



Université Djilali BOUNAAMA Khemis Miliana  
Faculté des Sciences et de la Technologies  
Département des mathématiques et de l'informatique

## Mémoire de fin d'études

Pour l'obtention du diplôme Master en Informatique

Option : Génie logiciel et systèmes distribués

---

# Détection des catastrophes naturelles à partir des réseaux sociaux

---

*Réalisé par :*

Mlle. FERRAH Safaa

*Encadré par :*

M. MEGHATRIA Riadh

*Soutenu le 18 juillet 2023, Devant le jury composé de :*

M. MOHAMED BOUZIANE Ilyes : UDBKM - Président

M. AZZOUZA Noureddine : UDBKM - Examineur

M.MEGHATRIA Riadh : UDBKM - Encadrant

Promotion : 2022/2023

---

## *Résumé*

Les catastrophes naturelles peuvent frapper à tout moment et en tout lieu, provoquant des dévastations considérables. Malheureusement, il n'est pas facile de percevoir rapidement l'ampleur d'une catastrophe naturelle. Toutefois, à l'ère des médias sociaux, Twitter est devenu une plateforme couramment utilisée par les individus pour partager leurs expériences et solliciter de l'aide en cas de catastrophe. Ainsi, Twitter est devenu une ressource inestimable pour les équipes d'intervention, leur permettant de rapidement identifier les zones affectées et coordonner les efforts de secours. Cependant, le défi réside dans le fait que trier manuellement les tweets liés aux catastrophes parmi le flot constant de messages postés chaque minute peut s'avérer décourageant.

Essentiellement, des approches traditionnelles d'apprentissage automatique et d'apprentissage profond ont été exploitées pour la classification des tweets liés aux catastrophes naturelles. Il a été constaté que ces techniques souffrent du problème de polysémie. Dans une tentative de remédier à ce problème, notre recherche présente un nouveau cadre basé sur la combinaison des modèles de langage Pré-entraîné (PLM) avec d'autres modèles de réseaux de neurones, PLM-BiLstm-CNN, pour classer les tweets liés aux catastrophes naturelles formés sur l'ensemble de données CrisisLEX T26.

Une analyse comparative du modèle proposé est réalisée par rapport aux modèles de l'état de l'art. Les résultats montrent que notre modèle proposé PLM-BiLstm-CNN démontre des performances satisfaisantes et meilleures que celles des modèles existants en termes de précision, de rappel, de mesure F et d'exactitude.

---

**Mots clés :** Classification des tweets, Catastrophes naturelles, Modèles de langage Pré-entraîné (PLM), RoBERTa, BERTweet, BiLSTM, CNN, CrisisLEX T26.

---

---

## *Abstract*

Natural disasters can strike at any time and in any place, causing significant devastation. Unfortunately, quickly perceiving the magnitude of a natural disaster is not easy. However, in the era of social media, Twitter has become a widely used platform for individuals to share their experiences and seek help during disasters. As such, Twitter has become an invaluable resource for disaster response teams, enabling them to swiftly identify affected areas and coordinate relief efforts. However, the challenge lies in manually sorting through disaster-related tweets amidst the constant stream of messages posted every minute, which can be discouraging.

Essentially, traditional machine learning and deep learning approaches have been utilized for the classification of disaster-related tweets. It has been observed that these techniques suffer from the problem of polysemy. To address this issue, our research presents a novel framework based on the combination of Pre-trained Language Models (PLM) with other neural network models, PLM-BiLstm-CNN, for classifying disaster-related tweets trained on the CrisisLEX T26 dataset.

A comparative analysis of the proposed model is conducted against state-of-the-art existing models. The results demonstrate that PLM-BiLstm-CNN outperforms other leading models in terms of accuracy, recall, F-measure, and precision.

---

**Keywords :** Tweet classification, Natural disasters, Pre-trained language models (PLM), RoBERTa, BERTweet, BiLSTM, CNN, CrisisLEX T26.

---

## ملخص

الكوارث الطبيعية يمكن أن تضرب في أي وقت وفي أي مكان، مسببةً دمارًا كبيرًا. للأسف، فإن تحديد حجم الكارثة الطبيعية بسرعة ليس أمرًا سهلاً. ومع ذلك، في عصر وسائل التواصل الاجتماعي، أصبح تويتر منصة شائعة للغاية يستخدمها الأفراد لمشاركة تجاربهم والبحث عن المساعدة خلال الكوارث. وبالتالي، أصبح تويتر مصدرًا لا يقدر بثمن لفرق الاستجابة للكوارث، مما يتيح لهم تحديد المناطق المتأثرة بسرعة وتنسيق جهود الإغاثة. ومع ذلك، يكمن التحدي في فرز التغريدات المتعلقة بالكوارث يدويًا في ظل تدفق مستمر للرسائل التي يتم نشرها كل دقيقة، مما يمكن أن يكون مثبطًا

مؤخرًا، تم استخدام التقنيات التقليدية للتعلم الآلي والتعلم العميق لتصنيف التغريدات المتعلقة بالكوارث. ومع ذلك، لوحظ أن هذه التقنيات تعاني من مشكلة التعددية في المعاني. لمعالجة هذه المشكلة، يقدم بحثنا إطارًا جديدًا يعتمد على مزيج من نماذج اللغة المدربة مسبقًا (PLM) مع نماذج الشبكات العصبية الأخرى ، PLM-BiLSTM-CNN ، لتصنيف التغريدات المتعلقة بالكوارث المدربة على مجموعة بيانات CrisisLEXT26 .

تم إجراء تحليل مقارنة للنموذج المقترح مقابل النماذج الموجودة المتقدمة في الوقت الحالي. توضح النتائج أن النموذج المقترح يفوق النماذج الأخرى الرائدة من حيث مقاييس الدقة و F1-SCORE .

---

**الكلمات المفتاحية:** تصنيف التغريدات ، الكوارث الطبيعية، نماذج اللغة المدربة مسبقًا (PLMs) ،  
RoBERTa ، BERTweet ، BiLSTM ، CNN ، CrisisLEX T26 .

---

---

## *Dédicace*

*À ma merveilleuse mère,  
le cœur battant de mon histoire,  
la source infinie de mon amour et la lumière qui guide mes pas.  
Tu es mon roc, ma force et ma tendresse.  
À toi, qui m'as offert un amour inconditionnel,  
je dédie cette mémoire en reconnaissance de tout ce que tu représentes dans ma vie.  
Merci d'avoir été ma plus grande inspiration et mon soutien constant.  
Je t'aime au-delà des mots.  
Ton souvenir reste gravé dans mon cœur, guidant mes pas et inspirant mes pensées.  
Même si tu n'es plus physiquement présente, ton héritage vivra à travers moi,  
et je continuerai à chérir ta mémoire avec gratitude et affection.*

*À mon père, celui qui a été la pierre angulaire de mon parcours académique,  
mon roc inébranlable et mon inspiration constante.  
Grâce à toi, j'ai appris l'importance de la persévérance,  
de la détermination et de la passion dans la poursuite de mes objectifs.  
Cette réalisation est dédiée à toi,  
pour ton amour inconditionnel, tes encouragements sans faille  
et ta confiance indéfectible en mes capacités.  
Je te suis profondément reconnaissante d'avoir façonné la personne que je suis  
aujourd'hui.  
Merci pour tout.*

*- Safaa -*

---

## *Remerciements*

Tout d'abord, je tiens à exprimer ma gratitude envers **Allah**, le Tout-Puissant, pour m'avoir accordé le courage et la patience nécessaires pour mener ce travail à son terme.

Je tenais à exprimer ma profonde gratitude et mes sincères remerciements à mon encadrant **M. MEGHATRIA Riadh** pour sa précieuse contribution à mon projet de fin d'études. Votre soutien inestimable a été l'un des piliers de mon parcours académique. Votre expertise, votre patience et votre encouragement constant ont été d'une valeur incommensurable. Vos conseils éclairés et votre volonté de partager vos connaissances ont joué un rôle essentiel dans le développement de mon projet, me permettant d'explorer de nouvelles idées et d'élargir mes horizons. Votre passion pour l'apprentissage, votre expertise dans votre domaine et votre dévouement envers vos étudiants ont été une source constante d'inspiration pour moi.

Je tiens également à exprimer ma gratitude envers **M. BAHLOUL Djamal** et **Dr. AIT ABDERRAHIM Imène**, Je vous adresse mes plus sincères remerciements. Votre impact positif sur ma vie restera à jamais gravé dans ma mémoire. Merci d'avoir été des enseignants exceptionnels, des guides inspirants et des mentors bienveillants.

Je souhaite remercier mon pilier de force, mon père. Je te suis infiniment reconnaissant pour tout ce que tu as fait pour moi. À mes sœurs et frères, je suis constamment béni de vous avoir à mes côtés. Et à mes chers neveux, qui sont de véritables sources de bonheur, votre présence illumine mes journées.

Enfin, je tiens à exprimer ma profonde gratitude à mes amis proches **Hafsa, Rahma, Marwa, Hadjer** et **Aicha**, pour votre soutien indéfectible tout au long de mon parcours. Votre amour, vos encouragements et votre compréhension ont été une source de force et de motivation, sans lesquels cette réalisation n'aurait pas été possible.

# Table des matières

Introduction générale	1
<b>Chapitre 1: Introduction : Catastrophes Naturelles, Twitter et Apprentissage Automatique</b>	<b>3</b>
1.1 Introduction	4
1.2 Les médias sociaux	4
1.2.1 Micro-blogs	4
1.2.2 Twitter	4
1.3 La définition d'un tweet	5
1.4 Les types d'un tweet	5
1.4.1 Le tweet classique	5
1.4.2 La mention	5
1.4.3 La réponse	5
1.4.4 Retweet	5
1.4.5 Hashtag	6
1.5 La définition d'une catastrophe	6
1.6 Les catastrophes naturelles	6
1.7 Les différentes phases du cycle de gestion d'une catastrophe naturelle	7
1.7.1 PRÉVENTION	7
1.7.2 PRÉPARATION	7
1.7.3 RÉACTION	7
1.7.4 REDRESSEMENT	7
1.8 Communication des catastrophes	8
1.9 Réseaux sociaux pendant les situations de catastrophe	9
1.9.1 Utilisation de Twitter durant les catastrophes naturelles	9
1.10 Définition du problème	10
1.11 L'apprentissage automatique	10
1.11.1 Apprentissage supervisé	11
1.11.1.1 Régression logistique	11
1.11.1.2 Arbre de décision	12
1.11.1.3 Random forest	13
1.11.1.4 La machine à vecteurs de support SVM	13
1.11.1.5 K plus proche voisin KNN	14
1.11.1.6 Naive Bayes	15
1.11.2 Apprentissage non supervisé	15

1.12	L'apprentissage profond . . . . .	15
1.12.1	Les réseaux de neurones convolutifs (CNN) . . . . .	16
1.12.2	Les réseaux neuronaux récurrents (RNN) . . . . .	16
1.12.2.1	Long Short-Term Memory (LSTM) . . . . .	17
1.13	L'apprentissage par transfert . . . . .	17
1.13.1	Les transformateurs . . . . .	17
1.13.2	Les modèles de langage Pré-entraîné (PLM) . . . . .	17
1.13.2.1	BERT . . . . .	18
1.13.2.2	RoBERTa . . . . .	19
1.13.2.3	DistilBERT . . . . .	19
1.13.2.4	BERTweet . . . . .	20
1.13.2.5	GPT . . . . .	20
1.14	Les embeddings de mots (word embeddings) . . . . .	20
1.15	Conclusion . . . . .	21
<b>Chapitre 2: État de l'art</b>		<b>22</b>
2.1	Introduction . . . . .	23
2.2	Historique . . . . .	23
2.3	Paradigmes pour la détection automatique des catastrophes naturelles . . . . .	24
2.4	Méthodes classiques . . . . .	25
2.4.1	Filtrage par mots clés . . . . .	25
2.4.2	Crowdsourcing . . . . .	25
2.5	Méthodes automatisée . . . . .	26
2.5.1	Méthodes traditionnelles d'apprentissage automatique . . . . .	26
2.5.2	Méthodes basées sur les réseaux de neurones(NN) et l'apprentissage profond . . . . .	27
2.6	Résumé des travaux récents sur la détection des catastrophes naturelles à partir des réseaux sociaux . . . . .	28
2.7	Conclusion . . . . .	30
<b>Chapitre 3: Conception et implémentation</b>		<b>31</b>
3.1	Introduction . . . . .	32
3.2	Modèles proposés . . . . .	32
3.2.1	Aperçu du Modèle proposé PLM-BiLstm-CNN . . . . .	33
3.2.1.1	Phase 01 : PLM . . . . .	33
3.2.1.2	Phase 02 : BiLSTM . . . . .	34
3.2.1.3	Phase 03 : CNN . . . . .	34
3.3	Description du dataset . . . . .	35
3.3.1	CrisisLexT26 dataset . . . . .	36
3.4	Stratégies d'évaluation . . . . .	36
3.4.1	Sélection des ensembles de données . . . . .	37
3.4.2	Validation croisée . . . . .	37
3.4.3	Métriques d'évaluation . . . . .	37
3.4.4	L'exactitude (Accuracy) . . . . .	38

## Table des matières

---

3.4.5	La précision (Precision)	39
3.4.6	Le rappel (Recall)	39
3.4.7	Le score F1 (F1-score)	39
3.5	Stratégies d'optimisation	39
3.5.1	Paramétrage	39
3.5.1.1	La taille de lot (Batch size)	39
3.5.1.2	Taux d'apprentissage (Learning rate)	39
3.5.1.3	Nombre d'époques (epochs)	40
3.5.1.4	L'arrêt précoce (Early stopping)	40
3.5.1.5	Extra paramètres	40
3.6	Étapes du processus	40
3.6.1	Prétraitement	40
3.6.1.1	Filtrage	40
3.6.1.2	Élimination des mots d'arrêt (Stop words)	40
3.6.1.3	Racinisation(Stemming)	41
3.6.1.4	Lemmatisation	41
3.6.1.5	Tokenisation	41
3.6.1.6	CrisisLexT26 Prétraitement	41
3.6.2	Dévision du dataset	41
3.6.3	Les types de classification	42
3.6.3.1	La classification multiclass	42
3.6.3.2	La classification binaire	43
3.6.4	visualisation de données	43
3.7	Implémentation	44
3.7.1	Langage	44
3.7.1.1	Python	44
3.7.2	Outils	44
3.7.2.1	Google Colab	44
3.7.3	Plateforme et API	45
3.7.3.1	NLTK	45
3.7.4	Librairies	45
3.7.4.1	Transformers	45
3.7.4.2	Scikit-learn (sklearn)	45
3.7.4.3	Pandas	45
3.7.4.4	Matplotlib	45
3.7.4.5	Seaborn	45
3.7.4.6	Nlpaug	46
3.7.5	Implémentation des PLMs	46
3.7.5.1	Le choix du Meilleur PLM(Classification multiclass )	46
3.7.5.2	La combinaison des PLMs avec BiLstm	50
3.7.5.3	La combinaison des PLM-BiLSTM avec CNN	51
3.7.5.4	L'ajout d'un optimiseur	52
3.7.6	Implémentation des PLMs (Classification binaire)	53

## Table des matières

---

3.7.6.1	Le choix du Meilleur PLM . . . . .	53
3.7.6.2	La combinaison des PLMs avec BiLSTM . . . . .	57
3.7.6.3	La combinaison des PLMs avec BiLSTM et CNN . . . . .	58
3.8	Comparaison entre les résultats de nos modèles et du baselines . . . . .	58
3.9	Conclusion . . . . .	59
	<b>Conclusion et perspectives</b>	<b>60</b>

# Table des figures

1.1	Les différentes phases du cycle de gestion d'une catastrophe. . . . .	8
1.2	Les différentes phases du cycle de gestion d'une catastrophe . . . . .	11
1.3	Régression logistique . . . . .	12
1.4	Arbre de décision. . . . .	12
1.5	Random forest . . . . .	13
1.6	support vector machine . . . . .	14
1.7	KNN . . . . .	14
1.8	Naive Bayes. . . . .	15
1.9	L'architecture des transformateurs . . . . .	18
1.10	Schéma simplifié de l'architecture du modèle BERT . . . . .	19
2.1	Approches de la détection automatique des catastrophes naturelles . . . . .	24
3.1	Le modèle PLM-BiLstm-CNN . . . . .	33
3.2	Le modèle PLMsEnsemble . . . . .	35
3.3	Hashtags choisis pour CrisisLexT26 Dataset . . . . .	36
3.4	Validation croisée . . . . .	37
3.5	Matrice de confusion pour $n = 2$ . . . . .	38
3.6	La distribution des multiclassés dans CrisisLexT26. . . . .	43
3.7	La distribution des binaires classes dans CrisisLexT26. . . . .	44
3.8	Comparaison entre les PLMs selon la taille du lot. . . . .	47
3.9	Comparaison entre les différentes versions de prétraitement. . . . .	48
3.10	Comparaison des résultats selon le taux d'apprentissage. . . . .	49
3.11	PLM & PLM-BiLstm . . . . .	51
3.12	PLM-BiLstm & PLM-BiLSTM-CNN . . . . .	52
3.13	Comparaison entre les PLMs selon la taille du lot. . . . .	54
3.14	Comparaison entre les différentes versions de prétraitement. . . . .	55
3.15	Comparaison entre les différentes versions de prétraitement. . . . .	56
3.16	Comparaison des Plms selon le meilleur taux d'apprentissage. . . . .	57

# Liste des tableaux

2.1	Travaux connexes . . . . .	29
3.1	L'échantillonnage du dataset CrisisLexT26 après la division . . . . .	42
3.2	Comparaison des résultats selon la taille du lot. . . . .	46
3.3	Compararésultats selon le type de prétraitement du dataset. . . . .	47
3.4	Comparaison des résultats selon le taux d'apprentissage. . . . .	49
3.5	Les PLMs choisi avec les meilleurs hyperparamètres . . . . .	49
3.6	Les résultats du PLM-BiLSTM . . . . .	50
3.7	Comparaison des résultats selon le taux d'apprentissage. . . . .	50
3.8	Les résultats du PLM-BiLSTM-CNN . . . . .	51
3.9	Comparaison des résultats selon le taux d'apprentissage. . . . .	52
3.10	L'ajout d'un optimiseur. . . . .	53
3.11	Comparaison des résultats selon la taille du lot (Classification binaire). . .	53
3.12	Comparaison des résultats selon le type de prétraitement du dataset. . . .	54
3.13	Comparaison entre la version prétraitée et non prétraitée du dataset (taille du lot = 32). . . . .	55
3.14	Les hyperparamètres choisi. . . . .	56
3.15	Comparaison des Plms selon la variation du taux d'apprentissage. . . . .	56
3.16	Classement des PLMs selon les meilleurs résultats. . . . .	57
3.17	Le taux d'apprentissage compatible pour PLM-BiLSTM. . . . .	58
3.18	Le taux d'apprentissage compatible pour PLM-BiLSTM-CNN. . . . .	58
3.19	Comparaison entre les résultats de nos modèles et du baselines . . . . .	58

# Acronymes

**ACC** : Accuracy .

**BERT** : Bidirectional Encoder Representations from Transformers.

**BiLSTM** : Bidirectional long short-term memory.

**CNN** : Convolutional Neural Network.

**DL** : Deep Learning.

**DNN** : Deep Neural Network.

**FN** : False Negative.

**FP** : False Positive.

**IA** : Intelligence Artificielle.

**KNN** : K-Nearest Neighbors.

**LSTM** : Long Short-Term Memory.

**ML** : Machine Learning.

**NB** : Naïve Bayes.

**NLTK** : Natural Language Toolkit.

**NN** : Neural Networks.

**PLM** : Pretrained Language Models.

**RF** : Random Forest.

**RNN** : Recurrent Neural Networks.

**TF-IDF** : Term Frequency-Inverse Document Frequency.

**TN** : True Negative.

**TP** : True Positive.

**SVM** : Support Vector Machine.

**SGD** : Stochastic Gradient Descent.

# *Introduction générale*

## **Contexte**

De nos jours, dans un monde interconnecté, les médias sociaux ont émergé en tant qu'outil essentiel de communication quotidienne. Il n'est donc pas surprenant que lors de périodes de calamité, les gens se tournent instinctivement vers ces plateformes pour trouver du réconfort et du soutien. La recherche a clairement démontré l'usage répandu de Twitter en période de crise, les individus exploitant ses fonctionnalités à plusieurs fins. Cela comprend la fourniture de détails en temps réel sur l'évolution des événements, la vérification du bien-être de leurs proches, la recherche de soutien émotionnel et la collecte d'informations complètes sur l'ampleur de la catastrophe.

