



Mémoire de fin d'étude

PRESENTÉ EN VUE DE L'OBTENTION  
DU DIPLOME DE MASTER

Filière : Informatique  
Option : Réseaux et Multimédia

***Détection de stress en utilisant  
l'apprentissage profond dans les réseaux sociaux***

Préparé par :

- ❖ **Bouazize Ferial**
- ❖ **Loucif Imene**

Devant le jury :

Président	M. Moussaoui Boubakeur	Enseignant à l'université de BBA
Examinatrice	Mme. Chellakh Hafida	Enseignante à l'université de BBA
Encadreur :	M. Naili Makhlouf	Enseignant à l'université de BBA

*Année Universitaire 2023-2024*

## **REMERCIEMENT**

*Nous voulons exprimer vivement nos remerciements les plus respectueux et sincères à notre encadreur Dr. NAILI MAKHLOUF pour ses conseils, sa patience et pour tous ses efforts fournis pour finaliser ce travail.*

*A tous les enseignants qui ont participé à notre formation. Nos remerciements s'adressent également aux membres de jurys qui ont accepté d'évaluer notre travail.*

*Nous tenons à remercier également tous ceux qui nous ont aidées de près ou de loin pour réaliser ce travail.*

## ***Dédicace***

*À celui qui m'a aidé dans mon parcours éducatif, qui Attende ma réussite :*

*Ma chère mère et mon père qui ont toujours m'aider sur ce chemin long d'étude, avec leurs encouragements, leurs conseils et leurs sacrifices.*

*À toute ma famille pour l'amour et le respect qu'ils M'ont toujours accordé.*

*Et finalement à mon binôme Loucif Imen.*

*À toute personne qui m'a aidé à franchir un horizon dans ma vie.*

***Bouazize feriel***

## Dédicace

*C'est avec une joie immense et le cœur ému que je dédie ce mémoire à moi-même en premier et à ma chère famille pour leurs affections inépuisables et leurs précieux conseils.*

*À Ma mère*

*Source inépuisable de tendresse, de patience et de sacrifices, Ta prière et ta bénédiction m'ont été d'un grand secours tout au long de vie, la source de ma réussite et de mes efforts, puisse Dieu tout puissant te préserver et t'accorder santé longue vie et bonheur.*

*À Mon père*

*L'épaule solide la plus design de mon estime et de mon respect aucune dédicace ne saurait exprimer ma reconnaissance et mon profond amour.*

*L'esprit de ma précieuse grand-mère*

*À mes sœurs Sahra, Yasmin, Nour, Lina et ma petite nièce Jana. Et mes frères Mohamed, Abd Al-djalil, Anas, Abd-raouf.*

*Mes chères tantes Soumia, Moufida et à mon binôme Feriel.*

*À mon futur brun et à mes chères amies.*

*À tous ceux que j'aime.*

**Imene loucif**

## RESUME

L'analyse des émotions et l'informatique émotionnelle ont attiré beaucoup d'intérêt dans divers domaines de recherche ces dernières décennies, notamment, avec l'apparition des problèmes concernant la santé psychologique des utilisateurs comme les maladies de stress, d'anxiété et de la dépression. Pour analyser ces impacts de réseaux sociaux, les analyses textuelles sont particulièrement efficaces pour identifier les caractéristiques du comportement humain et décrire l'état émotionnel.

Dans ce projet, des techniques avancées de l'apprentissage profond pour analyser les données des réseaux sociaux sont utilisées, afin de comprendre les signaux émotionnels qui présentent les indices de stress exprimés dans les textes. Pour détecter le stress dans les réseaux sociaux, nous avons analysé les données textuelles de plateformes Twitter et Reddit. L'utilisation du modèle LSTM permet de capturer les dépendances temporelles et contextuelles dans les textes, et d'identifier avec précision des émotions de stress. En plus, les performances de modèle LSTM sont comparées avec celles des méthodes classiques.

