclusion générale et perspectives

Dans les années précédentes, les catastrophes naturelles ont provoqué des dégâts massifs et des pertes humaines innombrables. La gestion des conséquences faites par ces catastrophes ont été difficiles à cause du manque des données qui concernent les zones sinistrées ce qui a causé une perte de temps et plusieurs autres obstacles aux secouristes qui vont intervenir dans la zone. La perte du temps dans l'intervention dans ces cas va causer des risques énormes.

Pour cela nous avons étudié la possibilité de fournir les informations nécessaires aux secouristes pour effectuer leur travail le plus rapidement possible.

Dans la partie bibliographique de notre mémoire nous avons étudié l'imagerie satellitaire pour s'assurer que l'utilisation de ces images va nous fournir les informations nécessaires des zones abordées. L'étude de ce chapitre nous a permis de distinguer les différents types d'images satellitaires et de faire le meilleur choix de données pour notre étude. Aussi nous avons abordé le domaine de la gestion des catastrophes naturelles qui représente le domaine d'application de notre projet, l'étude de ce chapitre a servi de bien comprendre les conséquences des catastrophes ainsi que les informations nécessaires qui doivent être présentes le plutôt possible pour la gestion de ses phénomènes. Ensuite nous avons étudié les techniques de l'apprentissage profond qui ont permis l'exploitation des images satellitaires afin d'aider à gérer les catastrophes naturelles.

Les réseaux de neurones qui représentent le noyau des techniques de l'apprentissage profond ont prouvé leurs efficacités dans le domaine de l'apprentissage machine. L'étude du chapitre « techniques de l'apprentissage profond » a permis de comprendre les réseaux de neurone et ces paramètres, il s'est avéré que les réseaux de neurone convolutifs sont les plus adaptées à notre étude. Nous avons donc aussi étudié les architectures propres à ce type afin d'élire les meilleures structures des réseaux de neurone à utiliser dans notre contribution.

La consécration de notre travail est représenté dans l'élaboration des modèles de réseaux de neurone convolutifs puissants et performants en termes de qualité d'analyse des zones sinistrées afin de les exploiter dans le domaine d'application. Pour concevoir notre système, nous sommes passés par plusieurs étapes nous citons la recherche des données et la réalisation de ces traitements afin de s'assurer que les données sont prêtes à utilisées. Ainsi que la préparation et le développement des modèles afin d'exploiter les données déjà préparées pour réaliser l'objectif final. Les réseaux de neurones ont plusieurs paramètres qui contrôlent leurs efficacités et performances. Dans notre cas plusieurs tentatives ont été faites afin de se stabiliser sur les modèles expliqués dans la partie de contribution. Enfin nous avons déployé nos solutions dans une application desktop afin que l'utilisateur final puisse facilement exploiter les modèles des réseaux de neurone convolutifs.

Notre logiciel « CIS » est un outil simple à utiliser. Le système à deux solutions, La première solution est conçue pour que les utilisateurs concernés puissent savoir si une zone précise est endommagée ou pas. Cette solution a été réalisée en implémentant deux architectures différentes des réseaux de neurone convolutifs, et en déployant le modèle le plus puissant entre les deux. La deuxième solution est conçue pour une étude plus approfondie, cette dernière est réalisée pour connaître l'état d'endommagement de chaque structure dans la zone. Nous avons réalisé cette solution en utilisant une architecture entièrement convolutionnelle spécialisée dans

la segmentation sémantique pour distinguer les bâtiments présents dans l'image satellitaire. Par la suite, nous avons utilisé une architecture des réseaux de neurone convolutifs pour classifier les bâtiments préalablement détectés par la première architecture afin de connaître leurs états d'endommagement. Le système résultant peut être utilisé dans plusieurs cas ou ce genre de phénomènes ce produit tel que les récents évènements en Algérie (séisme Mila, Séisme Tipaza).

Le plus grand obstacle que nous avons rencontré est de se procurer les données qui vont contribuer à l'apprentissage des réseaux de neurone, car ces derniers nécessitent des données volumineuses pour qu'ils soient performants.

Nous pouvons dire à ce stade que les objectifs fixés au début de cette étude sont atteints, et que l'apprentissage profond est une technique adéquate qui permet d'exploiter les données satellitaires des catastrophes naturelles afin de réaliser des systèmes d'aide à la gestion de ces phénomènes, mais nous pensons que si les données d'endommagement des autres structures seront disponibles nous pouvons les exploiter de la même manière faite dans ce projet. Donc d'un point de vue technique il est possible de faire évoluer le système réalisé pour qu'il soit un système qui aidera à la gestion des catastrophes par d'autres critères comme l'état des réseaux routiers et l'état des réseaux d'énergies. Aussi il est possible de déployer notre système pour qu'il soit opérationnel en temps réel.