De plus, les organisations humanitaires reconnaissent de plus en plus la valeur considérable de l'exploitation des tweets pour extraire des informations essentielles en vue d'une réponse efficace aux catastrophes. Elles cherchent à comprendre la situation dans son ensemble, tout en répondant à des besoins d'informations spécifiques tels que l'évaluation des dommages aux infrastructures ou l'identification des besoins urgents des personnes touchées. Ces organisations s'appuient sur la vaste réserve d'informations offerte par Twitter.

## **Problématique**

Le volume substantiel de données générées par les médias sociaux offre une opportunité sans précédent pour l'analyse des catastrophes. Twitter, en tant que plateforme sociale de premier plan, génère quotidiennement un nombre impressionnant de 500 millions de tweets. De nombreuses agences se fient à Twitter pour surveiller et réagir rapidement aux événements catastrophiques. Cependant, la construction d'un modèle prédictif précis pour identifier les tweets liés aux catastrophes présente des défis, car ils manquent souvent de contexte suffisant. De plus, il peut être difficile de distinguer les tweets liés aux catastrophes des tweets réguliers en raison de l'abondance des informations et l'ambiguïté des mots. À la présence de ces défis, comment peut-on construire un modèle prédictif précis pour identifier les tweets liés aux catastrophes, en tenant compte du manque de contexte et de l'ambiguïté des mots présents dans ces messages ?

Des preuves récentes mettent en évidence des avancées significatives dans les modèles de détection des catastrophes grâce à l'utilisation de techniques d'encodage de mots

contextuels (modèles de langage Pré-entraîné (PLM)). Contrairement aux méthodes traditionnelles sans contexte, ces techniques prennent en compte le contexte entourant un mot, ce qui permet d'obtenir de meilleurs résultats.

## Objectifs

Notre recherche vise à explorer une gamme de modèles d'apprentissage ensembliste qui combinent des modèles de langage Pré-entraîné (PLM) avec des algorithmes de réseaux neuronaux profonds. Notre objectif est d'évaluer de manière approfondie leur efficacité dans l'identification des communications liées aux catastrophes sur Twitter, qu'elles soient informatives ou non.

## Organisation du mémoire

Ce mémoire est structuré en trois chapitres :

Chapitre 1 : **"Introduction"**

Ce premier chapitre présente les raisons pour lesquelles les réseaux sociaux sont devenus une source d'information cruciale lors des catastrophes. Le chapitre explore également les différentes approches d'apprentissage automatique et d'apprentissage profond utilisées dans ce domaine, mettant en lumière l'importance des modèles pré-entraînés et des architectures neuronales avancées.

Chapitre 2 : **"État de l'art"**

Ce chapitre vise à explorer les avancées récentes, les méthodes et les approches utilisées par les chercheurs pour résoudre ce problème. Il examine les différentes techniques de détection des catastrophes naturelles. Ce chapitre offre un aperçu complet de l'état de l'art, permettant ainsi de positionner notre travail de recherche dans le contexte actuel et de mettre en évidence les lacunes ou les opportunités pour améliorer les performances de détection des catastrophes naturelles à partir des réseaux sociaux.

Chapitre 3 : **"Conception et implémentation"**

Ce chapitre présente les différentes étapes du processus de développement de notre système, en commençant par la définition des objectifs et des exigences. Nous décrivons ensuite l'architecture globale de notre système. Nous abordons également les détails de l'implémentation, y compris les choix technologiques et les bibliothèques utilisées. Ce chapitre met en lumière les décisions prises lors de la conception et fournit un aperçu du fonctionnement interne de notre système de détection des catastrophes naturelles à partir des réseaux sociaux.

# Chapitre 1

## Introduction : Catastrophes Naturelles, Twitter et Apprentissage Automatique

### 1.1 Introduction

La gestion de crise est cruciale pour atténuer les conséquences des événements imprévisibles tels que les catastrophes naturelles, les attaques terroristes et les pandémies. Les plateformes de médias sociaux, notamment Twitter, sont devenues des outils inestimables pour obtenir des informations en temps réel et partager des mises à jour lors de situations de crise, contribuant ainsi à une meilleure gestion de ces situations.

Dans ce chapitre nous allons aborder quelques notions générales, ainsi que les différentes phases du cycle de gestion d'une catastrophe naturelle et quelques notions dans le domaine d'apprentissage automatique et profond. Les différentes phases du cycle de gestion d'une catastrophe naturelle.

### 1.2 Les médias sociaux

Les médias sociaux font référence à une variété d'outils électroniques, de technologies et d'applications Web 2.0 qui permettent la communication interactive et l'échange de contenu, permettant aux utilisateurs de passer facilement du rôle de consommateur à celui de producteur de contenu. [25]

#### 1.2.1 Micro-blogs

Des plateformes de microblogging permettent de partager facilement des mises à jour courtes sur votre vie en déplacement avec vos amis et observateurs intéressés. Ces outils offrent une forme de communication légère et facile, en permettant aux utilisateurs de diffuser et de partager des informations sur leurs activités, opinions et statuts. Twitter est l'une des plateformes de microblogging les plus populaires.

Les microblogs se situent quelque part entre les blogs et la messagerie instantanée. Ils visent à diffuser rapidement des informations en se limitant à l'essentiel. Ils permettent l'archivage sur le Web et le partage en temps réel de contenu pertinent pour leurs auteurs, tout comme la messagerie instantanée. [18]

#### 1.2.2 Twitter

Est un réseau social de microblogage géré par l'entreprise Twitter . Il permet à un utilisateur d'envoyer gratuitement des micromessages, appelés tweets, sur internet, par messagerie instantanée. Ces messages sont limités à 280 caractères.

Dans le contexte de catastrophes, Twitter peut être utilisé comme un outil à la fois pour diffuser des informations et pour recueillir des mises à jour en temps réel auprès des personnes sur le terrain.

### 1.3 La définition d'un tweet

Message court, limité à 280 caractères. Publié sur le service Twitter et contenant du texte, des photos, un GIF ou une vidéo. Les utilisateurs enregistrés peuvent publier, aimer et retweeter des tweets, mais les utilisateurs non enregistrés ne peuvent lire que ceux qui sont accessibles au public.

### 1.4 Les types d'un tweet

Sachez qu'il existe différents types de tweets sur Twitter. Par exemple :

#### 1.4.1 Le tweet classique

C'est un message publié sur Twitter contenant du texte, des photos, un GIF et/ou une vidéo. Il s'agit donc de tous les tweets qui ne commencent pas par le symbole "@".

#### 1.4.2 La mention

C'est un tweet qui contient le nom d'utilisateur d'un autre compte Twitter. Il est précédé du symbole "@".

La page de profil d'un compte ne comporte pas les Tweets qui le mentionnent. Néanmoins, vous pouvez rechercher sur Twitter les Tweets qui mentionnent le nom d'utilisateur en question.

#### 1.4.3 La réponse

Une réponse est une réaction à un tweet d'une tierce personne. Les réponses des utilisateurs dont les Tweets sont protégés ne sont pas visibles par les autres utilisateurs.

#### 1.4.4 Retweet

Un retweet fait référence à l'acte de republier ou de transmettre un message à ses abonnés Twitter. En règle générale, l'auteur original du tweet est crédité pour le retweet, ce qui motive les utilisateurs à créer un contenu facilement partageable et peut accroître leur présence sur Twitter. Le principal avantage des retweets est qu'ils augmentent la visibilité du tweet d'origine. En étant diffusés à des personnes qui ne suivent peut-être pas l'auteur original, les retweets étendent la portée du contenu du tweet.

### 1.4.5 Hashtag

Les hashtags sont une combinaison de mots-clés ou phrases précédés du symbole "#", ils aident à regrouper les tweets et conversations autour d'un thème similaire afin que les gens puissent facilement trouver et suivre ce qui les intéresse. Alors quand les gens recherchent et cliquent sur un hashtag spécifique, ils pourront trouver tous les profils et publications publiques qui utilisent ce hashtag.

## 1.5 La définition d'une catastrophe

Une catastrophe peut être définie comme un événement soudain et inattendu qui cause des dommages importants, la destruction et la perte de vies et de biens.

Les catastrophes peuvent avoir des conséquences de grande portée, y compris des répercussions économiques, sociales et environnementales. Des stratégies efficaces de gestion des catastrophes sont essentielles pour minimiser les risques et les répercussions des catastrophes et pour assurer la sécurité et le bien-être des personnes.

Les catastrophes peuvent être causées par :

Des incidents d'origine humaine comme les accidents industriels, le terrorisme et la guerre,

Ou par des phénomènes naturels comme les tremblements de terre, les inondations, les ouragans et les feux de forêt. Et c'est le type sur lesquelles nous nous sommes concentrés dans notre étude.

## 1.6 Les catastrophes naturelles

Les catastrophes naturelles sont des événements catastrophiques qui se produisent naturellement et qui peuvent causer des dommages importants à l'environnement, aux biens et à la vie humaine. Ces événements sont hors de contrôle humain et peuvent comprendre des inondations, des ouragans, des tremblements de terre, des tsunamis, des éruptions volcaniques, des feux de forêt, des sécheresses et des glissements de terrain.

Les catastrophes naturelles peuvent endommager gravement les infrastructures, perturber les services essentiels et entraîner la perte de vies humaines et le déplacement de collectivités. Des stratégies efficaces de gestion des catastrophes, y compris des plans de réduction des risques, de préparation et d'intervention, sont essentielles pour minimiser les répercussions des catastrophes naturelles et assurer la sécurité des personnes et des collectivités.

## **1.7 Les différentes phases du cycle de gestion d'une catastrophe naturelle**

La gestion d'une catastrophe naturelle implique un effort d'intervention coordonné visant à minimiser l'impact de la catastrophe et à assurer la sécurité et le bien-être des personnes et des communautés touchées. Voici quelques étapes clés dans la gestion d'une catastrophe naturelle :

### **1.7.1 PRÉVENTION**

recouvre Toute action visant à réduire les risques ou à atténuer les conséquences préjudiciables d'une catastrophe pour les personnes, les animaux, l'environnement et les biens, y compris pour le patrimoine culturel.

### **1.7.2 PRÉPARATION**

on entend L'état de préparation et la capacité des moyens humains et matériels, des structures, des communautés et des organisations permettant d'assurer une réaction rapide et efficace face à une urgence, obtenus par des mesures anticipatoires .

### **1.7.3 RÉACTION**

La fourniture de services d'urgence et de l'assistance publique pendant ou immédiatement après une catastrophe afin de sauver des vies humaines, de réduire les impacts sur la santé, d'assurer la sécurité du public et de répondre aux besoins essentiels de subsistance des personnes .

### **1.7.4 REDRESSEMENT**

est La restauration, l'amélioration, l'installation des moyens de subsistance et des conditions de vie des communautés touchées par des catastrophes, y compris les efforts visant à réduire les facteurs de risque .

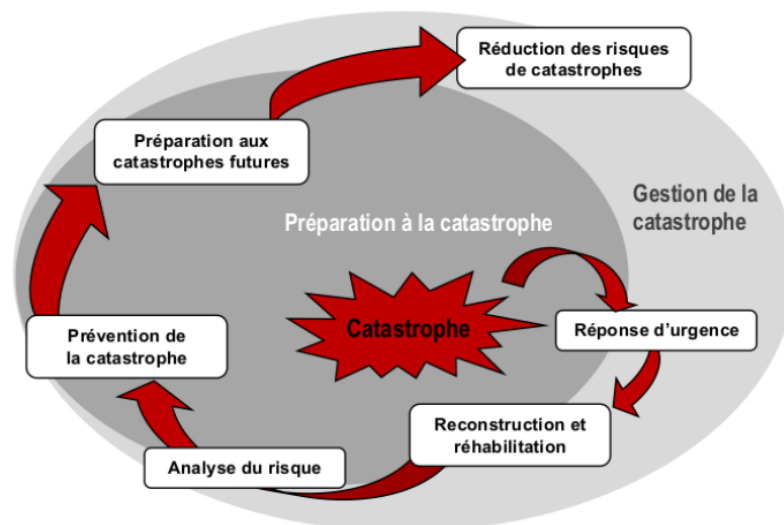


FIGURE 1.1 – Les différentes phases du cycle de gestion d’une catastrophe.  
[1]

## 1.8 Communication des catastrophes

La communication sur les risques joue un rôle crucial dans la gestion efficace des catastrophes naturelles et autres crises. Dans le passé, la communication des risques était souvent un processus à sens unique, les experts émettant des jugements et informant le public. Cependant, cette approche a négligé la manière dont le public interprète et perçoit le risque, qui peut être influencé par des facteurs tels que les expériences passées, l’incertitude et la susceptibilité à l’influence. Pour résoudre ces problèmes, les stratégies modernes de communication des risques se concentrent sur l’établissement d’un dialogue structuré entre les individus, les groupes et les institutions afin de promouvoir une compréhension commune du risque et de son acceptabilité.

Un élément clé de la communication moderne sur les risques est l’utilisation de méthodes interactives et participatives. Cela implique d’impliquer les parties prenantes dans le processus de communication des risques, par exemple par le biais de réunions publiques, de forums en ligne et d’autres formes de sensibilisation. En impliquant les parties prenantes dans le processus, la communication des risques peut être adaptée à leurs besoins et préoccupations spécifiques, et leur contribution peut être utilisée pour façonner l’élaboration de stratégies de gestion des risques.

De plus, les stratégies modernes de communication des risques utilisent souvent une gamme de canaux de communication pour atteindre divers publics. Cela peut comprendre les médias traditionnels comme la télévision et la radio, ainsi que les médias sociaux et d’autres plateformes numériques. En utilisant plusieurs canaux, la communication des risques peut atteindre un public plus large et mieux interagir avec différents groupes et communautés.

## 1.9 Réseaux sociaux pendant les situations de catastrophe

Déclare Daniel Aldrich, un professeur du Nord-Est, directeur du programme de sécurité et de résilience de l'université et codirecteur du Global Resilience Institute à Northeastern Global News Les smartphones et les médias sociaux ont radicalement changé et démocratisé les efforts de secours en cas de catastrophe,

Pendant des centaines d'années, la gestion des catastrophes était un processus à sens unique, dit-il. C'était soit du haut vers le bas - lorsque les annonces, les équipes de secours, les efforts de secours et l'aide venaient du gouvernement - soit du bas vers le haut, lorsque les résidents appelaient les services d'urgence pour demander de l'aide.

Les médias sociaux ont renversé la situation Au lendemain du tremblement de terre meurtrier qui a frappé la Turquie et la Syrie le 6 février, de nombreuses personnes piégées sous les décombres se sont tournées vers les médias sociaux pour demander leur secours.

Vu que les efforts de gestion et de secours en cas de catastrophe manquent souvent d'informations en temps réel sur les catastrophes en cours, les réseaux sociaux peuvent fréquemment fournir des détails sur les développements d'une crise beaucoup plus rapidement que les sources traditionnelles.

De nombreux citoyens ont été sauvés lors de la crise de tremblement de terre naturelle syrienne grâce à la large diffusion d'hashtag HelpSyria en tendance sur Twitter. Ce dernier est maintenant devenu un outil qui facilite la tâche aux secouristes à intervenir au plus vite en cas de catastrophe naturelle pour repérer les victimes, pour trouver des lieux de refuge, et pour coordonner l'aide humanitaire. La prévention est aussi rendue plus efficace. Twitter sera de plus en plus utilisé dans la gestion des catastrophes, mais il n'est pas forcément sans risque en raison de son caractère ouvert qui rend le suivi plus difficile.[29]

### 1.9.1 Utilisation de Twitter durant les catastrophes naturelles

Twitter, un site de microblogging, sert de forme immédiate de diffusion d'informations dans le monde ; c'est un endroit où les gens convergent numériquement pendant les catastrophes . Les données informatives provenant de sites tels que Twitter peuvent soit être obtenues directement auprès des spectateurs d'une catastrophe, soit "dérivées - c'est-à-dire des informations sous forme de reposts ou de pointeurs vers des informations disponibles ailleurs".