**Mots clés :** Analyse de réseaux sociaux, Détection de stress, apprentissage profond, LSTM

## **ABSTRACT**

Emotion analysis and emotional computing have attracted much interest in various research fields in recent decades, particularly with the emergence of problems concerning users' psychological health such as stress, anxiety and depression. To analyze these social media impacts, textual analyzes are particularly effective in identifying characteristics of human behavior and describing emotional state.

In this project, advanced deep learning techniques to analyze social media data are used, in order to understand the emotional signals that present the stress indices expressed in texts. To detect stress in social networks, we analyzed textual data from Twitter and Reddit platforms. Using the LSTM model makes it possible to capture temporal and contextual dependencies in texts, and to accurately identify stressful emotions. Additionally, the LSTM model performance is compared with that of classical methods.

**Key words:** Social networks analysis, Stress detection, Deep learning, LSTM

## ملخص

لقد اجتذب تحليل المشاعر والحوسبة العاطفية الكثير من الاهتمام في مختلف مجالات البحث في العقود الأخيرة، لا سيما مع ظهور مشاكل تتعلق بالصحة النفسية للمستخدمين مثل التوتر والقلق والاكتئاب. وتحليل تأثيرات وسائل التواصل الاجتماعي، تكون التحليلات النصية فعالة بشكل خاص في تحديد خصائص السلوك البشري ووصف الحالة العاطفية.

في هذا المشروع، يتم استخدام تقنيات التعلم العميق المتقدمة لتحليل بيانات وسائل التواصل الاجتماعي، من أجل فهم الإشارات العاطفية التي تمثل مؤشرات التوتر المعبر عنها في النصوص. للكشف عن التوتر في الشبكات الاجتماعية، قمنا بتحليل البيانات النصية من منصات تويتر وريديت. إن استخدام نموذج LSTM يجعل من الممكن التقاط الروابط الزمنية والسياقية في النصوص، وتحديد المشاعر التوتر بدقة. بالإضافة إلى ذلك، تمت مقارنة أداء نموذج LSTM بأداء الطرق الكلاسيكية.

**الكلمات المفتاحية:** تحليل الشبكات الاجتماعية، اكتشاف التوتر، التعلم العميق، LSTM

## Table de matières

<i>Introduction générale</i> .....	1
<i>Chapitre I : Détection du stress via les réseaux sociaux</i>	
I.1. Introduction .....	5
I.2. Réseaux sociaux .....	5
I.2.1. Définition .....	5
I.2.2. Importance des réseaux sociaux .....	6
I.2.3. Impacts de réseaux sociaux sur les relations humaines .....	6
I.3. Détection du stress via les réseaux sociaux .....	7
I.3.1. Signes et indicateurs de stress .....	8
I.3.2. Méthodologie de détection du stress .....	8
I.3.3. Importances de la détection du stress via les réseaux sociaux .....	9
I.4. Conclusion .....	10
<i>Chapitre II : Deep Learning</i>	
II.1. Introduction .....	13
II.2. L'apprentissage profond .....	13
II.2.1. Historique .....	13
II.2.2. Définition .....	13
II.2.3. L'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond .....	14
II.2.4. Mode de fonctionnement .....	15
II.2.5. Types d'apprentissage profond .....	16
II.2.6. Avantages de l'apprentissage profond .....	18
II.2.7. Inconvénients de l'apprentissage profond .....	19
II.2.8. Domaines d'application .....	20
II.3. Modèles d'apprentissage profond .....	21
II.3.1. Réseaux de neurones artificiels simples .....	21
II.3.2. Réseaux de neurones artificiels complexes .....	22
II.4. Modèle d'apprentissage profond utilisé .....	23
II.4.1. Caractéristiques des réseaux LSTM .....	23
II.4.2. Architecture du LSTM .....	24
II.4.3. Fonctionnement du LSTM .....	24
II.4.4. Avantages et inconvénients du LSTM .....	25
II.4.5. Applications des réseaux LSTM .....	26
II.5. Conclusion .....	27

### *Chapitre III : Conception du système*

III.1. Introduction .....	29
III.3. Architecture générale du système .....	31
III.4. Architecture détaillée du système .....	32
III.4.1. Prétraitement de données .....	32
III.4.2. Apprentissage de système.....	33
III.4.3. Utilisation de système .....	35
III.5. Conclusion .....	36