---

## Références bibliographiques

---

- [1] Statista, «statista.com» 2018. [En ligne]. Available: <https://fr.statista.com/themes/3658/les-catastrophes-naturelles-dans-le-monde/>,. [Accès le 17 08 2020], (Article web).
- [2] Atlas Magazine, «atlas-mag.net» 2018. [En ligne]. Available: <https://www.atlas-mag.net/article/bilan-des-catastrophes-naturelles-de-2018>. [Accès le 17 08 2020] , (Article web).
- [3] Nations unies, «Solutions spatiales aux problèmes mondiaux» 2006. [En ligne]. Available: [www.unoosa.org](http://www.unoosa.org). [Accès le 12 11 2019].
- [4] D. Souhila, «Repérage et poursuite intermittent par un satellite de plusieurs cibles terrestres mobiles», PhD these, Tlemcen, 2010.
- [5] G. & a. Francisco Eugenio, «Manuel de Télédétection Spatiale» Université de Las palma, edition U.E, 2013.
- [6] G. & a. Mauricio Labrador,«Satellites pour la Télédétection appliquée à la gestion territoriale», Editeur: Département de l’Agriculture, de l’Élevage, de la Pêche et des Eaux duGouvernement des Canaries, 2013.
- [7] A. Samuel, C. Christina et D. Michel, «Capacités et limites de la télédétection pour cartographier les habitats naturels» Irstea- UMR TETIS, edition UNESCO, 2013.
- [8] D. David, «environnement logiciel d’exploitation des images satellitaires Pour faciliter la gestion des catastrophes majeures», thèse Master, MONTRÉAL , 2009.
- [9] O. M. M. Moulay et B. Hamza, «Modélisation des sources de vibration dans les satellites lasers» thèse Master, Ouargla 2017.
- [10] W. L. RAHAL, « étude de l’orbitographie des satellites artificiels et exploitation de leurs données», PhD these, UST Oran 2013.
- [11] C. F. T. e. a. Tison, «Retrieval of building shapes from shadows in high resolution SAR interferometric images» *International Geoscience and Remote Sensing Symposium* , pp. 1788-1791, 20 9 2004.
- [12] V. M. C. e. a. Amberg, «Structure extraction from high resolution SAR data on urban areas» *International Geoscience and Remote Sensing Symposium*, pp. 1784-1787, 24 09 2004.
- [13] Q. Z. L. e. a. Tan, «Lake shoreline detection and tracing in SAR images using wavelet transform and ACM method» *International Geoscience and Remote Sensing Symposium* , pp. 3703-3706, 25 07 2005.

- [14] H. A. Mokhtar, «Conception d'un système hybride entre la Méta heuristique Electromagnétique et l'algorithme de colonie de fourmis pour la classification des images satellitaires,» PhD these, Oran, Algerie, 2010.
- [15] B. Ibtissem, «Contribution des Données Optiques au Traitement Multi-sources des Désastres Naturels», thèse Master, univ-usto 2017.
- [16] ministère de l'Écologie , « risques naturels majeurs» le ministère de l'Écologie et du Développement durable, direction de la Prévention des pollutions et des risques, paris, France, 2004.
- [17] A.-L. Chesnel, «Quantification de dégâts sur le bâtiment liés aux catastrophes majeures par images satellite multimodales très haute résolution» thèse Master, Ecole Nationale Supérieure des Mines , Paris, France, 2008.
- [18] L. r. v. Jacques-Marie Bardintzeff, «futura-sciences.com» 19 02 2018. [En ligne]. Available: <https://www.futura-sciences.com/planete/dossiers/volcanologie-risques-volcaniques-441/>. [Accès le 09 12 2019], (Article web).
- [19] A. Zatir, «Le séisme: origines, mécanismes, effets et gestion» thèse Master, École Polytechnique d'architecture et d'urbanisme (EPAU), 2017.
- [20] T. H. Abderrahmane, «GENERALITE SUR LES GLISSEMENTS DE TERRAIN,» Centre universitaire Abdehafid boussouf Mila, 2019.
- [21] Direction de la Prévention des pollutions et des risques, France, Editer par Le Ministère de l'Écologie, du Développement durable et de l'Énergie, 2004.
- [22] Les risques naturels majeurs, France : direction de la Prévention des pollutions et des risques, France, Editer par Le Ministère de l'Écologie, du Développement durable et de l'Énergie, 2002.
- [23] P.Vincent, Modèles à noyaux à structure locale, thèse Master, Montréal: Université de Montréal, 2003.
- [24] E. Fouz, «Clustering des News.» thèse Master, Université de nice sophia antipolis., Nice , 2013.
- [25] M. Bouguessa, «Forage de données» thèse Phd, Université du Québec à Montréal , Montréal , 2015.
- [26] A. MOAWAD, «Medium» 01 02 2018. [En ligne]. Available: <https://medium.com/datathings/neural-networks-and-backpropagation-explained-in-a-simple-way-f540a3611f5e>. [Accès le 05 05 2020](Article Web).
- [27] F. SIMON, «Deep Learning, les fonctions d'activation» thèse Phd,U C Etienne 2018.
- [28] N. Kumar, «medium.com, Deep Learning Best Practices: Activation Functions & Weight Initialization Methods — Part 1» 4 5 2019, (Article Web) [En ligne]. Available:

<https://medium.com/datadriveninvestor/deep-learning-best-practices-activation-functions-weigh>. [Accès le 1 05 2020].

- [29] Javatpoint, «Javatpoint.com» 2019. [En ligne]. Available: <https://www.javatpoint.com/pytorch-backpropagation-process-in-deep-neural-network>. [Accès le 07 05 2020] (Article Web).
- [30] J. brownlee, «how to configure rate learning hyperparameter when training deep learning neural network» thèse Phd, 2019 .
- [31] Racinely, «Racinely,» 1 12 2019. [En ligne]. Available: <https://www.racinely.com/post/les-fonctions-d-activation-part-i>. [Accès le 02 05 2020] (Article Web).
- [32] P. Jain, «Complete Guide of Activation Functions» edition MC.IA, 2019.
- [33] D. Liu, « A Practical Guide to ReLU.» web article, Medium 2019.
- [34] sebastianraschka, «sebastianraschka.com,» 2015. [En ligne]. Available: [https://sebastianraschka.com/faq/docs/softmax\\_regression.html](https://sebastianraschka.com/faq/docs/softmax_regression.html). [Accès le 28 03 2020] (Article Web).
- [35] R. Gómez, « Understanding Categorical Cross-Entropy Loss, Binary Cross-Entropy Loss, Softmax Loss, Logistic Loss, Focal Loss and all those confusing names» neptune.ai, 2018.
- [36] S.-C. Guillaume, «Descente de Gradient – Gradient Descent.», edition machine learnia, 2019.
- [37] B. Tomas, «Day 69: rmsprop», web article, Medium, 2017.
- [38] J. L. B. Diederik P. Kingma, «ADAM : A METHOD FOR STOCHASTIC OPTIMIZATION» un document de conférence, ICLR 2015.
- [39] R. e. a. Sharma, «Bias-variance tradeoffs in program analysis.» San Diego, CA, USA, ACM SIGPLAN, 2014.
- [40] W. M. e. a. Van der Aalst, «Process mining: a two-step approach to balance between underfitting and overfitting», Software & Systems Modeling, 2010.
- [41] R. K. e. a. Srivastava, «Understanding locally competitive networks» conference paper ICLR, Lugano, Suisse 2014.
- [42] H. N. K. e. a. Al-Behadili, «2018» Symposium on Computer Applications & Industrial Electronics (ISCAIE), Rule pruning techniques in the ant-miner classification algorithm and its variants: A review..
- [43] D. Saunders, «The Bias-Variance Tradeoff», MasterThèse,UMass Amherst 2017.