L'analyse des données informatives des tweets permettra de mieux comprendre les tendances au cours d'une catastrophe. Les sources de données informatives et leurs branches ( dérivées ) peuvent être cartographiées pour ( identifier les nœuds (par exemple, les utilisateurs) avec les connexions les plus sortantes (par exemple, les réponses envoyées) ou entrantes (par exemple, les retweets reçus) ), ce qui peut conduire à identifier de nombreux modèles, y compris les ( mesures d'intermédiarité ou de centralité ) et les ( groupes et divisions dans le réseau ). S'il existait un système pour filtrer les informations des tweets conversationnels, les efforts de secours auraient un énorme avantage pour décider

quoi faire et où concentrer les efforts de secours. En combinaison avec la géolocalisation, l'analyse des sentiments et d'autres recherches d'exploration de données sur les réseaux sociaux, le filtrage informatif des réseaux sociaux peut conduire à des décisions plus correctes, entraînant moins de victimes ou de blessés. Notre objectif est de concevoir de nouvelles fonctionnalités qui peuvent être utilisées comme entrée pour les classificateurs d'apprentissage automatique afin d'identifier automatiquement et avec précision les tweets informatifs du reste en temps opportun.

### 1.10 Définition du problème

Les médias sociaux jouent un rôle essentiel dans l'échange d'informations pendant Calamités, car il permet aux utilisateurs de partager, contribuer au suivi des conditions en signalant incidents liés à des événements catastrophiques.

D'autre part, les données volumineuses et bruitées générées dans les données des médias sociaux créent des difficultés dans la gestion des crises en limitant la disponibilité des informations issues des réseaux sociaux. Différentes organisations doivent extraire diverses informations des tweets pour améliorer les opérations de gestion des catastrophes.

Cependant, les défis résident dans la sélection des tweets provenant d'autres informations telles que les dommages subis, les opinions et les réponses sympathiques, concevoir des fonctionnalités appropriées pour discerner et identifier des classes spécifiques est une tâche difficile à effectuer, en différenciant les tweets liés à la catastrophe des tweets non liés à la catastrophe, et aussi avec rares étiquettes.

La classification des tweets liés à une catastrophe a une importance énorme en termes de recherche. Des investigations .la majorité des méthodes actuelles utilisent l'apprentissage automatique et l'apprentissage profond permettant à Twitter de stimuler l'engagement, de présenter le contenu le plus pertinent pour ses utilisateurs et de promouvoir des communications plus saines.

Dans ce qui suit nous allons définir l'apprentissage automatique avec ces approches les plus utilisées dans le domaine de la détection ainsi que l'apprentissage profond.

### 1.11 L'apprentissage automatique

L'apprentissage automatique (ML) est une forme d'intelligence artificielle (IA) qui est axée sur la création de systèmes qui apprennent, ou améliorent leurs performances, en fonction des données qu'ils traitent.

L'intelligence artificielle est un terme large qui désigne des systèmes ou des machines simulant une forme d'intelligence humaine.

Il existe trois types de base d'apprentissage automatique : l'apprentissage non supervisé, l'apprentissage supervisé et l'apprentissage par renforcement.

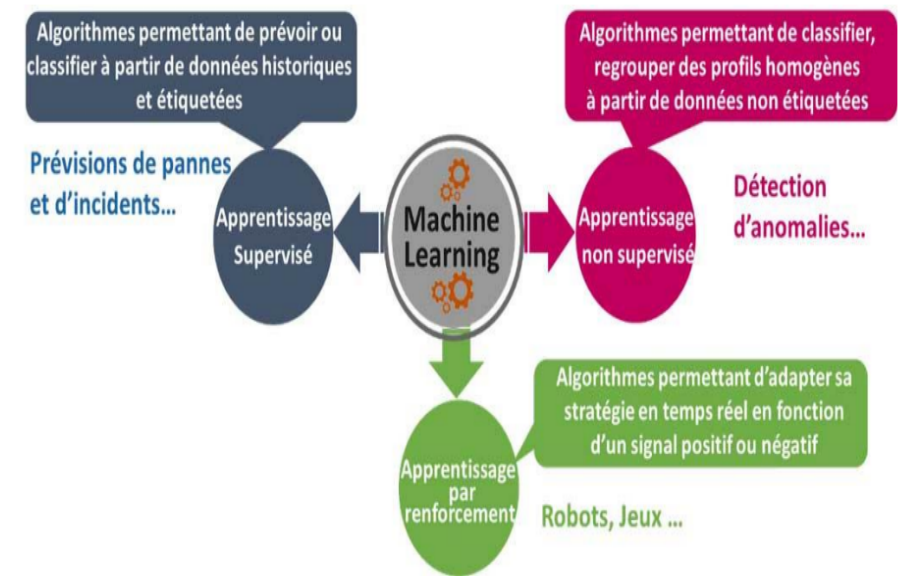


FIGURE 1.2 – Les différentes phases du cycle de gestion d’une catastrophe [2]

### 1.11.1 Apprentissage supervisé

Apprend une fonction pour prédire une étiquette définie en fonction des données d’entrée. Il peut s’agir soit de classer des données dans une catégorie (problème de classification), soit de prévoir un résultat (algorithmes de régression). Nous citons ci-après quelques algorithmes connus d’apprentissage supervisé pour les problèmes de classification :

#### 1.11.1.1 Régression logistique

Logistic Regression utilise la fonction sigmoïde qui est une ligne semblable à des gri-bouillis pour renvoyer la probabilité d’une étiquette. Il est largement utilisé lorsque le problème de classification est binaire — vrai ou faux, gagnant ou perdant, positif ou négatif...

La fonction sigmoïde génère une sortie de probabilité. En comparant la probabilité avec un seuil prédéfini, l’objet est affecté à une étiquette en conséquence.[44]




FIGURE 1.3 – Régression logistique .  
[3]

### 1.11.1.2 Arbre de décision

Decision Tree construit des branches d'arbre dans une approche hiérarchique et chaque branche peut être considérée comme une instruction if-else. Les branches se développent en partitionnant l'ensemble de données en sous-ensembles en fonction des caractéristiques les plus importantes. La classification finale se produit aux feuilles de l'arbre de décision. Il est ainsi nommé car il commence par une seule décision simple ou racine, qui se divise ensuite en un certain nombre de branches jusqu'à ce qu'une décision ou une prédiction soit prise, formant un arbre.[47]




FIGURE 1.4 – Arbre de décision.  
[3]

### 1.11.1.3 Random forest

Random forest est une collection d'arbres de décision. Il s'agit d'un type courant de méthodes d'ensemble qui agrègent les résultats de plusieurs prédicteurs. Random forest utilise en outre une technique d'ensachage qui permet à chaque arbre d'être entraîné sur un échantillonnage aléatoire de l'ensemble de données d'origine et d'obtenir le vote majoritaire des arbres. Comparé à Decision Tree, il a une meilleure généralisation mais moins interprétable, en raison de plus de couches ajoutées au modèle. Cet algorithme peut être utilisé à la fois pour des tâches de classification et de régression.[6]




FIGURE 1.5 – Random forest .  
[3]

### 1.11.1.4 La machine à vecteurs de support SVM

La machine à vecteurs de support trouve le meilleur moyen de classer les données en fonction de la position par rapport à une frontière entre classe positive et classe négative. Cette frontière est connue sous le nom d'hyperplan qui maximise la distance entre les points de données de différentes classes. Semblable à l'arbre de décision et à la forêt aléatoire, la machine à vecteurs de support peut être utilisée à la fois dans la classification et la régression, SVC (classificateur de vecteurs de support) est pour le problème de classification.[11]




FIGURE 1.6 – support vector machine .  
[3]

#### 1.11.1.5 K plus proche voisin KNN

On pouvait penser à k algorithmme du plus proche voisin comme représentant chaque point de données dans un espace à n dimensions - qui est défini par n caractéristiques. Et il calcule la distance entre un point à un autre, puis attribue l'étiquette des données non observées en fonction des étiquettes des points de données observés les plus proches. KNN peut également être utilisé pour construire un système de recommandation. Il peut être utilisé pour la régression ainsi que pour la classification, mais il est prin cipalement utilisé pour les problèmes de classification.[20]




FIGURE 1.7 – KNN .  
[3]

### 1.11.1.6 Naive Bayes

Naive Bayes est basé sur le théorème de Bayes - une approche pour calculer la probabilité conditionnelle basée sur des connaissances antérieures et l'hypothèse naïve selon laquelle chaque caractéristique est indépendante l'une de l'autre. Le plus grand avantage de Naive Bayes est que, bien que la plupart des algorithmes d'apprentissage automatique reposent sur une grande quantité de données d'entraînement, il fonctionne relativement bien même lorsque la taille des données d'entraînement est petite.[21]




FIGURE 1.8 – Naive Bayes.  
[3]

### 1.11.2 Apprentissage non supervisé

Ce type d'apprentissage utilise des algorithmes d'apprentissage automatique pour analyser et regrouper des ensembles de données non étiquetés. Ces algorithmes découvrent des modèles ou des regroupements de données cachés sans intervention humaine. Sa capacité à découvrir les similitudes et les différences dans les informations en fait la solution idéale pour l'analyse exploratoire des données.

## 1.12 L'apprentissage profond

L'apprentissage en profondeur, également connu sous le nom de "deep learning" ou "DL", est un domaine émergent de recherche au sein de la communauté de l'apprentissage automatique et de l'intelligence artificielle. Cette technique consiste à apprendre automatiquement des représentations hiérarchiques dans des architectures profondes, dans le but de réaliser des tâches de classification. Au cours des dernières années, l'apprentissage en profondeur a attiré beaucoup d'attention en raison de ses performances exceptionnelles dans divers domaines.

Plus précisément, l'apprentissage en profondeur utilise des réseaux de neurones artificiels (ANN) pour découvrir des caractéristiques abstraites dans les niveaux les plus élevés de la représentation. Cette technique permet de séparer facilement les divers facteurs explicatifs des données, afin de réaliser des tâches de classification plus précises et

plus efficaces. En somme, l'apprentissage en profondeur est un domaine de recherche prometteur qui offre de nombreuses applications potentielles dans différents domaines, de la reconnaissance d'images à la reconnaissance vocale et à la traduction automatique .[24]

Les deux modèles d'apprentissage en profondeur les plus populaires sont le réseau de neurones récurrent (RNN) et le réseau de neurones convolutifs (CNN).

### 1.12.1 Les réseaux de neurones convolutifs (CNN)

Les réseaux de neurones convolutifs (CNN) sont un type de réseau neuronal qui ont été initialement développés pour la reconnaissance d'images, mais ils ont également montré des résultats prometteurs pour la classification de texte. Dans le cas de la classification de texte, les données d'entrée sont une séquence de mots ou de caractères, qui peuvent être représentées sous forme de matrice d'incorporation .[30]

Les réseaux de neurones convolutifs utilisent des couches convolutives pour extraire les caractéristiques importantes des données d'entrée. Ces couches convolutives effectuent une opération de convolution en glissant un filtre sur la matrice d'incorporation, extrayant ainsi des caractéristiques pertinentes. Ensuite, une couche de pooling est utilisée pour réduire la taille de la sortie de la couche convolutive en prenant les valeurs les plus importantes, tout en maintenant les caractéristiques les plus importantes. Les couches convolutionnelles et de pooling peuvent être empilées pour former un réseau de neurones convolutifs plus profond.

Enfin, les caractéristiques extraites par les couches convolutives sont données en entrée à une ou plusieurs couches de neurones entièrement connectées, qui effectuent la classification finale. Les réseaux de neurones convolutifs sont capables de capturer des informations locales et hiérarchiques dans les données d'entrée, ce qui en fait une technique de pointe pour la classification de texte.

### 1.12.2 Les réseaux neuronaux récurrents (RNN)

Les réseaux neuronaux récurrents (RNN) sont adaptés pour le traitement de séquences de données comme le texte, car ils prennent en compte les relations entre les éléments de la séquence grâce à des connexions récurrentes entre les neurones. Les RNN sont souvent utilisés pour la modélisation de langage naturel, en utilisant des séquences de mots ou de caractères représentées sous forme de vecteurs d'incorporation. Chaque élément de la séquence est traité séquentiellement, en passant par des couches de neurones récurrents qui mettent à jour l'état caché du réseau en fonction de l'entrée actuelle et de l'état caché précédent. Les RNN comprennent également une variante populaire appelée réseau neuronal LSTM (Long Short-Term Memory), qui est utile pour la génération de texte en retenant des informations importantes sur l'ensemble du texte. Les RNN sont une méthode précise pour le traitement de données textuelles grâce à leur capacité à prendre en compte les relations temporelles entre les éléments de la séquence .[16]

Il existe divers types de réseaux de neurones récurrents (RNN) qui ont été développés pour relever différents défis et améliorer les performances dans des scénarios spécifiques.

### 1.12.2.1 Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) est un type spécialisé de réseau de neurones récurrents (RNN) qui excelle dans le traitement de données séquentielles telles que les séries chronologiques, la parole et le texte. Alors que les RNN traditionnels ont du mal à capturer les dépendances à long terme, LSTM a été spécifiquement conçu par Hochreiter et Schmidhuber pour surmonter ce défi.[19]

LSTM se distingue en introduisant une cellule de mémoire, un conteneur capable de conserver des informations pendant des périodes prolongées. Cette caractéristique permet à LSTM de prédire de manière plus précise les mots stockés dans la mémoire à long terme tout en exploitant les informations récentes. Contrairement aux RNN classiques qui perdent progressivement en efficacité à mesure que la longueur de l'écart augmente, LSTM est capable, par défaut, de conserver les informations pertinentes pendant de longues périodes.[43]

## 1.13 L'apprentissage par transfert

L'apprentissage par transfert, utilisé dans l'apprentissage automatique, est la réutilisation d'un modèle pré-entraîné sur un nouveau problème. Tant que, une machine exploite les connaissances acquises lors d'une tâche précédente pour améliorer la généralisation sur une autre.

### 1.13.1 Les transformateurs

Sont un type d'architecture d'apprentissage profond qui ont été introduits pour surmonter les limitations des modèles de réseau neuronal traditionnels tels que les réseaux de neurones convolutifs (CNN) et les réseaux de neurones récurrents (RNN). Contrairement aux CNN, qui sont adaptés à l'extraction de fonctionnalités locales mais ont du mal à capturer des dépendances à long terme, et aux RNN, qui sont capables de capturer des dépendances à longue portée mais difficiles à paralléliser, les Transformers utilisent un mécanisme d'auto-attention pour capturer des dépendances à longue portée et extraire des fonctionnalités significatives à partir de séquences d'entrée. Ils se composent de couches d'encodeurs empilées et d'un mécanisme d'auto-attention, et peuvent être utilisés pour transformer une séquence en une autre en utilisant uniquement des mécanismes d'attention sans aucun module récurrent ou convolutif.[49]

### 1.13.2 Les modèles de langage Pré-entraîné (PLM)

Sont des modèles basés sur les Transformers qui ont été entraînés sur de grands ensembles de données non étiquetées en utilisant des techniques d'apprentissage auto-supervisé telles que la modélisation de la langue masquée et la prédiction de la phrase

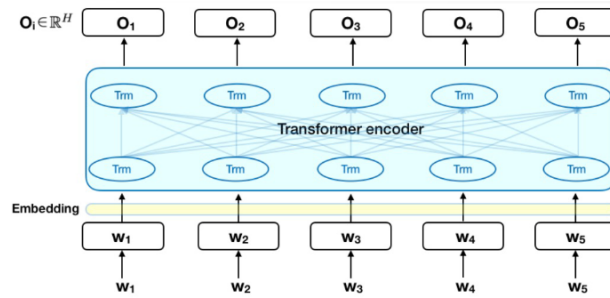


FIGURE 1.9 – L’architecture des transformateurs [4]

suivante. Ces modèles sont devenus la clé pour résoudre des tâches complexes de traitement du langage naturel (NLP) et ont atteint des performances de pointe sur un large éventail de benchmarks de NLP. [5]

Dans la section suivante, nous présenterons quelques exemples de modèles de langage pré-entraînés qui ont été proposés, offrant ainsi une diversité de choix dans ce domaine.

### 1.13.2.1 BERT

BERT (Bidirectional Encoder Representations from Transformers) a été introduit par l’équipe de recherche de Google AI [15] en tant que modèle révolutionnaire de langage pré-entraîné. Ce modèle novateur excelle dans la capture des significations sémantiques et contextuelles nuancées inhérentes aux mots et aux phrases en entrée. En masquant aléatoirement les tokens et en représentant chaque mot masqué par un vecteur, BERT dévoile une compréhension plus profonde du langage.

BERT se compose d’un encodeur transformer bidirectionnel à plusieurs couches. Il est constitué de plusieurs blocs Transformer empilés les uns sur les autres. Chaque bloc Transformer contient un mécanisme d’auto-attention et un réseau neuronal à propagation avant.

L’entrée de BERT est une séquence de tokens, qui sont initialement incorporés dans des embeddings de token. Ces embeddings de token sont ensuite combinés avec des embeddings de segment et des embeddings de position. Les embeddings de segment aident BERT à distinguer entre différentes phrases dans une séquence, tandis que les embeddings de position codent la position relative de chaque token dans la séquence.

BERT est généralement pré-entraîné sur un grand corpus de données textuelles en utilisant des objectifs de modélisation de langage masquée (MLM) et de prédiction de la phrase suivante (NSP). Après le pré-entraînement, BERT peut être affiné pour des tâches spécifiques en ajoutant des couches spécifiques à la tâche et en l’entraînant sur des données étiquetées.

Dans l’ensemble, l’architecture de BERT tire parti de la puissance des transformateurs et des mécanismes d’auto-attention pour capturer des informations contextuelles riches et produire des représentations de haute qualité des tokens dans les tâches de traitement du langage naturel.

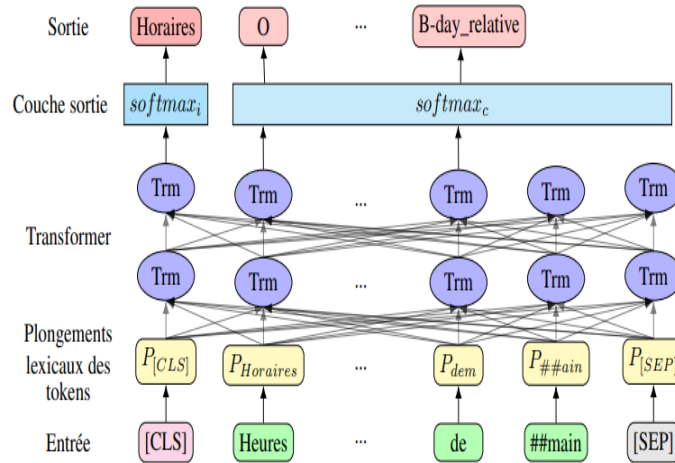


FIGURE 1.10 – Schéma simplifié de l'architecture du modèle BERT [8]

### 1.13.2.2 RoBERTa

En 2019, Yinhan Liu et al. de Meta AI ont présenté une approche améliorée appelée RoBERTa (Robustly Optimized BERT-Pretraining Approach) pour la pré-formation des systèmes de traitement du langage naturel (NLP), dans le but de surpasser les performances de Bidirectional Encoder Representations from Transformers (BERT).