### *Chapitre IV : Implémentation et résultats*

IV.1. Introduction .....	38
IV.2. Environnement et outils de développement.....	38
IV.2.1. Matériels utilisés .....	38
IV.2.2. Langages, logiciels et librairies utilisés .....	38
IV.3. Base de données utilisées .....	41
IV.3.1. Informations générales sur l'ensemble des données.....	41
IV.3.2. Distribution générale de classes .....	42
IV.3.3. Les termes les plus fréquents (Word cloud) .....	43
IV.4. Préparation de données pour la classification .....	45
IV.4.1. Les méthodes de base .....	45
IV.4.2. Apprentissage profond.....	46
IV.5. Résultats et comparaison .....	47
IV.5.1. Résultats obtenus .....	47
IV.6. Discussion des résultats .....	47
IV.6.1. Évaluation des différents Classificateurs .....	47
IV.6.2. Évaluation du modèle LSTM.....	52
IV.7. Conclusion.....	55
<i>Conclusion générale</i> .....	<i>55</i>
<i>Références</i> .....	<i>57</i>

## Liste des figures

<b>Figure I. 1.</b> Quelque plateforme de réseaux sociaux .....	6
<b>Figure I. 2.</b> Influence des Réseaux sociaux .....	7
<b>Figure II. 1.</b> La relation entre l'IA, le ML et DL [14] .....	15
<b>Figure II. 2.</b> Mécanisme d'apprentissage profond.....	16
<b>Figure II. 3.</b> Types d'apprentissage profond .....	18
<b>Figure II. 4.</b> Architecture et fonctionnement de LSTM [22].....	25
<b>Figure III. 1.</b> Architecture générale du système.....	32
<b>Figure IV. 1.</b> Word cloud .....	43
<b>Figure IV. 2.</b> Distribution des classes.....	44
<b>Figure IV. 3.</b> Courbe ROC (gauche) et courbe PRC (droite) des méthodes de base.....	51
<b>Figure IV. 4.</b> Matrice de confusion du SVM.....	52
<b>Figure IV. 5.</b> Les courbes ROC ET PRC du LSTM.....	54
<b>Figure IV. 6.</b> La matrice de confusion du LSTM .....	55

## Liste des Tableaux

<b>Tableau IV. 1.</b> Caractéristiques du matériel.....	38
<b>Tableau IV. 2.</b> Caractéristiques de l'ensemble de données .....	42
<b>Tableau IV. 3.</b> Distribution des classes de l'ensemble de données .....	43
<b>Tableau IV. 4.</b> Les termes les plus fréquents dans la base de données .....	43
<b>Tableau IV. 5.</b> Exemple de prétraitement de texte.....	45
<b>Tableau IV. 6.</b> Les résultats de performance des méthodes de base .....	47
<b>Tableau IV. 7.</b> Les résultats de performance de modèle LSTM. ....	47

## Liste des abréviations

**AI** : Artificiel Intelligence

**ML**: Machine Learning

**DL**: Deep Learning

**RL** : Apprentissage par Renforcement

**NLP** : Traitement du Langage Naturel

**MLP** : Réseaux de Perceptrons Multicouches

**CNN** : Les réseaux de Neurones Convolutionnels

**RNN** : Réseaux de Neurones Récurents

**GAN** : Réseaux de Neurones Génératifs

**LSTM** : Mémoire longue à Court Terme

**ROC**: Receiver Operating Characteristic

**PRC**: Precision-Recall Curve

**SVM** : Machines à Vecteurs de Support

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

# *Introduction générale*

## **Introduction générale**

Grâce à l'essor des technologies de l'information et de la communication, les réseaux sociaux sont devenus indispensables dans notre quotidien. Ceux-ci ont modifié notre façon d'interagir, de partager des informations et de former des opinions. Il est essentiel d'analyser les réseaux sociaux afin de saisir les dynamiques sociales, les tendances et les comportements des utilisateurs en ligne. Grâce au développement des techniques de deep learning, l'analyse des réseaux sociaux a atteint des niveaux de précision et de compréhension encore plus élevés.