- [44] D. B. e. a. Figueiredo Filho, «When is statistical significance not significant?» *Brazilian Political Science Review*, 2013.
- [45] ELITE DATA SCIENCE, «ELITE DATA SCIENCE» 2019. [En ligne]. Available: <https://elitedatascience.com/overfitting-in-machine-learning>. [Accès le 10 05 2020] (Article Web).
- [46] M. Paolini-Subramanya, «Medium,» 25 06 2018. [En ligne]. Available: <https://medium.com/datadriveninvestor/all-about-data-augmentation-9958f09368c6>. [Accès le 06 05 2020] (Article Web).
- [47] N. e. a. Srivastara, «Dropout :a simple way to prevent neural networks from overfitting» *The journal of machine learning research*, vol. 1, n°115, pp. 1929-1958, 2014.
- [48] S. e. a. Indolia, «Conceptual understanding of convolutional neural network-A deep learning approach», edition *Procedia Computer Science* , 2018.
- [49] L. D. a. D. Y. Abdel-hamid, «Exploring Convolutional Neural Network Structures and Optimization Techniques for Speech Recognition», p. 3366–3370, 08 2013.
- [50] N. B. A. e. a. Mustafa, Image processing of an agriculture produce: Determination of size and ripeness of a banana, *International Symposium on Information Technology*, 2008 .
- [51] A. G. Zakaria, «Classification des phases de la marche humaine par apprentissage profond – Application au domaine médical»Thèse Master, Alger, 2019.
- [52] Prabhu, «Understanding of Convolutional Neural Network (CNN) — Deep Learning,», *Medium*, 2018.
- [53] A. Dertat, «Applied Deep Learning - Part 4 : Convolutional Neural Networks,» *Towards data science*, 2017.
- [54] I. R. K. S. A. C. oAndrey Arsenov1, «Evolution of Convolutional Neural Network Architecture in Image Classification Problems,» Phd Thèse Kharkiv National University of Radio Electronics, Kharkiv, Ukraine, 2019, .
- [55] K. S. & A. Zisserman, «VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION,» *Visual Geometry Group, Department of Engineering Science, Phd Thèse, University of Oxford, londre*, 2014.
- [56] Cv-foundation, 2015. [En ligne]. Available: [https://www.cv-foundation.org/openaccess/content\\_cvpr\\_2015/papers/Szegedy\\_Going\\_Deeper\\_With\\_2015\\_CVPR\\_paper.pdf](https://www.cv-foundation.org/openaccess/content_cvpr_2015/papers/Szegedy_Going_Deeper_With_2015_CVPR_paper.pdf). [Accès le 6 05 2020] (Article Web).
- [57] H. Kaiming, X. Zhang, R. Shaoqing et S. Jian, «Deep Residual Learning for Image Recognition», *Microsoft Research,CPVR, Computer vision foundation*, 2015.

- [58] E. S. Olivas, «Handbook of Research on Machine Learning Applications and Trends: Algorithms, Methods, and Techniques: Algorithms, Methods and Techniques,» IGI Global, 2009.
- [59] J. e. a. Yosinski, «How transferable are features in deep neural networks? Advances in neural information processing systems», *Advances in Neural Information Processing Systems* 27, pages 3320-3328. Dec. 2014.
- [60] M. J. e. a. o Hasan, «Acoustic spectral imaging and transfer learning for reliable bearing fault diagnosis under variable speed conditions.», *Measurment*, n° 1138, pp. 620-631, 2019.
- [61] T. e. a. Tommasi, «Learning categories from few examples with multi model knowledge transfer,», *Transactions on Pattern Analysis and Machine Intelligence*, vol. 5, n° 136, pp. 928-941, 2013.
- [62] h. r. F. samadzadegan, «Automatic detection and classification of damaged buildings, using high resolution satellite imagery and vector data» dept. of surveying and geomatics engineering, engineering faculty, university of tehran, tehran, 2009.
- [63] W. L. Z. L. P. K. V. Z. Joseph Z.Xu, «Building Damage Detection in Satellite Imagery Using Convolutional Neural Networks», Google AI, 2018.
- [66] IBM, «ibm.com,» [En ligne]. Available: [https://www.ibm.com/support/knowledgecenter/SS3RA7\\_sub/modeler\\_crispdm\\_ddita/clementine/crisp\\_help/crisp\\_overview.html](https://www.ibm.com/support/knowledgecenter/SS3RA7_sub/modeler_crispdm_ddita/clementine/crisp_help/crisp_overview.html) (Article Web).
- [67] Xview2, «xview2.org,» [En ligne]. Available: <https://xview2.org/dataset> (Article Web).
- [68] Bouliech, «Wikimedia,» 4 10 2018. [En ligne]. Available: [https://commons.wikimedia.org/wiki/File:Carto\\_IA\\_deepLearning.svg](https://commons.wikimedia.org/wiki/File:Carto_IA_deepLearning.svg). [Accès le 06 03 2020] (Article Web).
- [69] Avinash Sharma V, «Understanding Activation Functions in Neural Networks,» Web Article, Medium, 2017.