RoBERTa agit comme une réimplémentation de BERT, incorporant diverses modifications aux hyperparamètres essentiels et apportant de légères ajustements aux embeddings. De plus, il introduit une configuration distincte pour les modèles pré-entraînés RoBERTa. Notamment, RoBERTa s'éloigne de BERT en omettant l'objectif de pré-formation de la phrase suivante. De plus, ce modèle est entraîné en utilisant des mini-batches significativement plus grands et des taux d'apprentissage plus élevés, mettant l'accent sur une optimisation robuste.

Le cadre de RoBERTa offre une version affinée et optimisée de BERT, améliorant ses capacités dans la pré-formation des modèles NLP et faisant progresser le domaine du traitement du langage naturel.

### 1.13.2.3 DistilBERT

Le modèle DistilBERT est une version optimisée dérivée du modèle BERT grâce à un processus appelé distillation des connaissances. Lors de la pré-formation, la taille du modèle BERT a été réduite de manière significative de 40% tout en conservant 97% de ses capacités de compréhension du langage. Cette réduction de taille permet à DistilBERT de fonctionner 60% plus rapidement.

Pour garantir l'efficacité de DistilBERT, une approche de triple perte est introduite. Cela combine la modélisation du langage, la distillation et les pertes de distance cosinus, en exploitant les biais inductifs acquis par les modèles plus grands lors de la pré-formation.

DistilBERT se distingue en tant que modèle compact, plus rapide et plus léger, ce qui le rend plus rentable pour la pré-formation et adapté aux applications embarquées.[41]

### 1.13.2.4 BERTweet

BERTweet est une variante du modèle BERT, spécialement conçue pour traiter les données textuelles provenant de Twitter. Il prend en compte les caractéristiques uniques des tweets, telles que les hashtags, les mentions et les URL, qui peuvent influencer la compréhension sémantique du texte.

BERTweet intègre une stratégie de tokenisation adaptée pour gérer les éléments spécifiques à Twitter, ce qui lui permet de capturer efficacement les relations contextuelles au sein des tweets. Cela permet au modèle de mieux comprendre et de générer des représentations précises du texte sur Twitter.[34]

### 1.13.2.5 GPT

GPT signifie "Generative Pre-trained Transformer". Il s'agit d'un type de modèle d'apprentissage automatique largement connu pour ses capacités de traitement du langage naturel et de génération de texte. Les modèles GPT sont basés sur l'architecture des transformateurs.

La caractéristique clé de GPT est sa phase de pré-entraînement, où le modèle est formé sur un grand corpus de données textuelles afin d'apprendre les modèles et les structures du langage. Ce pré-entraînement permet au modèle de capturer les informations sémantiques et syntaxiques, ainsi que les relations contextuelles entre les mots et les phrases.[39]

## 1.14 Les embeddings de mots (word embeddings)

La représentation vectorielle des mots, appelée "word embedding" en TAL (traitement automatique du langage), est un terme important utilisé pour représenter les mots dans le cadre de l'analyse de texte sous forme de vecteurs à valeurs réelles. Il s'agit d'une avancée en TAL qui a amélioré la capacité des ordinateurs à comprendre le contenu textuel de manière plus précise. C'est considéré comme l'une des avancées les plus significatives de l'apprentissage profond pour résoudre des problèmes complexes de traitement automatique du langage naturel.

Dans cette approche, les mots et les documents sont représentés sous forme de vecteurs numériques, ce qui permet aux mots similaires d'avoir des représentations vectorielles similaires. Les caractéristiques extraites sont ensuite utilisées dans un modèle d'apprentissage automatique afin de travailler avec des données textuelles et de préserver les informations sémantiques et syntaxiques. Une fois que ces informations sont reçues sous leur forme convertie, elles sont utilisées par les algorithmes de TAL qui assimilent facilement ces représentations apprises et traitent les informations textuelles.[50]

### 1.15 Conclusion

Dans ce chapitre, nous avons abordé la détection des catastrophes naturelles sur les réseaux sociaux, en mettant l'accent sur Twitter. Nous avons exploré les types de catastrophes, les phases de gestion, et l'importance de la communication pendant les événements. Nous avons également examiné les tweets et leur pertinence dans ce contexte, ainsi que les techniques d'apprentissage automatique et d'apprentissage profond utilisées, telles que KNN, SVM, K-means, CNN, BERT et RoBERTa. En somme, ce chapitre jeté les bases nécessaires pour notre étude sur la détection des catastrophes naturelles à partir des tweets.

## Chapitre 2

### État de l'art

### 2.1 Introduction

Avec l'augmentation de la quantité d'informations disponibles en ligne, la détection et la surveillance des événements catastrophiques à partir de données textuelles (comme les tweets) peuvent être difficiles. Lorsqu'une catastrophe se produit, les plateformes de médias sociaux sont inondées d'une multitude d'informations sur l'événement, suivie d'une forte diminution de la couverture médiatique. Il devient donc crucial de détecter de tels événements à partir de documents en ligne et de suivre les rapports ultérieurs sur des événements similaires, afin de surveiller leur développement successif et leurs conséquences.

Au cours des dernières années, les médias sociaux ont attiré une attention considérable en ce qui concerne la détection d'événements catastrophiques, avec un grand nombre de chercheurs montrant un fort intérêt pour l'analyse et la détection de ces événements naturels sur ces plateformes. Plusieurs approches ont été suggérées pour aborder cette problématique.

### 2.2 Historique

L'histoire de la détection de textes de catastrophes naturelles remonte aux débuts d'Internet, lorsque les gens ont commencé à partager des informations sur des événements dans le monde entier. Au milieu des années 1990, des chercheurs ont commencé à explorer des moyens de classer automatiquement les articles de presse liés aux catastrophes naturelles à l'aide d'algorithmes d'apprentissage automatique.

L'un des premiers efforts pour développer un système de détection de texte de catastrophe naturelle a été le Natural Disaster News Detector, créé par des chercheurs de l'Université du Maryland en 1997. Le système utilisait des règles et des heuristiques pour identifier les articles de presse liés aux catastrophes naturelles, telles que les tremblements de terre, les ouragans et les inondations.

Au cours des années suivantes, les chercheurs ont continué à affiner et à améliorer les algorithmes de détection de textes pour les catastrophes naturelles. En 2006, une équipe de l'Université du Wisconsin-Madison a développé CrisisTracker, qui utilise des algorithmes d'apprentissage automatique pour détecter automatiquement les articles de presse et les publications sur les réseaux sociaux liés aux catastrophes.

En 2012, [52] ont développé un algorithme d'apprentissage automatique capable de détecter les tweets liés aux catastrophes naturelles, en utilisant des filtres basés sur des mots-clés et la localisation, ainsi que des techniques de traitement du langage naturel pour identifier les tweets pertinents.

En 2013, un système appelé "QuakeCatcher" a été développé par des chercheurs de l'Université de Californie à Riverside pour détecter les tremblements de terre à partir des données de Twitter. Le système analysait en temps réel les tweets et identifiait des motifs indiquant qu'un tremblement de terre se produisait. Il a détecté un tremblement de terre de magnitude 6,9 en Californie avant que l'US Geological Survey ne le signale. [45]

En 2019, Les auteurs [36] ont adopté LSTM pour traiter les analyse temporelle sur

5000 Tweets. L'ensemble de données a été nettoyé par la suppression des espaces et de la ponctuation. Après réglage des hyperparamètres, l'architecture de 5 couches LSTM de taille 128, taille de lot de 25 et un taux d'apprentissage de 0,0001 ont donné la plus grande précision de 86,3%.

En 2020, Les auteurs dans [53] ont proposé deux méthodes d'apprentissage profond pour l'analyse des sentiments du texte multilingue des médias sociaux. Le jeu de données contient 20375 tweets en deux langues. Les données les échantillons ont été classés en positifs, négatifs et neutres. Les auteurs ont évalué les performances de deux représentations d'encodeur bidirectionnel de Transform-ers (BERT), en particulier le BERT multilingue (mBERT) et XLM-RoBERTa (XLM-R). Dans le réglage des hyperparamètres, le le taux d'apprentissage du mBERT a été fixé à  $2e-5$  alors que l'apprentissage le taux de XLM-R était de  $2e-6$ . Les résultats expérimentaux ont montré que mBERT a obtenu une précision de 69 % et que XLM-R a enregistré 71 % de précision.

### 2.3 Paradigmes pour la détection automatique des catastrophes naturelles

La classification des catastrophes naturelles à partir de Twitter est devenue de plus en plus difficile en raison des quantités massives de données générées sur la plateforme chaque seconde. Pour relever ces défis, différents efforts ont été déployés pour aborder ce problème sous différents angles. Les deux grandes catégories d'approches sont les méthodes classiques, comprenant la filtration par mots-clés et le crowdsourcing, et les approches d'apprentissage automatique, qui incluent des méthodes traditionnelles ainsi que des méthodes basées sur l'apprentissage en profondeur.

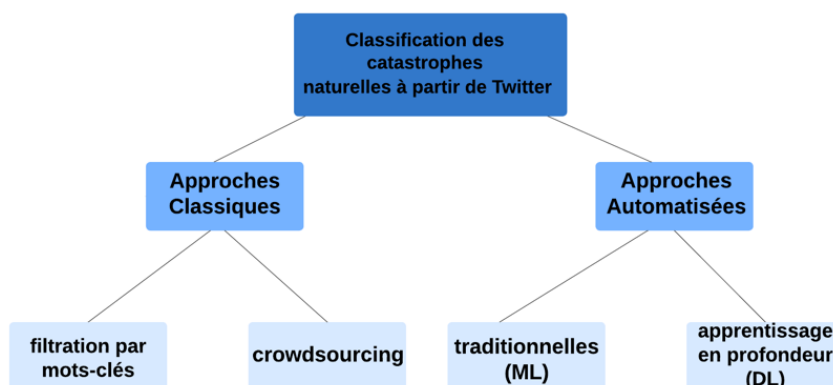


FIGURE 2.1 – Approches de la détection automatique des catastrophes naturelles

### 2.4 Méthodes classiques

#### 2.4.1 Filtrage par mots clés

Cette approche consiste à identifier les mots-clés ou hashtags pertinents susceptibles d'être utilisés par des personnes partageant des informations sur la catastrophe sur Twitter, puis à utiliser ces mots-clés ou hashtags pour filtrer les tweets.

[22] proposent " An Event-Based Approach for Filtering Tweets During Major Disaster Events", Cette étude propose une approche basée sur les événements pour filtrer les tweets pendant les grandes catastrophes. Les auteurs ont développé un ensemble de règles basées sur les mots-clés et les hashtags liés à l'événement de catastrophe, ainsi que d'autres critères tels que les retweets et la crédibilité de l'utilisateur. Ils ont utilisé cette approche pour classer les tweets liés à l'attentat du marathon de Boston.

En 2014, [37] donnant leurs étude " Keyword and Location Based Classification of Disaster-Related Tweets " qui propose un cadre pour classer les tweets liés aux catastrophes en fonction des mots-clés et de la localisation. Ils ont développé une liste de mots-clés liés à différents types de catastrophes et les ont utilisés pour filtrer les tweets. Ils ont également utilisé les informations de localisation dans les tweets pour les classer en fonction de leur pertinence pour l'événement de catastrophe.

[12] présente dans son étude un corpus de tweets annoté par des humains pour le traitement du langage naturel (NLP) des messages liés aux crises. Les chercheurs ont utilisé un filtrage par mot-clé pour sélectionner les tweets liés à différents types de catastrophes, puis les ont manuellement annotés pour créer un corpus de référence en or pour la recherche en NLP.

[28] dans leur étude propose une approche basée sur l'apprentissage automatique pour classer les tweets liés à un événement de catastrophe. Ils ont utilisé un filtrage par mot-clé pour sélectionner les tweets liés à l'événement de catastrophe, puis ont entraîné un modèle d'apprentissage automatique pour les classer en fonction de leur sentiment, pertinence et proximité par rapport à l'événement de catastrophe.

Bien que cette approche puisse être efficace pour identifier les tweets pertinents pour l'événement de catastrophe, il existe des limitations à l'utilisation de la classification des événements basée sur les mots-clés. Par exemple, elle peut ne pas capturer les tweets qui utilisent des mots-clés ou des hashtags différents pour décrire le même événement, ou les tweets qui utilisent un langage ambigu ou non lié pour décrire l'événement. De plus, cette approche peut également entraîner une forte quantité de tweets non pertinents ou de spam étant classés comme pertinents, ce qui peut être chronophage et nécessiter des ressources importantes pour les filtrer. [26]

#### 2.4.2 Crowdsourcing

Le crowdsourcing est un modèle en ligne très efficace pour la résolution de problèmes et la production distribuée qui permet aux individus de participer à diverses tâches et de contribuer à l'effort collectif. Ces tâches peuvent englober un large éventail d'activités,

allant de la simple validation ou étiquetage d'informations et d'images, à des tâches plus complexes telles que l'édition et la gestion de grands ensembles de données.

L'un des systèmes les plus connus est Ushahidi12. Cette plate-forme permet aux gens de partager des informations sur la situation dans divers médias, par exemple par SMS, par e-mail et bien sûr par Twitter. Les messages peuvent ensuite être étiquetés avec des catégories pertinentes pour l'événement. [26]

En 2015, AIDR a été développé pour la première fois en réponse rapide au séisme de 2013 au Pakistan. Son objectif principal est de faciliter les méthodes d'apprentissage automatique pour rationaliser le processus d'annotation. Dans une situation nouvelle, les utilisateurs choisissent d'abord leurs propres mots clés et régions pour commencer à collecter un flux de tweets. Ensuite, des volontaires annotent les catégories pertinentes. Un classificateur supervisé est ensuite formé sur ces exemples donnés et est automatiquement appliqué aux nouveaux messages entrants. [23]

CrisisTracker [40] est un autre outil qui contribue à la collecte de tweets lors de situations de crise grâce au crowdsourcing. Il fonctionne en temps réel et utilise le hachage sensible local (LSH) pour détecter des grappes de sujets, également appelées "histoires". Cette fonctionnalité permet aux bénévoles d'analyser collectivement des tweets connexes plutôt qu'individuellement. De plus, CrisisTracker intègre le moteur AIDR pour filtrer automatiquement les sujets. La plateforme a été testée sur le terrain lors de la guerre civile syrienne de 2012. Bien que CrisisTracker soit gratuit et en open source, il n'a pas été mis à jour depuis 2016.

## 2.5 Méthodes automatisées

Les méthodes de détection automatisées peuvent fournir une approche plus efficace, cohérente, évolutive et objective pour analyser les données et pour séparer les informations exploitables utiles du déluge d'autres publications sur les réseaux sociaux

### 2.5.1 Méthodes traditionnelles d'apprentissage automatique

Ces méthodes impliquent l'utilisation d'algorithmes de natural language processing (NLP) et d'apprentissage automatique (ML) pour classer automatiquement les publications sur les réseaux sociaux liées aux catastrophes. Les méthodes traditionnelles d'apprentissage automatique ont été largement utilisées dans ce contexte. [42]

[46] décrivent une approche d'apprentissage supervisé utilisant des machines à vecteurs de support (SVM) pour classer les tweets liés aux tremblements de terre en quatre catégories. L'étude a révélé que le classifieur SVM s'est bien comporté dans la classification des tweets liés aux tremblements de terre. Le modèle a atteint une précision de 0.75 et a pu identifier rapidement les tweets pertinents après un tremblement de terre.

[23] ont proposé une approche d'apprentissage supervisé utilisant des classifieurs Random Forest et SVM pour classer les tweets liés aux catastrophes naturelles dans des catégories telles que les dommages aux infrastructures, l'aide humanitaire et les demandes d'aide. L'étude a révélé que le classifieur Random Forest surpassait le SVM dans la classification

des tweets liés aux catastrophes naturelles. L'étude a également souligné l'importance des caractéristiques basées sur le contexte pour améliorer les performances des classifieurs.

[17] ont proposé une approche de classification multi-étiquettes utilisant des méthodes traditionnelles d'apprentissage automatique telles que Random Forest, SVM et Naive Bayes pour classer les tweets liés aux catastrophes naturelles dans des catégories telles que les dommages, les dons et les volontaires. L'étude a montré que la classification multi-étiquettes à l'aide de méthodes traditionnelles d'apprentissage automatique telles que Random Forest, SVM et Naive Bayes pouvait classer efficacement les tweets liés aux catastrophes naturelles.

### 2.5.2 Méthodes basées sur les réseaux de neurones(NN) et l'apprentissage profond

Récemment, l'apprentissage profond s'est révélé être une technique prometteuse pour saisir des abstractions de haut niveau dans les données, offrant ainsi une amélioration significative de la classification de texte par rapport aux méthodes traditionnelles d'apprentissage automatique. Dans l'étude de [32], les méthodes ML traditionnelles (Naïve Bayes avec des caractéristiques faites à la main) ont été comparées aux méthodes profondes (CNN et RNN), révélant que les méthodes profondes surpassent les méthodes classiques (en particulier CNN).

Plusieurs autres études ont appliqué des CNN pour classer les données liées aux crises sur les réseaux sociaux [33]. Dans ce contexte, [9] ont proposé des modèles de CNN améliorés sémanti-quement afin de détecter des catégories d'informations liées aux crises. Leurs modèles ont été évalués sur l'ensemble de données CrisisLexT26 [38], composé d'environ 28 000 tweets étiquetés collectés lors de 26 événements de crise survenus en 2012 et 2013. Le travail de Burel et al. constitue une exploration de la détection "tous risques".

Plus récemment, les réseaux neuronaux récurrents (RNN), spécialisés dans la modélisation séquentielle, sont de plus en plus utilisés dans la classification de texte. Les RNN avec des mécanismes de portes tels que les mémoires à court terme à long terme (LSTM) et les mémoires à court terme à long terme bidirectionnelles (BiLSTM) [36] ont été largement utilisés, car ils peuvent capturer des dépendances à long terme. [48] ont proposé une approche multimodale pour l'identification de tweets informatifs liés aux crises en utilisant à la fois des données textuelles et des données d'image, qui sont entraînées respectivement par un réseau LSTM et le réseau VGG-16. Une autre étude importante de ce type est celle de [14], qui ont proposé un modèle multitâche basé sur LSTM pour l'identification des hashtags dans les tweets de crise.