Les algorithmes de deep learning ont la capacité de traiter de grandes quantités de données provenant des réseaux sociaux, telles que des textes, des images et des vidéos. Les chercheurs peuvent extraire des caractéristiques complexes et repérer des motifs cachés dans les données sociales en utilisant des réseaux de neurones convolutifs (CNN) pour l'analyse des images et des réseaux de neurones récurrents (RNN) pour le traitement du langage naturel (NLP).

L'utilisation du deep learning dans l'analyse des médias sociaux comporte de nombreux obstacles, mais également de grandes possibilités. La gestion de la diversité et de l'hétérogénéité des données sociales constitue l'un des aspects les plus importants. Le langage informel et les abréviations peuvent être abondants dans les données textuelles, tandis que les images et les vidéos nécessitent des techniques de traitement avancées pour une analyse efficace. En résolvant ces défis, les systèmes basés sur l'apprentissage profond peuvent offrir des points de vue précieux pour la prise de décision dans différents secteurs, tels que le marketing, la politique, la santé publique et la sécurité.

En plus, l'incorporation des méthodes de deep learning dans l'analyse des réseaux sociaux offre de nouvelles opportunités pour appréhender et exploiter les immenses quantités de données générées chaque jour sur les plateformes sociales. L'objectif de cette méthode est d'améliorer la précision des analyses et de favoriser une meilleure compréhension des comportements et des interactions entre les individus en ligne.

Malgré les impacts positifs des réseaux sociaux sur les modes de vie des personnes, particulièrement dans les côtés de communication, d'information et des relations humaines, ils apparaissent des maladies psychiques qui influencent la santé mentale des individus comme le stress, l'isolation et la dépression. La problématique principale traitée dans cette étude, c'est comment l'analyse des réseaux sociaux combinée à l'apprentissage profond peut-elle permettre

une détection efficace du stress et ouvrir la voie à des interventions ciblées pour améliorer le bien-être mental des individus ?

Cette étude réside dans la capacité à détecter le stress de manière précoce et précise en exploitant les interactions et les données des réseaux sociaux. Parmi les objectifs de ce projet de fin d'études est de développer un modèle capable de détecter le stress dans les individus ou les communautés via les réseaux sociaux. Ainsi que, d'évaluer les performances du système, puis explorer les applications potentielles de la détection de stress lié à la surveillance de la santé mentale.

Ce manuscrit est organisé en quatre chapitres qui détaillent la méthodologie utilisée dans ce projet de fin d'études :

**Le premier chapitre :** donne quelques concepts sur les réseaux sociaux puis un aperçu de la détection de stress et les principales techniques.

**Le Deuxième chapitre :** il se concentre sur l'apprentissage profond, en définissant ses caractéristiques principales, ses avantages et ses différents modèles

**Le Troisième chapitre :** détaille la conception du système à développer et présente les méthodes suivies dans ses différentes phases.

**Le Quatrième chapitre :** il décrit l'environnement matériel et logiciel utilisé pour mettre en place le système et discute les résultats expérimentaux obtenus. En dernier lieu, une conclusion générale qui résume les points essentiels de ce travail.

*Chapitre I : Détection du  
stress via les réseaux  
sociaux*

## **I.1. Introduction**

Les réseaux sociaux font aujourd'hui partie intégrante de notre vie quotidienne. Ils sont devenus des outils incontournables pour interagir avec les autres et partager divers contenus en ligne, que ce soit pour rester en contact avec des amis et des membres de la famille, pour trouver de nouvelles opportunités professionnelles, ou simplement pour se divertir, les réseaux sociaux ont investi tous les aspects de notre société moderne.

Dans ce chapitre, nous examinerons comment les réseaux sociaux peuvent être une ressource précieuse pour identifier le stress chez les individus.