Dans le domaine du transfert d'apprentissage pour la classification automatique des publications sur les réseaux sociaux liées aux catastrophes, la technique de fine-tuning des modèles basés sur les transformers tels que BERT [15], DistilBERT [41], etc., est devenue la méthode principale pour atteindre des performances de pointe dans diverses tâches linguistiques et domaines.

## 2.6 Résumé des travaux récents sur la détection des catastrophes naturelles à partir des réseaux sociaux

Le Tableau (2.1) présente l'aperçu des études sur les approches de la détection des catastrophes naturelles à partir des réseaux sociaux discutées dans cette section. En résumé, l'analyse montre que la majorité des études sur la détection des catastrophes sur Twitter étaient basées sur les techniques traditionnelles d'incorporation sans contexte, tandis que celles explorant les techniques plus robustes basées sur les transformateurs étaient rares. De plus, on peut observer que BERT reste largement à explorer à cet égard, malgré les résultats prometteurs. L'analyse fournit donc un aperçu des lacunes de la détection des catastrophes sur Twitter basée sur l'IA et aide à guider notre étude dans l'exploration des transformateurs à travers des modèles d'apprentissage profond.

## Chapitre 2. État de l'art

Reference	Classification	Data	Features	Algorithm	Best Score
(Xiao et al. 2018) [51]	Binary	Weibo Data	tf-idf	Random Forest*, SVM, Naive Bayes	0.83 (acc)
(XNguyen et al. 2022) [35]	Informativeness	crisisNLP	BERTweet/		0.85 (F1)
(Yamouni et al.2022)	Binary	CrisisLexT26	tf-idf	SVM, KNN, LR, Naive Bayes, Decision Trees, Extra Trees*	0.81 (F1)
(Yamouni et al.2022)	Binary	CrisisLexT26	BERT	/	0.89 (F1)
(Alam et al. 2020) [7]	Informativeness	CrisisLexT26 CrisisNLP	BERT	CNN*	0.86 (F1)
(chanda et al. 2021) [13]	Informativeness	Kaggle competition	BERT	BI-LSTM	0.83 (F1)
(Naaz et al. 2021) [31]	Relatedness	crisisLexT26 crisisNLP	BERT	LSTM, CNN	0.71 (F1)

TABLE 2.1 – Travaux connexes

### 2.7 Conclusion

Ce chapitre offre une vue d'ensemble de l'évolution des techniques de détection des catastrophes naturelles à partir des réseaux sociaux, mettant en évidence les opportunités et les défis qui se présentent. Ces travaux fournissent des bases solides pour approfondir nos recherches et contribuer à l'amélioration des systèmes de détection des catastrophes naturelles basés sur l'intelligence artificielle et l'apprentissage automatique.

Il est indéniable qu'il existe un potentiel significatif pour améliorer la détection des catastrophes naturelles en exploitant davantage les méthodes d'apprentissage profond basées sur les transformateurs. Notre objectif est donc de combler cette lacune en explorant ces techniques et en proposant de nouveaux modèles d'apprentissage profond permettant une détection plus précise et rapide des catastrophes naturelles à partir des réseaux sociaux. Les résultats de cette recherche auront un impact concret sur l'amélioration de la gestion des crises et la préservation des vies lors de situations d'urgence.

# Chapitre 3

## Conception et implémentation

### 3.1 Introduction

Dans ce dernier chapitre, nous explorons en détail les aspects de l'architecture du modèle proposé, ainsi que des aperçus complets sur l'ensemble de données utilisé et la myriade de techniques utilisées méticuleusement tout au long des phases de conception et de mise en œuvre.

### 3.2 Modèles proposés

À partir de nos lectures de l'état de l'art, nous avons constaté que les méthodes basées sur l'apprentissage profond notamment utilisant Les modèles de langage prétraités (PLM) présentent souvent de meilleures performances. À partir de cela nous nous sommes inspiré à proposer nos modèles qui sont essentiellement un fine-tuning des modèles de langage prétraités combinés à d'autres modèles très fréquents tels que : BiLSTM et CNN.

#### PLM-BiLstm-CNN

Notre modèle PLM-BiLSTM-CNN est une combinaison de plusieurs composants clés, visant à exploiter les avantages des modèles de langage pré-entraînés, des réseaux de neurones récurrents bidirectionnels (BiLSTM) et des réseaux de neurones convolutifs (CNN) pour la détection des catastrophes en temps réel à partir des données Twitter.

Tout d'abord, nous utilisons un modèle de langage pré-entraîné (PLM). Le PLM nous permet de capturer des représentations contextuelles riches des mots dans les tweets liés aux catastrophes, en tenant compte du contexte global de chaque mot dans une séquence.

Ensuite, nous ajoutons une couche de BiLSTM après le modèle PLM qui prend en compte le contexte des mots à la fois dans le passé et dans le futur. Cela permet de capturer les dépendances séquentielles et les relations à longue distance entre les mots dans les tweets.

Une fois que les informations contextuelles riches sont capturées par le modèle PLM et que les dépendances séquentielles à long terme sont prises en compte par la couche BiLSTM, nous ajoutons une couche de CNN pour extraire les caractéristiques locales des tweets liés aux catastrophes et pour obtenir une représentation riche et complète des tweets pour la classification .

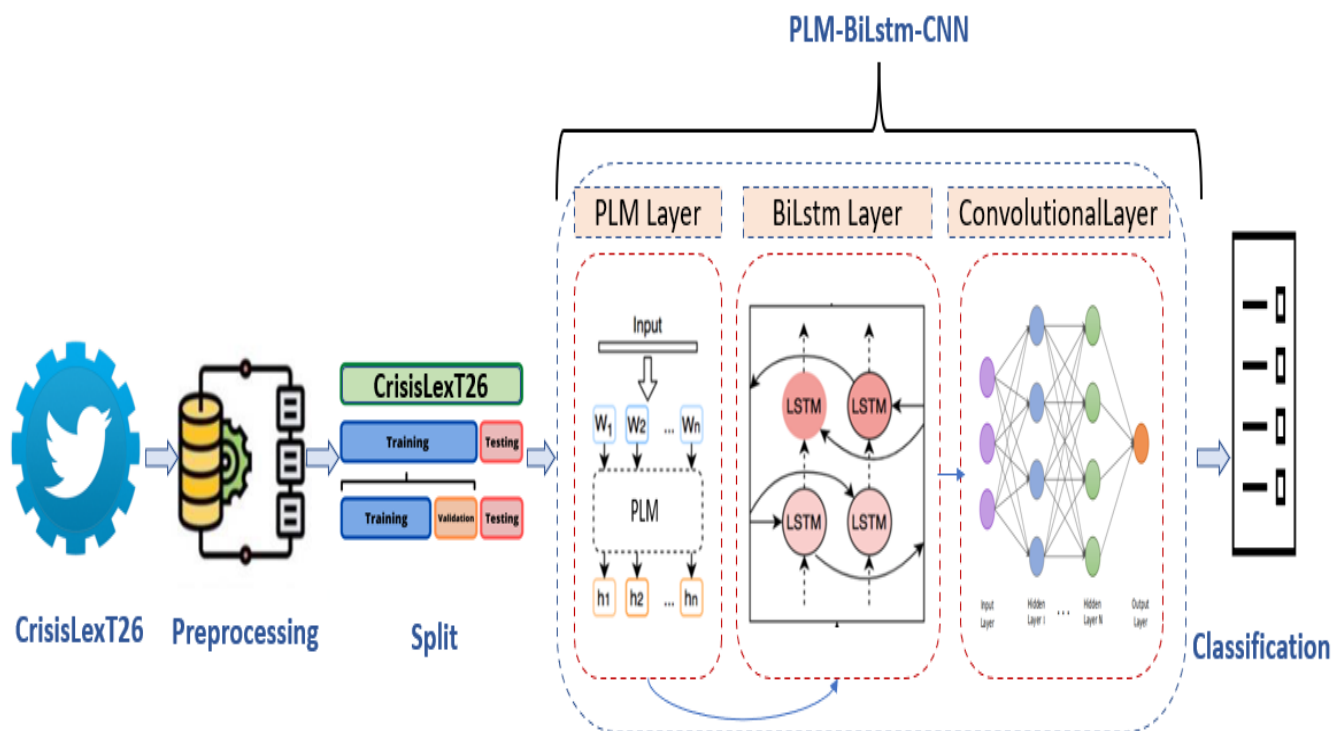


FIGURE 3.1 – Le modèle PLM-BiLstm-CNN

## 3.2.1 Aperçu du Modèle proposé PLM-BiLstm-CNN

### 3.2.1.1 Phase 01 : PLM

Cette phase consiste à utiliser un modèle de langage pré-entraîné (PLM) pour capturer des représentations contextuelles riches des mots dans les tweets liés aux catastrophes. Le PLM encode chaque mot dans un vecteur numérique qui tient compte de son sens et de son contexte. Nous utilisons ensuite ces encodages de mots comme entrée pour un modèle de classification (dans un premier temps pour tester les PLM seuls), tel qu'un réseau de neurones, qui apprend à prédire si un tweet est lié à une catastrophe ou non. Le PLM améliore la compréhension des tweets en capturant les dépendances contextuelles, tandis que le modèle de classification utilise ces encodages pour effectuer la classification des tweets relatifs aux catastrophes. Cette approche nous permet de détecter les tweets pertinents les classer avec précision.

### 3.2.1.2 Phase 02 : BiLSTM

Après la couche PLM, nous intégrons également un réseau de neurones récurrents bidirectionnels (BiLSTM) dans notre modèle pour la détection des catastrophes dans les tweets. Après avoir capturé les représentations contextuelles riches des mots avec le modèle de langage pré-entraîné (PLM), nous ajoutons une couche de BiLSTM entre le PLM et le classifieur. Le BiLSTM prend en compte le contexte des mots à la fois dans le passé et dans le futur, ce qui permet de capturer les dépendances séquentielles et les relations à longue distance entre les mots dans les tweets. Cette couche de BiLSTM améliore notre compréhension des séquences de mots et permet au modèle de capturer des informations séquentielles essentielles pour la détection des catastrophes. En combinant les avantages du PLM et du BiLSTM, notre modèle serait capable de mieux exploiter le contexte global et les dépendances séquentielles pour une détection précise des catastrophes dans les tweets.

### 3.2.1.3 Phase 03 : CNN

Après les deux phases précédentes, nous utilisons également des réseaux de neurones convolutifs (CNN) pour extraire des caractéristiques locales des tweets liés aux catastrophes et améliorer la représentation des données. Après avoir capturé les représentations contextuelles riches des mots avec le modèle de langage pré-entraîné (PLM) et pris en compte les dépendances séquentielles avec le BiLSTM, nous ajoutons une couche de CNN. Cette couche de CNN permet de détecter des motifs spécifiques, tels que des mots ou des expressions clés associés aux catastrophes, en analysant les caractéristiques locales des tweets. Les CNN sont capables d'extraire des informations importantes à partir de fenêtres de mots adjacentes, ce qui contribue à une représentation riche et complète des tweets pour la classification. En intégrant le CNN dans notre modèle, nous exploitons les avantages des réseaux de neurones convolutifs pour améliorer la détection des catastrophes en identifiant les caractéristiques locales significatives dans les tweets.

## PLMsEnsemble

Dans notre première proposition, nous avons présenté une combinaison séquentielle entre un des PLMs, un BiLSTM et un réseau CNN. Notre deuxième proposition consiste évidemment à tester l'autre possibilité de combiner entre ces 3 modèles (PLM, BiLSTM et CNN) qui est une combinaison parallèle avec une stratégie d'ensemble qui permet l'exploitation des sorties des trois modèles et d'utiliser pour avoir une classification des tweets en entrée. Dans un premier lieu et pour des restrictions temporelles, nous avons commencé par tester d'entraîner parallèlement deux PLMs seulement comme PLMsEnsemble.

Notre modèle d'ensemble PLMsEnsemble combine les forces de deux modèles pré-entraînés, pour améliorer la détection des catastrophes en temps réel à partir des données Twitter. L'utilisation de modèles de langage pré-entraînés nous permet de capturer des représentations contextuelles riches des mots dans les tweets liés aux catastrophes, en

prenant en compte le contexte global de chaque mot dans une séquence. Notre modèle d'ensemble est en mesure de tirer parti des représentations contextuelles, des dépendances séquentielles et des caractéristiques locales pour améliorer les performances de détection des catastrophes.

Cette approche d'ensemble permet d'exploiter les avantages de chaque modèle pré-entraîné et de combiner leurs forces respectives pour une meilleure performance globale. En utilisant cette architecture, notre modèle peut fournir des prédictions plus précises et fiables pour la détection des catastrophes à partir des données Twitter.

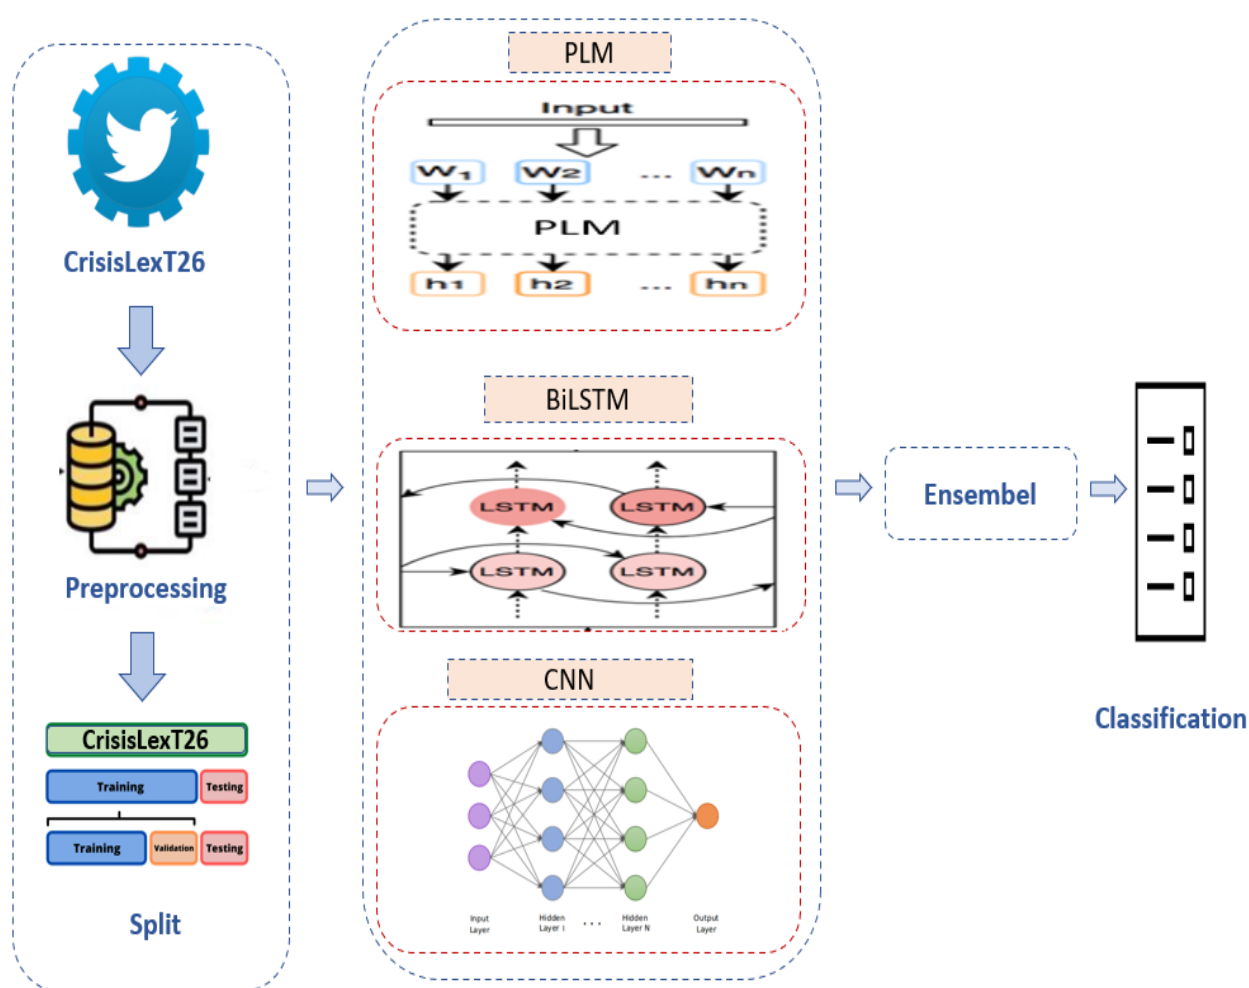


FIGURE 3.2 – Le modèle PLMsEnsemble

### 3.3 Description du dataset

Nous avons utilisé un ensemble de données (corpus de messages et d'annotations) formé de tweets déjà collectés utilisant L'API de Twitter. Nous avons choisi d'utiliser le dataset CrisisLexT26 sur la base que c'est le plus récent des datasets et le plus utilisé et qui comportent des tweets en langue anglaise, relatifs aux catastrophes naturelles.

### 3.3.1 CrisisLexT26 dataset

Un ensemble de données largement utilisé dans la recherche sur la détection des crises et des catastrophes naturelles. Il comprend une collection de tweets annotés, provenant de situations de crise réelles, tels que des tremblements de terre, des inondations et des incendies. Le nombre de ces tweets par catastrophe varie entre 1100 et 157 500. Au total, environ 285 000 tweets ont été collectés. Ces tweets sont classés en différentes catégories, telles que l'informativité (informative ou non informative), le type de crise et d'autres caractéristiques pertinentes. (Olteanu 2014)

L'utilisation du jeu de données CrisisLexT26 offre une opportunité de créer des modèles de détection des crises plus précis et fiables, en tirant parti des informations et des schémas présents dans les tweets générés pendant les crises. Cela permet de mieux comprendre les besoins et les préoccupations des utilisateurs des réseaux sociaux pendant ces événements, ce qui peut contribuer à une prise de décision éclairée et à une réponse plus rapide lors de futurs incidents.