## **I.2. Les Réseaux sociaux**

Les réseaux sociaux ont parcouru un long chemin depuis ses premiers jours sur Classmates en 1995 jusqu'à aujourd'hui où nous avons des expériences de réalité virtuelle partagées sur différentes plateformes comme Instagram ou Snapchat. Il a évolué rapidement au fil des années, en grande partie en raison de la concurrence accrue entre les plateformes existantes et des progrès technologiques qui nous ont permis d'accéder à encore plus de moyens d'interaction en ligne. De plus, le contexte culturel peut être important dans le développement de réseaux sociaux ; la compréhension de la culture locale des peuples et d'individus peut aider à établir la confiance entre les utilisateurs, ce qui les amène à rester fidèles même s'ils changent d'ordinateur ou d'appareil [1,2].

### **I.2.1. Définition**

Un réseau social est un site web ou une application qui offre aux utilisateurs la possibilité de se connecter et d'interagir avec d'autres utilisateurs en échangeant des informations, des opinions ou des contenus multimédias. En règle générale, les réseaux sociaux utilisent des algorithmes qui trient les données afin de les présenter aux utilisateurs en fonction de leurs intérêts et de leurs interactions antérieures [3,4].

Les utilisateurs ont également la possibilité de créer des profils, d'ajouter des amis et de rejoindre des communautés spécifiques afin de communiquer avec d'autres individus qui partagent les mêmes intérêts et passions. Ils proposent diverses fonctionnalités comme la publication, le partage et l'échange de commentaires, de messages, de photos et de vidéos. De plus, ils offrent aux entreprises et aux marques la possibilité d'impliquer leur public cible de manière innovante et plus personnelle.

La figure suivante représente un aperçu sur quelques plateformes de médias sociaux les plus connues, par exemple, Facebook, Instagram, Twitter et LinkedIn.



**Figure I. 1.** Quelques logos de réseaux sociaux

### **I.2.2. Importance des réseaux sociaux**

Les réseaux sociaux ont profondément transformé notre approche de la communication, de la socialisation et de la consommation d'informations, tel que :

- De nouvelles possibilités ont été ouvertes pour établir des liens sociaux, échanger des opinions, des idées et des expériences.
- Les médias sociaux ont également occupé une place essentielle dans les mouvements sociaux et les causes humanitaires en offrant une plateforme permettant de sensibiliser, mobiliser et recueillir des fonds.
- Ils ont acquis une importance capitale dans le domaine du commerce en ligne et de la publicité.

### **I.2.3. Impacts de réseaux sociaux sur les relations humaines**

Les réseaux sociaux ont eu des impacts profonds sur les relations humaines. Parmi ces impacts on cite [5]:

- Ils facilitent la communication à distance, permettant aux personnes de rester en contact avec des proches éloignés géographiquement et de partager des moments importants de leur vie.

- Les réseaux sociaux peuvent également causer des conflits et des malentendus en raison de la rapidité avec laquelle les informations sont partagées et de l'anonymat qu'ils offrent.
- Ils ont également contribué à l'émergence de nouvelles formes de relations et de rencontres en ligne.
- Ils peuvent entraîner la dépendance et la perte de temps, ainsi qu'une pression constante à cause de comparaison sociale.

La figure suivante représente les différentes manières de communication entre les gens, en utilisant les différents types d'informations comme les messages, les vidéos, les images. Ces communications peuvent être déroulées malgré les endroits éloignés des utilisateurs.



**Figure I. 2.** Influence des Réseaux sociaux

### **I.3. Détection du stress via les réseaux sociaux**

La santé mentale est une préoccupation majeure dans la société actuelle, et si elle n'est pas traitée de manière appropriée, elle peut rapidement se transformer en pensées suicidaires. La détection précoce de problèmes de santé mentale, telle que le stress, est un moyen d'intervention efficace. Cette détection peut être basée sur le contenu généré par les utilisateurs sur les plateformes de réseaux sociaux [6].

Le concept de détection du stress via les données textuelles fait son apparition comme un sujet important dans la littérature, en raison de sa valeur dans l'analyse de la santé mentale

et physique des individus. Elle est définie comme la reconnaissance des émotions qui sont étroitement liées à l'état de stress, comme l'anxiété, la confusion, la contrariété, etc. Cette tâche a été profondément étudiée du point de vue des signaux biologiques. Cependant, les données textuelles obtenues provenant des services de messagerie ou des réseaux sociaux servent de source tout aussi importante pour analyser le stress chez les individus [7].

### **I.3.1. Signes et indicateurs de stress**

Les signes et indicateurs de stress sur les réseaux sociaux peuvent se manifester de différentes manières, notamment [8]:

- a. Changements dans le langage** : Utilisation accrue de mots liés à l'anxiété, la dépression ou la fatigue.
- b. Fréquence des postes** : Augmentation ou diminution soudaine de la fréquence des publications.
- c. Heures de publication** : Activité en ligne à des heures inhabituelles (tard dans la nuit, tôt le matin).
- d. Interactions sociales** : Réduction des interactions sociales ou réponses négatives aux commentaires.
- e. Contenu émotionnel** : Publications exprimant des émotions négatives comme la tristesse, la colère ou le désespoir.

### **I.3.2. Méthodologie de détection du stress**

Il existe plusieurs méthodes pour la détection du stress. Ces méthodes peuvent être classées en trois catégories qui sont [9]:

#### **a. Analyse de contenu textuel**

L'analyse de contenu textuel implique l'extraction et l'analyse de mots, phrases et expressions dans les publications pour détecter des signes de stress. Cela peut inclure :

- **Lexiques émotionnels** : Cette approche utilise un lexique de mots annotés avec leur polarité de sentiment respective (positive, négative). Le sentiment d'un texte est déterminé en fonction des valeurs de sentiment des mots qu'il contient. Par exemple, imaginez que nous ayons un lexique avec les entrées suivantes :
  - Anxiety: anxious, stressed, nervous, and worried
  - Depression: depressed, sad, melancholic, hopeless
  - Fatigue: exhausted, tired, worn out, fatigued

- **Analyse de la sémantique** : Compréhension du contexte dans lequel des mots spécifiques sont utilisés. Les techniques de Word Embedding, comme Word2Vec ou GloVe, aident à saisir le contexte sémantique des mots en le représentant sous forme de vecteurs.

**a. Reconnaissance des sentiments**

La reconnaissance des sentiments consiste à identifier les émotions exprimées dans le texte. Ces techniques incluent :

- **Analyse des sentiments** : Classification des textes comme positifs, négatifs. Des algorithmes comme Naïve Bayes, Support Vector Machines (SVM), et des modèles de Deep Learning sont souvent utilisés pour cette tâche.
- **Évaluation des sentiments** : Mesure de l'intensité émotionnelle dans les publications.

**b. Analyse des comportements en ligne**

Cette approche examine les comportements des utilisateurs sur les réseaux sociaux, tels que :

- **Modèles de publication** : Analyse des tendances dans la fréquence et le timing des publications. Par exemple, une analyse de séries temporelles peut être utilisée pour détecter des changements significatifs dans les habitudes de publication.
- **Interactions sociales** : Suivi des interactions avec d'autres utilisateurs, y compris les réponses aux commentaires et la participation à des discussions. Une diminution des interactions positives ou une augmentation des interactions négatives peuvent être des indicateurs de stress. [7]

### **I.3.3. Importances de la détection du stress via les réseaux sociaux**

La détection du stress dans les réseaux sociaux est importante dans les domaines de la psychologie et de la santé mentale, où [10]:

- L'analyse des conversations en ligne peut permettre d'identifier les individus en stress et de leur offrir un soutien approprié.
- La détection précoce des signaux de stress ou de comportements suicidaires sur les réseaux sociaux peut aider à prévenir les suicides en permettant une intervention rapide par des professionnels de la santé mentale ou des services d'urgence.

- En analysant les tendances du stress dans les communautés en ligne, les autorités de santé publique peuvent obtenir des informations sur les facteurs de stress émergents, les crises potentielles et les besoins en matière de santé mentale dans différentes populations.
- L'analyse des données des réseaux sociaux offre également des opportunités pour la recherche en psychologie et en sciences sociales. La détection du stress à grande échelle peut fournir des données précieuses pour comprendre les dynamiques sociales, les facteurs de stress culturels et les réponses individuelles au stress.