Event	Hashtag	Occurrences/1001
2012 Typhoon Pablo	#PabloPH	453
2013 Bohol Earthquake	#PrayForVisayas	338
2013 Singapore Haze	#sghaze	667
2013 West Texas Explosion	#PrayForTexas	152
2012 Italy Earthquakes	#terremoto	711
2013 Manila Floods	#MaringPH	399
2013 Boston Bombings	#PrayForBoston	259
2013 Brazil Nightclub Fire	#SantaMaria	353
2013 Colorado Floods	#coflood	317
2013 LA Airport Shootings	#LAX	451
2012 Guatemala Earthquake	#sismo	165
2012 Philippines Floods	#rescuePH	571
2013 Sardinia Floods	#Sardegna	764
2012 Venezuela Refinery Explosion	#Amuay	588
2013 Alberta Floods	#yycflood	497
2013 Lac Megantic Train Crash	#LacMegantic	254
2013 Typhoon Yolanda	#Haiyan	264
2013 Glasgow Helicopter Crash	#Clutha	286
2013 Queensland Floods	#bigwet	684
2012 Colorado Wildfires	#colorado	151
2013 Australia Bushfire	#nswfires	481
2013 Savar Building Collapse	#Bangladesh	579
2012 Costa Rica Earthquake	#earthquake	363
2013 Russia Meteor	#RussianMeteor	407

FIGURE 3.3 – Hashtags choisis pour CrisisLexT26 Dataset

## 3.4 Stratégies d'évaluation

L'approche ou à la méthodologie utilisée pour évaluer les performances d'un modèle ou d'un système. Elle consiste à sélectionner des ensembles de données, à définir des métriques et à concevoir des expériences pour mesurer et comparer l'efficacité de différents modèles ou configurations.

Il comprend généralement les éléments suivants :

### 3.4.1 Sélection des ensembles de données

L'ensemble de données choisi pour l'évaluation doit être diversifié, impartial et couvrir un large éventail de scénarios pertinents pour le problème étudié. L'ensemble de données doit être ensuite divisé en ensembles d'entraînement, de validation et de test, en suivant les principes de la division des données mentionnés précédemment.

### 3.4.2 Validation croisée

La validation croisée (Cross-validation) est une technique couramment utilisée dans les stratégies d'évaluation pour atténuer l'impact de la variabilité des données. Elle consiste à diviser l'ensemble de données en plusieurs sous-ensembles ou plis et à effectuer plusieurs cycles d'apprentissage et de test en faisant tourner le pli utilisé pour le test. Cela permet d'obtenir une évaluation plus robuste et fiable des performances du modèle.

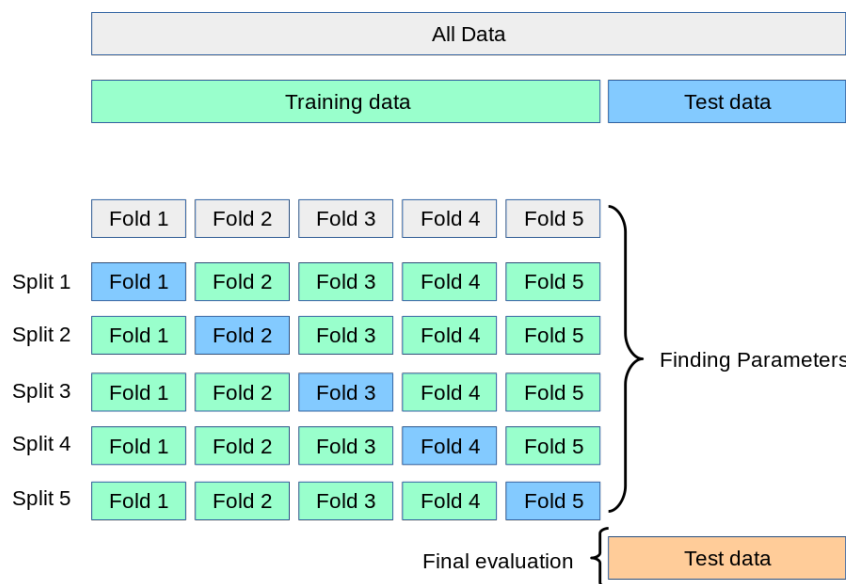


FIGURE 3.4 – Validation croisée  
[27]

### 3.4.3 Métriques d'évaluation

La matrice de confusion (Confusion Matrix) est une représentation tabulaire utilisée pour évaluer les performances d'un modèle de classification. Elle permet de visualiser et d'analyser les prédictions faites par le modèle en comparant les valeurs prédites avec les valeurs réelles des données.

Une matrice de confusion est généralement de dimension  $n \times n$ , où  $n$  représente le nombre de classes ou de catégories dans le problème de classification. Les éléments de

la matrice représente les différentes combinaisons de prédictions et de vérités, et sont organisés de la manière suivante :

**Les vrais positifs (TP)** : Il s'agit des cas où le modèle a correctement prédit une classe positive.

**Les vrais négatifs (TN)** : Il s'agit des cas où le modèle a correctement prédit une classe négative.

**Les faux positifs (FP)** : Il s'agit des cas où le modèle a prédit à tort une classe positive alors que la vérité est négative.

**Les faux négatifs (FN)** : Il s'agit des cas où le modèle a prédit à tort une classe négative alors que la vérité est positive.

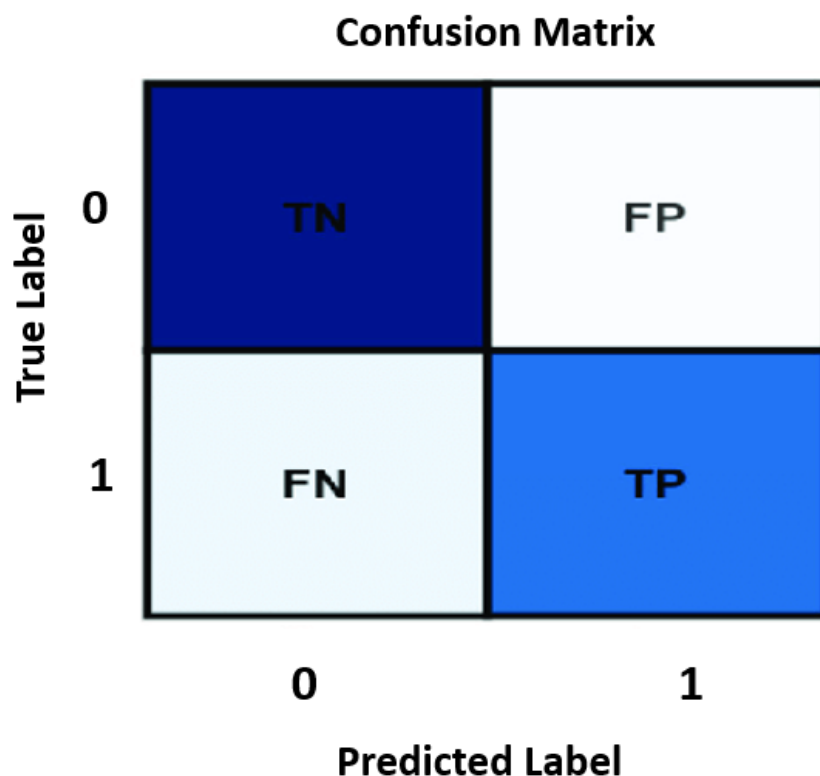


FIGURE 3.5 – Matrice de confusion pour  $n = 2$ .

#### 3.4.4 L'exactitude (Accuracy)

Elle représente le rapport entre le nombre de prédictions correctes (vrais positifs (TP) et vrais négatifs (TN)) et le nombre total d'échantillons dans le jeu de données.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

### 3.4.5 La précision (Precision)

C'est le rapport entre le nombre de vrais positifs (VP) et la somme des vrais positifs et des faux positifs (VP + FP). Elle mesure la capacité du modèle à identifier correctement les vrais positifs parmi toutes les prédictions positives.

$$Precision = \frac{TP}{TP + FP} \quad (3.2)$$

### 3.4.6 Le rappel (Recall)

C'est le rapport entre le nombre de vrais positifs (VP) et la somme des vrais positifs et des faux négatifs (VP + FN). Il mesure la capacité du modèle à identifier correctement tous les exemples positifs.

$$Recall = \frac{TP}{TP + FN} \quad (3.3)$$

### 3.4.7 Le score F1 (F1-score)

C'est la moyenne harmonique de la précision et du rappel. Il fournit une mesure globale de la performance du modèle en tenant compte à la fois de la précision et du rappel.

$$F1 - score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (3.4)$$

## 3.5 Stratégies d'optimisation

### 3.5.1 Paramétrage

#### 3.5.1.1 La taille de lot (Batch size)

Le nombre d'échantillons d'apprentissage présentés à un modèle lors d'une seule itération d'entraînement. Lors de l'entraînement d'un modèle, les données sont généralement divisées en lots (batches) afin de faciliter le processus d'optimisation. Au lieu de passer chaque échantillon individuellement dans le réseau de neurones, ce qui pourrait être inefficace en raison des opérations coûteuses en termes de calcul, les lots permettent de traiter plusieurs échantillons simultanément.

#### 3.5.1.2 Taux d'apprentissage (Learning rate)

Un hyperparamètre clé détermine l'ampleur des ajustements effectués sur les poids d'un modèle lors de la mise à jour des paramètres pendant l'entraînement. Il prend des valeurs entre 0.0 et 1.0. Le choix approprié du taux d'apprentissage est crucial pour assurer une convergence efficace du modèle et obtenir de bonnes performances sur les données d'apprentissage.

### 3.5.1.3 Nombre d'époques (epochs)

Le nombre de fois où l'ensemble des données d'entraînement est passé à travers le modèle d'apprentissage lors de l'entraînement. Une époque correspond à une itération complète sur l'ensemble des données d'entraînement, ce qui signifie que chaque exemple d'entraînement a été vu une fois par le modèle.

### 3.5.1.4 L'arrêt précoce (Early stopping)

une technique basée principalement sur l'arrêt précoce est de surveiller la performance du modèle sur un ensemble de validation pendant l'entraînement et d'arrêter l'entraînement lorsque la performance cesse de s'améliorer et commence à se détériorer.

### 3.5.1.5 Extra paramètres

En plus des paramètres mentionnés précédemment, il existe plusieurs autres paramètres qui peuvent avoir une influence significative sur les performances des modèles comme l'optimiseur utilisé, le scheduler, le weight-decay, le warm-up etc. Et comme ces paramètres supplémentaires offrent des moyens d'optimiser davantage les performances des modèles neuronaux en ajustant finement les mécanismes d'apprentissage. Cependant, ils peuvent également introduire une complexité supplémentaire dans l'entraînement et nécessiter des ajustements et des expérimentations supplémentaires pour trouver les meilleures valeurs.

## 3.6 Étapes du processus

### 3.6.1 Prétraitement

Une étape essentielle dans le pipeline de l'apprentissage automatique, Il comprend une série d'opérations visant à améliorer la qualité globale et réduire le bruit des données et à faciliter l'extraction d'informations significatives .

#### 3.6.1.1 Filtrage

Le filtrage des tweets vise à éliminer les éléments indésirables, tels que les URL, les emojis, les mentions d'utilisateurs et les hashtags, dans le but de simplifier le texte et de le rendre plus approprié pour des analyses de texte ultérieures.

#### 3.6.1.2 Élimination des mots d'arrêt (Stop words)

La suppression des mots d'arrêt fait référence à la pratique consistant à éliminer les mots couramment utilisés, tels que les articles, les conjonctions et les prépositions, lors du prétraitement des données textuelles.

### 3.6.1.3 Racinisation(Stemming)

Le stemming est une technique de prétraitement des données textuelles qui vise à réduire les mots à leur racine ou à leur "stème". Il se contente de supprimer les suffixes des mots pour obtenir une forme tronquée.

### 3.6.1.4 Lemmatisation

Un processus qui vise à ramener les mots à leur forme de base ou à leur "lemme". Contrairement à la racinisation (stemming) qui se contente de supprimer les suffixes des mots, la lemmatisation prend en compte la morphologie et la grammaire pour déterminer la forme canonique d'un mot.

### 3.6.1.5 Tokenisation

La tokenisation est le processus de division d'un texte en unités plus petites appelées "tokens". Les tokens peuvent être des mots, des phrases, des symboles de ponctuation ou d'autres unités significatives, selon le contexte. La tokenisation est une étape essentielle dans le traitement du texte car elle permet de convertir le texte en une séquence de tokens qui peuvent être traités plus facilement lors de l'analyse et du traitement ultérieurs.

### 3.6.1.6 CrisisLexT26 Prétraitement

Dans notre approche de prétraitement des données, nous avons mis en place plusieurs étapes pour améliorer la qualité et la cohérence des textes. Voici les trois types de prétraitement que nous avons effectués :

**Prétraitement partiel :** Dans cette étape, nous avons effectué des transformations de base pour nettoyer les textes. Cela comprenait la suppression des URL, des ponctuations et des contractions. Ensuite, nous avons réalisé une tokenisation pour diviser les textes en mots individuels, ce qui facilite le traitement ultérieur.

**Prétraitement complet :** En plus des étapes mentionnées précédemment, nous avons également appliqué un prétraitement complet pour standardiser davantage les données. Nous avons utilisé les techniques de prétraitement mentionnées précédemment, telles que la suppression des majuscules, la normalisation des contractions, la suppression des caractères spéciaux, etc. Cela a permis d'obtenir des textes plus uniformes et cohérents pour l'analyse ultérieure.

**Version non prétraitée du dataset :** Dans un souci de comparaison, nous avons également conservé une version du dataset sans aucun prétraitement. Cela nous a permis d'évaluer l'impact du prétraitement sur les résultats et de déterminer si les étapes de nettoyage étaient nécessaires ou non dans notre cas spécifique.

## 3.6.2 Dévision du dataset

La division de l'ensemble de données fait référence au processus de partitionner un ensemble de données en sous-ensembles distincts dans le but d'accomplir différentes tâches.

Les divisions les plus courantes sont :

**L'ensemble d'entraînement (Train Set)** : Il s'agit de la plus grande partie de l'ensemble de données utilisée pour former le modèle d'apprentissage automatique. Son objectif est d'optimiser les paramètres du modèle et d'apprendre les motifs présents dans les données.

**L'ensemble de validation (Validation Set)** : C'est une portion plus petite de l'ensemble de données utilisée pour ajuster les hyperparamètres du modèle et évaluer sa performance pendant l'entraînement. Son rôle est de prévenir le surajustement en fournissant une évaluation indépendante de la capacité de généralisation du modèle.

**L'ensemble de test (Test Set)** : Il s'agit d'un sous-ensemble totalement indépendant des données qui n'est pas utilisé pendant l'entraînement du modèle ni pour l'ajustement des hyperparamètres. Cet ensemble est réservé à l'évaluation finale de la performance du modèle sur des données inconnues.

Dans notre cas, nous avons divisé le jeu de données en deux parties distinctes : l'ensemble d'entraînement et l'ensemble de test. L'ensemble d'entraînement représentait 80% des données, tandis que l'ensemble de test en représentait 20%. Ensuite, nous avons prélevé 20% de l'ensemble d'entraînement pour constituer l'ensemble de validation.

Dataset	Train	Validation	Test	Total
CrisisLexT26	3454	864	1080	5398

TABLE 3.1 – L'échantillonnage du dataset CrisisLexT26 après la division

### 3.6.3 Les types de classification

Pour notre étude, nous avons choisis deux types de classification :

#### 3.6.3.1 La classification multiclass

C'est la classification de chaque tweet dans sa classe correspondante, en fonction de la catastrophe qu'il reflétait .

nous remplaçons les étiquettes d'origine par les étiquettes correspondantes du dictionnaire 'label\_map'. Les étiquettes résultantes sont affectées à la colonne 'newLabels' dans le DataFrame. Ensuite nous transformons les étiquettes d'origine en leurs représentations numériques.

'0 =non informative', '1=Inondations (Flood)', '2 =Feux de forêt (Wild fires)', '3=Typhon (Typhoon)' .

L'objectif de notre classification multiclass était donc d'attribuer à chaque tweet une classe spécifique parmi ces quatre options, en fonction du type de catastrophe qu'il mentionnait ou représentait. Cela nous a permis de classifier les tweets en fonction de leur pertinence pour chaque type de catastrophe, facilitant ainsi l'analyse et la compréhension des informations liées aux catastrophes sur les réseaux sociaux.

### 3.6.3.2 La classification binaire

Dans notre approche de classification binaire des tweets, nous divisons chaque tweet en deux classes : "informative" et "non informative", en fonction de l'information qu'il contient.

Pour ce faire, nous avons regroupé les étiquettes d'origine telles que "Related - but not informative", "Not related" et "Not applicable" dans la classe "non informative". D'autre part, les tweets étiquetés comme "Related and informative" sont attribués à la classe "informative". Ainsi, nous avons créé une classification en deux classes distinctes : "1=informative" et "2=non informative".

L'objectif de cette classification binaire est de distinguer les tweets qui fournissent une information pertinente liée aux catastrophes de ceux qui ne sont pas informatifs dans ce contexte. En classant les tweets dans ces deux catégories, nous pouvons mieux identifier les tweets qui apportent une valeur informative pour notre analyse et compréhension des informations relatives aux catastrophes.

### 3.6.4 visualisation de données




FIGURE 3.6 – La distribution des multiclassés dans CrisisLexT26.




FIGURE 3.7 – La distribution des binaires classes dans CrisisLexT26.

## 3.7 Implémentation

### 3.7.1 Langage

#### 3.7.1.1 Python

Python est un langage de programmation interprété et polyvalent. Il est connu pour sa simplicité syntaxique et sa lisibilité, ce qui en fait un choix populaire parmi les programmeurs débutants et expérimentés. Python offre une combinaison unique de stabilité, flexibilité, robustesse et richesse des bibliothèques qui en fait un choix judicieux pour les projets d'apprentissage. (Van, 1995)

### 3.7.2 Outils

#### 3.7.2.1 Google Colab

Google Colab (Colaboratory) est un service cloud gratuit proposé par Google. Il repose sur Jupyter Notebook et est spécialement conçu pour la formation et la recherche dans le domaine de l'apprentissage automatique, sans aucune contrainte matérielle. L'avantage majeur de Colab réside dans le fait que les notebooks sont exécutés sur les serveurs cloud puissants de Google, offrant aux utilisateurs l'accès aux ressources de calcul de pointe (GPU...). Ainsi, nous pouvons exploiter la puissance de calcul de Google pour accélérer nos tâches d'apprentissage automatique.

### 3.7.3 Plateforme et API

#### 3.7.3.1 NLTK

NLTK (Natural Language Toolkit) est une bibliothèque populaire en Python utilisée pour le traitement du langage naturel (NLP). Elle fournit une gamme d'outils et de ressources pour analyser, nettoyer, prétraiter et comprendre le texte écrit en langage naturel. Sa flexibilité, sa richesse en fonctionnalités et sa documentation complète en font un choix privilégié pour les projets impliquant l'analyse et la compréhension du texte.

### 3.7.4 Librairies

#### 3.7.4.1 Transformers

Une bibliothèque populaire en Python, développée par Hugging Face, qui fournit des outils et des modèles pré-entraînés pour le traitement du langage naturel (NLP) et le deep learning. Elle est largement utilisée pour des tâches telles que la traduction automatique, la génération de texte, la classification de texte, la question-réponse, et bien d'autres.

#### 3.7.4.2 Scikit-learn (sklearn)

Une bibliothèque open-source en Python dédiée à l'apprentissage automatique (machine learning). Elle fournit des outils efficaces et faciles à utiliser pour effectuer diverses tâches d'apprentissage supervisé et non supervisé, ainsi que des évaluations de modèles et des prétraitements de données.

#### 3.7.4.3 Pandas

Est une bibliothèque très utilisée pour la manipulation et l'analyse de données en Python. Elle offre des structures de données flexibles et performantes, notamment le DataFrame, qui est idéal pour travailler avec des ensembles de données tabulaires. Pandas permet de charger des données à partir de divers formats tels que CSV, Excel, SQL, et de les prétraiter pour une utilisation ultérieure.

#### 3.7.4.4 Matplotlib

Une bibliothèque spéciale pour créer des visualisations graphiques. Elle offre des fonctionnalités complètes pour créer des graphiques statiques, Elle offre des fonctionnalités complètes pour créer des graphiques statiques, animés et interactives .

#### 3.7.4.5 Seaborn

Une bibliothèque puissante qui simplifie la création de graphiques statistiques attrayants en utilisant Python. Elle offre une interface conviviale et intuitive, tout en bénéficiant des capacités de personnalisation avancées de Matplotlib. Grâce à son intégration

avec Pandas, Seaborn facilite l'exploration et la visualisation de données structurées, offrant ainsi une solution complète pour l'analyse et la communication des résultats.

### 3.7.4.6 Nlpaug

Une bibliothèque Python dédiée à l'augmentation de données pour le traitement automatique du langage naturel (NLP). Elle offre une gamme de techniques d'augmentation de données pour améliorer la qualité et la diversité de l'ensembles de données textuels.

## Implimentation du modèle PLM-BiLstm-CNN

### 3.7.5 Implémentation des PLMs

#### 3.7.5.1 Le choix du Meilleur PLM(Classification multiclass )

Pour la première partie de notre proposition, qui consiste à choisir le meilleur modèle de langage pré-entraîné (PLM), nous avons commencé par effectuer un fine-tuning sur sept PLMs différents. Nous avons utilisé notre propre ensemble de données et les transformers de la bibliothèque Hugging Face dans l'environnement Google Colaboratory. Afin de choisir les meilleurs paramètres pour les modèles, nous avons suivi le processus suivant :

Tout d'abord, Nous avons entraîné les modèles pendant 50 époques en variant les valeurs de la taille de lot (batch size) entre 32, 64 et 128. Nous avons utilisé une version partiellement prétraitée de notre ensemble de données (avec un learning rate de  $1e-4$ ). Les résultats obtenus sont les suivants :

Modèle	Batch= <b>32</b>	Batch= <b>64</b>	Batch= <b>128</b>
	F1-Score	F1-Score	F1-Score
Bert based	84.16%	85.83%	85.64%
Distelbert based	84.35%	85.46%	83.14%
BERTweet based	83.24%	<b>86.2%</b>	86.15%
RoBERTa base	85%	85.46%	85.37%
BERT large	82.68%	<b>87.12%</b>	/
RoBERTa large	85.77%	86.02%	/
BERTweet large	83.66%	<b>87.05%</b>	/

TABLE 3.2 – Comparaison des résultats selon la taille du lot.

La figure 3.8 présente une comparaison des différents PLMs en termes de F1-Score en fonction de la variation de la taille du lot. Nous observons que le score le plus bas a été obtenu avec une taille de lot de 32, suivi des résultats pour une taille de lot de 128.

### Chapitre 3. Conception et implémentation

Malheureusement, nous n'avons pas pu obtenir les résultats pour les modèles large avec une taille de lot de 128 en raison de l'épuisement complet de la capacité du GPU.

Les valeurs de F1-Score étaient élevées pour une taille de lot de 64. Sur la base de ces résultats, nous avons décidé de fixer la taille du lot à 64 pour les prochaines étapes de notre étude.




FIGURE 3.8 – Comparaison entre les PLMs selon la taille du lot.

En maintenant la taille du lot à 64, nous avons poursuivi avec la même valeur de taux d'apprentissage ( $1e-4$ ) et avons recommencé l'entraînement des modèles en utilisant différentes versions prétraitées de notre ensemble de données. Les résultats obtenus sont présentés dans le tableau 3.8

Modèle	No preprocessed	Half preprocessed	Full preprocessed
	F1-Score	F1-Score	F1-Score
Bert based	84.44%	85.83%	84.35%
Distelbert based	85.09%	85.46%	83.79%
BERTweet based	85.46%	86.2%	86.07%
RoBERTa base	<b>87.03%</b>	85.46%	85.36%
BERT large	/	<b>87.12%</b>	83.98%
RoBERTa large	/	86.02%	41.30%
BERTweet large	/	<b>87.05%</b>	80.27%

TABLE 3.3 – Compararésultats selon le type de prétraitement du dataset.

### Chapitre 3. Conception et implémentation

la figure 3.9 met en évidence que les résultats les plus faibles ont été obtenus avec la version entièrement prétraitée du jeu de données. En revanche, la version partiellement prétraitée du jeu de données a obtenu le meilleur F1-Score pour les plus part des PLMs, surpassant même la version non prétraitée du jeu de données.




FIGURE 3.9 – Comparaison entre les différentes versions de prétraitement.

Après avoir fixé la taille du lot et le type de prétraitement de notre ensemble de données, notre prochaine étape consiste à explorer l'effet du taux d'apprentissage sur l'entraînement de nos modèles. Nous avons décidé de varier le taux d'apprentissage en considérant un intervalle de valeurs. Cette approche nous permettra d'explorer différentes options et de déterminer quelle valeur offre les meilleures performances pour notre tâche spécifique.

L'intervalle que nous avons choisi couvre une large gamme de valeurs de taux d'apprentissage, allant de très petites valeurs comme 0,00002 à des valeurs relativement plus grandes comme 0.001. Cette sélection d'intervalle nous permet d'explorer une diversité de valeurs afin de trouver celle qui optimise l'apprentissage de nos modèles.

Modèle	1e-3	1e-4	2e-4	1e-5	2e-5
	F1-Score	F1-Score	F1-Score	F1-Score	F1-Score
Bert based	40.31%	85.83%	83.42%	84.44%	84.44
Distelbert based	40.02%	85.46%	83.61%	84.90%	84.62%
BERTweet based	40.37%	86.2%	81.29%	<b>87.40%</b>	86.85%
RoBERTa base	85.37%	85.46%	85.37%	86.85%	<b>87.69%</b>
BERT large	/	<b>87.12%</b>	40.39%	86.29%	86.01%
RoBERTa large	/	86.02%	/	/	/
BERTweet large	/	<b>87.05%</b>	/	/	80.27%

TABLE 3.4 – Comparaison des résultats selon le taux d'apprentissage.

la figure 3.10 met en évidence que chacune des PLM arrive à une valeur idéale sous une valeur de aux d'apprentissage donnée .




FIGURE 3.10 – Comparaison des résultats selon le taux d'apprentissage.

Après avoir analysé les résultats, nous avons identifié les trois PLMs qui ont obtenu les meilleurs résultats pour notre tâche de détection des catastrophes naturelles à partir des réseaux sociaux. Nous avons également pris soin de conserver le taux d'apprentissage optimal pour chaque PLM sélectionné.

Modèle	Taux d'apprentissage	prétraitement	taille du lot
BERTweet based	1e-5	Half-Preprocessed	64
RoBERTa base	2e-5	Half-Preprocessed	64
BERT large	1e-4	Half-Preprocessed	64

TABLE 3.5 – Les PLMs choisi avec les meilleurs hyperparamètres .

Cette sélection des trois meilleurs PLMs et l’ajustement du taux d’apprentissage pour chaque modèle constituent une étape cruciale dans notre projet PLM-BiLstm-CNN. Ces choix stratégiques nous permettront de maximiser les performances de nos modèles et d’obtenir des résultats de détection des catastrophes naturelles encore plus précis et fiables.

#### 3.7.5.2 La combinaison des PLMs avec BiLstm

Dans la deuxième phase de notre projet, nous avons combiner les trois PLMs sélectionnés précédemment avec des BiLstm. Les BiLstm sont des réseaux de neurones récurrents qui permettent de capturer des informations à la fois du passé et du futur d’une séquence, améliorant ainsi la compréhension du contexte.

En combinant les PLMs avec les BiLstm, nous espérons à ce que les modèles bénéficient de l’apprentissage préalable des PLMs pour la compréhension du langage, tout en tirant parti de la capacité des BiLstm à modéliser les dépendances temporelles dans les séquences.

Dans notre configuration de BiLSTM, nous avons utilisé deux couches cachées (hidden layers) spécifié par le paramètre (`num_lstm_layers=2`) . et la taille de chaque couche cachées spécifié par 50.

Modèle	PLM	PLM-BiLstm
	F1-Score	F1-Score
BERTweet based	87.40%	87.50%
RoBERTa base	87.69%	88.42%
BERT large	87.12%	84.07%

TABLE 3.6 – Les résultats du PLM-BiLSTM .

la figure 3.11 montrent la comparaison des résultats entre les PLMs et les PLM-BiLstm. permet de comprendre la performance et l’efficacité de l’ajout d’une couche BiLSTM à l’architecture d’un PLM pour les modèles (BERTweet based et RoBERTa base) .

Afin d’offre les meilleures performances pour chaque modèle spécifique, nous avons décidé de varier le taux d’apprentissage en utilisant l’intervalle de valeurs prédéfini précédemment pour les trois modèles.

Modèle	1e-4	2e-4	1e-5	2e-5
BERTweet-BiLSTM	86.94 %	81.11 %	<b>87.50 %</b>	86.11 %
RoBERTa-BiLSTM	85.92%	40.50 %	87.68 %	<b>88.42 %</b>
BERT large-BiLSTM	84.07%	40.37%	86.29%	<b>87.31%</b>

TABLE 3.7 – Comparaison des résultats selon le taux d’apprentissage.

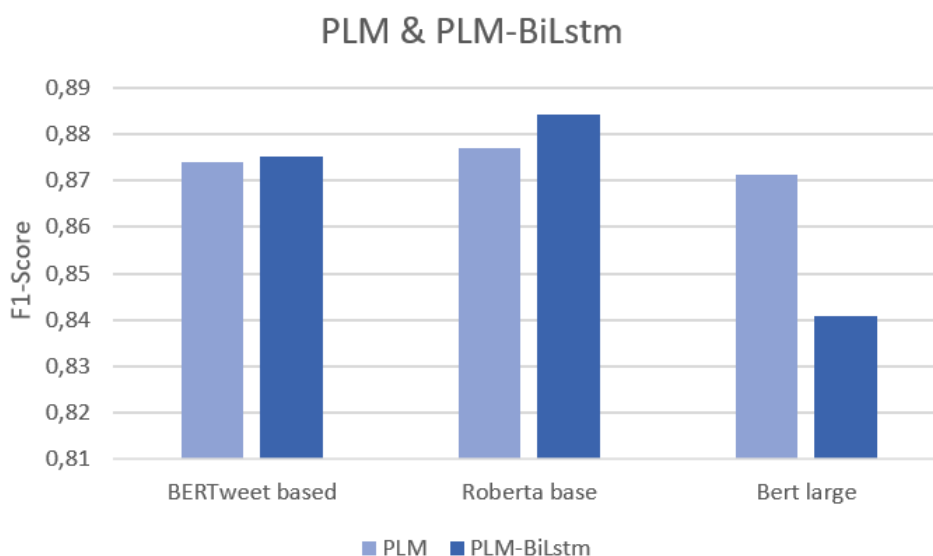


FIGURE 3.11 – PLM & PLM-BiLstm .

Le tableau 3.9 illustre que, pour le modèle BERT large-BiLSTM, la valeur optimale du taux d'apprentissage change après l'ajout de la couche BiLSTM. En revanche, pour les modèles BERTweet-BiLSTM et RoBERTa-BiLSTM, la valeur optimale du taux d'apprentissage reste inchangée. Cette observation suggère que l'ajout de la couche BiLSTM a un impact différent sur les différents modèles.

### 3.7.5.3 La combinaison des PLM-BiLSTM avec CNN

Dans la dernière phase de modèle proposé, nous avons réalisé une combinaison des modèles PLM-BiLSTM avec une couche CNN. Cette combinaison nous permet de tirer parti des avantages de chaque composant. Les PLMs captent les informations contextuelles, tandis que la BiLSTM modélise les dépendances séquentielles. En ajoutant une couche CNN après la BiLSTM, nous améliorons la capacité du modèle à capturer des motifs locaux dans les séquences d'entrée. Cela permet d'obtenir des représentations plus riches et discriminantes pour la tâche spécifique à laquelle le modèle est appliqué.

Pour la configuration de CNN, nous avons déterminé le nombre de filtres que nous avons utilisés dans notre couche CNN (`num_cnn_filters = 3`) aussi les tailles des kernels (filtres) utilisés par la couche CNN (`cnn_kernel_sizes=(2, 3, 4)`)

Modèle	PLM-BiLstm	PLM-BiLSTM-CNN
	F1-Score	F1-Score
BERTweet based	87.50%	87.03%
RoBERTa base	88.42%	85.55%
BERT large	87.31%	83.33%

TABLE 3.8 – Les résultats du PLM-BiLSTM-CNN .

D'après la figure 3.12 nous avons remarquer que Lorsque nous ajoutons une couche CNN à notre modèle PLM-BiLSTM, les résultats ne sont pas satisfaisants . l'ajout de la couche CNN introduit des modifications supplémentaires dans l'architecture du modèle et peut avoir un impact sur les performances.




FIGURE 3.12 – PLM-BiLstm & PLM-BiLSTM-CNN .

En suivant la même approche utilisée précédemment, nous avons entraîné nos modèles en variant les valeurs du taux d'apprentissage. L'objectif était d'optimiser les performances de chaque modèle et de sélectionner l'environnement d'entraînement le plus efficace.

Modèle	1e-4	2e-4	1e-5	2e-5
BERTweet-BiLSTM-CNN	<b>87.03 %</b>	40.37 %	<b>87.03 %</b>	85.83 %
RoBERTa-BiLSTM-CNN	83.88%	40.33 %	<b>86.20 %</b>	85.55 %
BERT large-BiLSTM-CNN	<b>84.16%</b>	82.22%	82.96%	83.33%

TABLE 3.9 – Comparaison des résultats selon le taux d'apprentissage.

### 3.7.5.4 L'ajout d'un optimiseur

L'ajout d'un optimiseur est importante lors de l'entraînement d'un modèle. Pour guider le processus d'optimisation des poids de notre modèle afin de minimiser la fonction de perte ou d'erreur .Nous avons ajouté l'optimizateur ADAM avec un taux d'apprentissage choisis dans l'etape précédent . Le tableau 3.10 met en évidence les résultats, confirmant l'efficacité de ce optimiseur .

Modèle	Sans optimizateur	Adam
	F1-Score	F1-Score
BERTweet-BiLSTM-CNN	87.03%	87.40%
RoBERTa-BiLSTM-CNN	86.20%	88.14 %
BERT-BiLSTM-CNN	84.16%	85.27%

TABLE 3.10 – L’ajout d’un optimiseur.

### 3.7.6 Implémentation des PLMs (Classification binaire)

#### 3.7.6.1 Le choix du Meilleur PLM

Modèle	Batch= <b>32</b>	Batch= <b>64</b>	Batch= <b>128</b>
	F1-Score	F1-Score	F1-Score
DistelBERT based	86.92%	88.55%	87.87%
BERT based	85.17%	89.2 %	89.17 %
BERTweet based	<b>90.3%</b>	89.02 %	89.41%
RoBERTa base	89.12 %	<b>89.8 %</b>	<b>89.76 %</b>
BERT large	88.37 %	87.73%	/
BERTweet large	89.94%	/	/
RoBERTa large	89.01%	/	/

TABLE 3.11 – Comparaison des résultats selon la taille du lot (Classification binaire).

La figure 3.13 présente une comparaison des différents PLMs en termes de F1-Score en fonction de la variation de la taille du lot .




FIGURE 3.13 – Comparaison entre les PLMs selon la taille du lot.

En maintenant la taille du lot à 64, nous avons poursuivi avec la même valeur de taux d'apprentissage ( $1e-5$ ) et avons recommencé l'entraînement des modèles en utilisant différentes versions prétraitées de notre ensemble de données. Les résultats obtenus sont présentés dans le tableau 3.12

Modèle	No preprocessed	Half preprocessed	Full preprocessed
	F1-Score	F1-Score	F1-Score
DistilBERT based	86.53%	88.55%	85.12 %
BERT based	88.92%	89.2%	88.13%
BERTweet based	<b>90.6%</b>	89.02%	85.24%
RoBERTa base	89.04%	<b>89.8%</b>	87.96 %
BERT large	89.24 %	87.73%	86.45 %
BERTweet large	/	/	<b>89.06 %</b>
RoBERTa large	/	/	87.6 %

TABLE 3.12 – Comparaison des résultats selon le type de prétraitement du dataset.

La figure 3.14 montre que les résultats les plus bas ont été obtenus avec la version entièrement prétraitée du dataset. Malheureusement, en raison de l'épuisement complet du GPU, nous n'avons pas pu choisir entre la version partiellement prétraitée et non prétraitée, et certains modèles n'ont pas pu être évalués. Par conséquent, nous avons

décidé de maintenir une taille de lot de 32 pour faciliter la comparaison entre la version prétraitée et non prétraitée du dataset. (tableau :3.13)




FIGURE 3.14 – Comparaison entre les différentes versions de prétraitement.

Modèle	No preprocessed	Half preprocessed
	F1-Score	F1-Score
DistelBERT based	89.15%	86.92%
BERT based	87.38%	85.17 %
BERTweet based	<b>90.25%</b>	<b>90.3%</b>
RoBERTa base	89.18%	89.12%
BERT large	89.78%	88.37%
BERTweet large	89.34%	89.94 %
RoBERTa large	90.22%	89.01 %

TABLE 3.13 – Comparaison entre la version prétraitée et non prétraitée du dataset (taille du lot = 32).

Après avoir analysé la figure 3.15, Nous avons décidé de fixé la taille du lot par 32 pour la suite de notre implémentation pour la classification binaire ainsi que la version du dataset non prétraitée.

Pour nos prochaines expérimentations, nous avons décidé de fixer les hyperparamètres conformément au tableau 3.7. Ces hyperparamètres seront appliqués à la version non prétraitée du dataset.




FIGURE 3.15 – Comparaison entre les différentes versions de prétraitement.

Batch size	Learning rate	Epochs	Early stopping	weight decay
32	[9e-6,5e-5]	50	3	0.01

TABLE 3.14 – Les hyperparamètres choisi.

Selon les résultats obtenus, tous les modèles ont été entraînés jusqu'à l'arrêt sans atteindre les 50 époques en utilisant le rappel du "Early Stopping Callback" fixé à 03.

Modèle	9e-6	1e-5	2e-5	3e-5	4e-5	5e-5
	F1-Score	F1-Score	F1-Score	F1-Score	F1-Score	F1-Score
DistelBERT based	88.54%	89.15%	89.29%	89.58%	89.83%	89.01%
BERT based	87.74%	87.38 %	89.59%	88.85 %	89.32 %	88.11%
BERTweet based	90.13%	<b>90.25%</b>	<b>89.76%</b>	89.69 %	<b>90.1 %</b>	<b>90.2%</b>
RoBERTa base	90.01%	89.18%	89.15%	<b>90.15%</b>	89.65%	89.4%
BERT large	88.71%	89.78%	89.21 %	89.75%	88.9%	87.52 %
BERTweet large	89.45%	89.34 %	87.97%	87.89 %	87.1 %	88.4%
RoBERTa large	<b>90.74%</b>	90.22%	89.75%	90.05%	89.87%	81.2 %

TABLE 3.15 – Comparaison des Plms selon la variation du taux d'apprentissage.

Après avoir examiné la figure3.16, nous avons réussi à classer les meilleurs modèles de langage pré-entraînés (PLMs) en fonction des meilleurs résultats obtenus, en spécifiant pour chaque PLMs son taux d'apprentissage.




FIGURE 3.16 – Comparaison des Plms selon le meilleur taux d’apprentissage.

En se référant au tableau ci-dessous, nous avons sélectionné les trois premiers modèles de langage pré-entraînés (PLMs) en précisant le taux d’apprentissage optimal pour chaque modèle. Cependant, nous avons pris la décision de varier à nouveau le taux d’apprentissage pour les expérimentations ultérieures afin de vérifier cette optimalité.

	PLMs	F1-Score	Learning rate
1	RoBERTa large	90.74 %	9e-6
2	BERTweet base	90.25%	1e-5
3	RoBERTa base	90.15%	3e-5
4	DistilBERT uncased	89.83%	4e-5
5	BERT large	89.78%	1e-5
6	BERT base	89.59%	2e-5
7	BERTweet large	89.45%	9e-6

TABLE 3.16 – Classement des PLMs selon les meilleurs résultats.

### 3.7.6.2 La combinaison des PLMs avec BiLSTM

Modèle	9e-6	1e-5	2e-5	3e-5	4e-5	5e-5
	F1-Score	F1-Score	F1-Score	F1-Score	F1-Score	F1-Score
RoBERTa large-BiLSTM	89.95 %	90.78%	89.43 %	88.51%	79.43%	79.43%
BERTweet base-BiLSTM	90.5%	89.43%	90.17 %	90.11%	88.17%	89.66%
RoBERTa base-BiLSTM	90.07%	90.76%	89.81%	89.47%	89.82%	88.57%

TABLE 3.17 – Le taux d’apprentissage compatible pour PLM-BiLSTM.

### 3.7.6.3 La combinaison des PLMs avec BiLSTM et CNN

Modèle	9e-6	1e-5	2e-5	3e-5	4e-5	5e-5
	F1-Score	F1-Score	F1-Score	F1-Score	F1-Score	F1-Score
RoBERTa large-BiLSTM-CNN	90%	90.07%	90.28%	90.18%	87.49%	86.27%
BERTweet base-BiLSTM-CNN	90.07 %	90.83%	87.93 %	89.69%	85.71 %	90.55%
RoBERTa base-BiLSTM-CNN	90.06%	89.25%	89.83%	89.55%	90.16%	86.83%

TABLE 3.18 – Le taux d’apprentissage compatible pour PLM-BiLSTM-CNN.

## 3.8 Comparaison entre les résultats de nos modèles et du baselines

Pour la comparaison, nous avons pris en compte le travail existant qui se concentre sur l’utilisation de CNN[10] pour la détection des tweets liés aux catastrophes naturelles. De plus, nous avons comparé les résultats finaux de notre modèle avec ceux des modèles basés sur PLM et PLM-BiLSTM. Cette comparaison nous permettra d’évaluer l’efficacité et les performances de notre approche par rapport aux approches existantes dans le domaine de la détection des catastrophes naturelles à partir des réseaux sociaux.

Modèle	multiclass	binaire
	F1-Score	F1-Score
CNN [10]	83.8%	/
PLM	87.69%	90.74
PLM-BiLSTM	(RoBERTa)88.42 %	(RoBERTa large) 90.78%
PLM-BiLSTM-CNN	(RoBERTa) 88.14%	(BERTweet)90.83%

TABLE 3.19 – Comparaison entre les résultats de nos modèles et du baselines .

### 3.9 Conclusion

Dans ce chapitre, nous avons abordé en détail les différentes étapes du processus de détection des tweets liés aux catastrophes naturelles, ainsi que la mise en œuvre de notre modèle proposé. Nous avons présenté les stratégies d'optimisation et d'évaluation que nous avons utilisées pour concevoir et réaliser notre étude. De plus, nous avons discuté des résultats obtenus après une comparaison approfondie entre notre modèle et celui du baseline. Ces résultats nous ont permis de mieux comprendre l'efficacité de notre approche et de mettre en évidence les améliorations apportées par notre modèle par rapport aux méthodes existantes.

# Conclusion et perspectives

### Conclusion générale

dans notre projet nous avons exploré l'utilisation des réseaux sociaux, en particulier Twitter, pour détecter les catastrophes naturelles. Nous avons développé et évalué un modèle basé sur les modèle de Langage Pré-entraîné pour identifier les tweets pertinents liés aux catastrophes.

Tout au long de notre étude, nous avons réalisé différentes étapes clés. Nous avons importé et prétraité les données des tweets, en appliquant des techniques de nettoyage et de normalisation pour améliorer la qualité des informations. Ensuite, nous avons réalisé un fine-tuning des modèles de langage pré-entraînés, tels que BERT et RoBERTa, pour capturer les informations contextuelles des tweets. Nous avons également introduit des composants tels que BiLSTM et CNN pour modéliser les dépendances séquentielles et extraire les caractéristiques locales des tweets.

Pour évaluer notre modèle, nous avons utilisé des mesures de performance telles que la précision, le rappel et la F-mesure. Nous avons également comparé les performances de notre modèle avec celles d'un modèle baseline pour évaluer son efficacité. Les résultats ont montré que notre modèle améliore significativement la détection des tweets liés aux catastrophes par rapport au modèle baseline qui repose uniquement sur l'utilisation d'un CNN pour capturer les information pertinentes à partir de tweets.

En conclusion, notre projet démontre que l'utilisation des réseaux sociaux, en combinaison avec des techniques d'intelligence artificielle, peut être une approche prometteuse pour la détection des catastrophes naturelles en temps réel ou en rétrospective. Notre modèle offre de bonnes performances et contribue à la rapidité et à l'efficacité de la réponse aux catastrophes. Cela ouvre la voie à de futures améliorations et à des applications pratiques dans le domaine de la gestion des catastrophes naturelles.

### Perspectives

- La partie classification reste à exploiter car nous n'avons malheureusement pas assez de temps pour la faire.
- Combinaison parallèle : Un ensembling des PLMs et des autres modèles peut donner plus de robustesse à notre système de détection des catastrophes naturelles.

# Bibliographie

- [5] Gloria ABUKA. “Text Summarization and Sentiment Analysis of Drug Reviews : A Transfer Learning Approach”. Thèse de doct. Middle Tennessee State University, 2023.
- [6] Tahir AHMAD et al. “Efficient fake news detection mechanism using enhanced deep learning model”. In : *Applied Sciences* 12.3 (2022), p. 1743.
- [7] Firoj ALAM et al. “CrisisBench : Benchmarking crisis-related social media datasets for humanitarian information processing”. In : *Proceedings of the International AAAI Conference on Web and Social Media*. T. 15. 2021, p. 923-932.
- [8] Nadège ALAVOINE et Arthur BABIN. “Mise en place d’un modèle compact à architecture Transformer pour la détection jointe des intentions et des concepts dans le cadre d’un système interactif de questions-réponses”. In : *18e Conférence en Recherche d’Information et Applications \\ 16e Rencontres Jeunes Chercheurs en RI \\ 30e Conférence sur le Traitement Automatique des Langues Naturelles \\ 25e Rencontre des Étudiants Chercheurs en Informatique pour le Traitement Automatique des Langues*. ATALA. 2023, p. 37-56.
- [9] Grégoire BUREL et Harith ALANI. “Crisis event extraction service (crees)-automatic detection and classification of crisis-related content on social media”. In : (2018).
- [10] Grégoire BUREL et Harith ALANI. “Crisis event extraction service (crees)-automatic detection and classification of crisis-related content on social media”. In : (2018).
- [11] Cornelia CARAGEA et al. “Classifying text messages for the Haiti earthquake.” In : *ISCRAM*. Citeseer. 2011.
- [12] Muhammad CASTILLO Imran, Prasenjit MITRA et CARLOS. “Twitter as a lifeline : Human-annotated twitter corpora for NLP of crisis-related messages”. In : *arXiv preprint arXiv :1605.05894* (2016).
- [13] Ashis Kumar CHANDA. “Efficacy of BERT embeddings on predicting disaster from Twitter data”. In : *arXiv preprint arXiv :2108.10698* (2021).
- [14] Jishnu Ray CHOWDHURY, Cornelia CARAGEA et Doina CARAGEA. “On identifying hashtags in disaster twitter data”. In : *Proceedings of the AAAI Conference on Artificial Intelligence*. T. 34. 01. 2020, p. 498-506.
- [15] Jacob DEVLIN et al. “Bert : Pre-training of deep bidirectional transformers for language understanding”. In : *arXiv preprint arXiv :1810.04805* (2018).

- [16] Robert DiPIETRO et Gregory D HAGER. “Deep learning : RNNs and LSTM”. In : *Handbook of medical image computing and computer assisted intervention*. Elsevier, 2020, p. 503-519.
- [17] Zhijie Sasha DONG et al. “Social media information sharing for natural disaster response”. In : *Natural hazards* 107 (2021), p. 2077-2104.
- [18] Houssein Eddine DRIDI. “Détection d’évènements à partir de Twitter”. In : (2015).
- [19] Sepp HOCHREITER et Jürgen SCHMIDHUBER. “Long short-term memory”. In : *Neural computation* 9.8 (1997), p. 1735-1780.
- [20] Sadegh Bafandeh IMANDOUST, Mohammad BOLANDRAFTAR et al. “Application of k-nearest neighbor (knn) approach for predicting economic events : Theoretical background”. In : *International journal of engineering research and applications* 3.5 (2013), p. 605-610.
- [21] Muhammad IMRAN et al. “Extracting information nuggets from disaster-Related messages in social media.” In : *Iscram* 201.3 (2013), p. 791-801.
- [22] Muhammad IMRAN et al. “Extracting information nuggets from disaster-Related messages in social media.” In : *Iscram* 201.3 (2013), p. 791-801.
- [23] Muhammad IMRAN et al. “Processing social media messages in mass emergency : A survey”. In : *ACM Computing Surveys (CSUR)* 47.4 (2015), p. 1-38.
- [24] Deepack JAKHAR et Ishmeet KAUR. “Artificial intelligence, machine learning and deep learning : definitions and differences”. In : *Clinical and experimental dermatology* 45.1 (2020), p. 131-132.
- [25] Andreas M KAPLAN et Michael HAENLEIN. “Users of the world, unite! The challenges and opportunities of Social Media”. In : *Business horizons* 53.1 (2010), p. 59-68.
- [26] Anna KRUSPE, Jens KERSTEN et Friederike KLAN. “Detection of actionable tweets in crisis events”. In : *Natural Hazards and Earth System Sciences* 21.6 (2021), p. 1825-1845.
- [27] Ajitesh KUMAR. “K-Fold Cross Validation – Python Example”. In : *Data Analytics Data Analytics AI, Data, Data Science, Machine Learning, Blockchain, Digital* 8 (2023).
- [28] Zhenlong LI et al. “A novel approach to leveraging social media for rapid flood mapping : a case study of the 2015 South Carolina floods”. In : *Cartography and Geographic Information Science* 45.2 (2018), p. 97-110.
- [29] Xialing LIN, Kenneth A LACHLAN et Patric R SPENCE. “Exploring extreme events on social media : A comparison of user reposting/retweeting behaviors on Twitter and Weibo”. In : *Computers in human behavior* 65 (2016), p. 576-581.
- [30] Fausto MILLETARI et al. “Hough-CNN : Deep learning for segmentation of deep brain regions in MRI and ultrasound”. In : *Computer Vision and Image Understanding* 164 (2017), p. 92-102.

- [31] Sumera NAAZ, Zain Ul ABEDIN et Danish Raza RIZVI. “Sequence Classification of Tweets with Transfer Learning via BERT in the Field of Disaster Management”. In : *EAI Endorsed Transactions on Scalable Information Systems* 8.31 (2021), e8-e8.
- [32] Venkata Kishore NEPPALLI, Cornelia CARAGEA et Doina CARAGEA. “Deep neural networks versus naive bayes classifiers for identifying informative tweets during disasters”. In : *Proceedings of the 15th Annual Conference for Information Systems for Crisis Response and Management (ISCRAM)*. 2018.
- [33] Dat NGUYEN et al. “Robust classification of crisis-related data on social networks using convolutional neural networks”. In : *Proceedings of the international AAAI conference on web and social media*. T. 11. 1. 2017, p. 632-635.
- [34] Dat Quoc NGUYEN, Thanh VU et Anh Tuan NGUYEN. “BERTweet : A pre-trained language model for English Tweets”. In : *arXiv preprint arXiv :2005.10200* (2020).
- [35] Thi Huyen NGUYEN et Koustav RUDRA. “Rationale aware contrastive learning based approach to classify and summarize crisis-related microblogs”. In : *Proceedings of the 31st ACM International Conference on Information & Knowledge Management*. 2022, p. 1552-1562.
- [36] Jakub NOWAK, Ahmet TASPINAR et Rafał SCHERER. “LSTM recurrent neural networks for short text and sentiment classification”. In : *Artificial Intelligence and Soft Computing : 16th International Conference, ICAISC 2017, Zakopane, Poland, June 11-15, 2017, Proceedings, Part II 16*. Springer. 2017, p. 553-562.
- [37] Alexandra OLTEANU et al. “Crisislex : A lexicon for collecting and filtering microblogged communications in crises”. In : *Proceedings of the international AAAI conference on web and social media*. T. 8. 1. 2014, p. 376-385.
- [38] Alexandra OLTEANU et al. “Crisislex : A lexicon for collecting and filtering microblogged communications in crises”. In : *Proceedings of the international AAAI conference on web and social media*. T. 8. 1. 2014, p. 376-385.
- [39] Alec RADFORD et al. “Improving language understanding by generative pre-training”. In : (2018).
- [40] Jakob ROGSTADIUS et al. “CrisisTracker : Crowdsourced social media curation for disaster awareness”. In : *IBM Journal of Research and Development* 57.5 (2013), p. 4-1.
- [41] Victor SANH et al. “DistilBERT, a distilled version of BERT : smaller, faster, cheaper and lighter”. In : *arXiv preprint arXiv :1910.01108* (2019).
- [42] Samane SHARIFI MONFARED et Bilal SEDEF. *Natural Language Processing for Prediction of Disaster Tweets using Machine Learning Methods*. Juin 2021.
- [43] Farhad Mortezapour SHIRI et al. “A Comprehensive Overview and Comparative Analysis on Deep Learning Models : CNN, RNN, LSTM, GRU”. In : *arXiv preprint arXiv :2305.17473* (2023).
- [44] Juliana TOLLES et William J MEURER. “Logistic regression : relating patient characteristics to outcomes”. In : *Jama* 316.5 (2016), p. 533-534.

- [45] Fujio TORIUMI et al. “Information sharing on Twitter during the 2011 catastrophic earthquake”. In : *Proceedings of the 22nd International Conference on World Wide Web*. 2013, p. 1025-1028.
- [46] Fujio TORIUMI et al. “Information sharing on Twitter during the 2011 catastrophic earthquake”. In : *Proceedings of the 22nd International Conference on World Wide Web*. 2013, p. 1025-1028.
- [47] Hieu TRAN. “A survey of machine learning and data mining techniques used in multimedia system”. In : *Dept. Comput. Sci., Univ. Texas Dallas Richardson, Richardson, TX, USA, Tech. Rep* (2019).
- [48] Abdul Hasib UDDIN, Durjoy BAPERY et Abu Shamim Mohammad ARIF. “Depression analysis from social media data in Bangla language using long short term memory (LSTM) recurrent neural network technique”. In : *2019 International Conference on Computer, Communication, Chemical, Materials and Electronic Engineering (IC4ME2)*. IEEE. 2019, p. 1-4.
- [49] Ashish VASWANI et al. “Attention is all you need”. In : *Advances in neural information processing systems* 30 (2017).
- [50] Vedran VUKOTIĆ, Vincent CLAVEAU et Christian RAYMOND. “IRISA at DeFT 2015 : supervised and unsupervised methods in sentiment analysis”. In : *DeFT, Défi Fouille de Texte, joint à la conférence TALN 2015*. 2015.
- [51] Yang XIAO, Beiqun LI et Zaiwu GONG. “Real-time identification of urban rainstorm waterlogging disasters based on Weibo big data”. In : *Natural Hazards* 94.2 (2018), p. 833-842.
- [52] Jie YIN et al. “Using social media to enhance emergency situation awareness”. In : *IEEE intelligent systems* 27.06 (2012), p. 52-59.
- [53] Aqsa YOUNAS et al. “Sentiment analysis of code-mixed Roman Urdu-English social media text using deep learning approaches”. In : *2020 IEEE 23rd International Conference on Computational Science and Engineering (CSE)*. IEEE. 2020, p. 66-71.

# Webographie

- [1] <https://www.guidisto-volontariat.fr/blog/aide-urgence/aider-sur-place-catastrophe-naturelle/>. April 2023.
- [2] <https://www.groupe-hli.com/comportement-clients-avec-ia/>. April 2023.
- [3] <https://www.visual-design.net/post/top-machine-learning-algorithms-classification>. April 2023.
- [4] <https://www.artezio.com/pressroom/blog/what-are-embeddings-how-do-they-help-ai-understand-human-world/>. April 2023.