#### **I.4. Conclusion**

Au cours de ce chapitre, nous avons exploré les différentes approches pour la détection du stress dans l'environnement des réseaux sociaux.

Le chapitre suivant va approfondir aux aspects techniques de l'apprentissage profond, en discutant quelques types de réseaux de neurones, comme les réseaux de neurones récurrents, les réseaux de neurones convolutionnels. Et comment ces modèles traitent-ils les données textuelles et comportementales pour détecter le stress.

# *Chapitre II : Deep Learning*

## **II.1. Introduction**

L'apprentissage profond est un domaine de pointe de l'intelligence artificielle qui a transformé la manière dont les machines apprennent et font des prédictions. Avec sa capacité à gérer de grandes quantités de données et à détecter des modèles complexes.

L'apprentissage profond a été appliqué à un large éventail d'applications, de la reconnaissance d'images et de la parole aux voitures autonomes et au diagnostic médical. Dans ce chapitre, nous allons d'abord présenter les notions liées à l'apprentissage profond.

## **II.2. L'apprentissage profond**

### **II.2.1. Historique**

L'exploration des réseaux neuronaux du cerveau humain, avec l'introduction du réseau de neurones perceptron à la fin des années 1950 et au début des années 1960, est à l'origine de l'apprentissage profond. Dans les années 1980, l'algorithme de rétropropagation a été introduit, permettant une adaptation efficace du poids des connexions dans les réseaux multicouches.

Toutefois, le deep learning est réellement à l'honneur au 21<sup>e</sup> siècle, sous l'influence de l'explosion du Big Data et des avancées majeures dans la puissance de calcul, en particulier l'utilisation des GPU. L'édition 2012 du concours ImageNet a été un tournant dans l'apprentissage profond, AlexNet dépassant les techniques classiques de vision par ordinateur. L'évolution de l'apprentissage profond est le reflet de l'interaction entre la théorie, l'expérimentation et le développement technique [11].

### **II.2.2. Définition**

L'apprentissage profond (Deep Learning) est une forme d'intelligence artificielle qui enseigne aux ordinateurs à accomplir des tâches en se basant sur des exemples, tout comme les êtres humains. Imaginez enseigner à un ordinateur la reconnaissance des chats : au lieu de lui demander de chercher des moustaches, des oreilles et une queue, vous lui présentez des milliers de photos de chats. L'ordinateur découvre lui-même les schémas fréquents et acquiert la capacité d'identifier un chat. Il s'agit de la base de l'apprentissage profond.

L'apprentissage profond se base sur ce qu'on nomme des "réseaux de neurones", qui sont inspirés du cerveau humain. Ces réseaux se composent de différentes couches de nœuds interconnectés qui gèrent les données. Plus les couches sont nombreuses, plus le réseau est

« profond », ce qui lui permet d'acquérir des compétences plus avancées et de réaliser des tâches plus complexes [12].

### **II.2.3. L'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond**

Dans ce qui suit, on va présenter les relations et les différences entre les trois domaines l'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond qui dominent actuellement l'évolution technologique dans le monde, ainsi que les modes de vis des individus [13].

#### **L'intelligence artificielle**

L'intelligence artificielle (IA) représente l'ensemble des méthodes permettant aux machines de simuler les capacités cognitives des êtres humains. Elle englobe divers processus tels que la résolution de problèmes, le développement des connaissances et la prise de décisions. Les systèmes d'IA varient en complexité, allant d'algorithmes simples et déterministes à des réseaux de neurones avancés capables d'apprentissage et d'évolution.

#### **L'apprentissage automatique**

L'apprentissage automatique ou la machine learning (ML) est une branche de l'IA qui se concentre sur la capacité des ordinateurs à apprendre et à prendre des décisions à partir de données sans être explicitement programmés. Il utilise des méthodes statistiques pour permettre aux machines d'améliorer leurs performances dans une tâche spécifique au fil du temps et avec l'expérience. Le ML comprend divers algorithmes tels que les arbres de décision, SVM et les réseaux de neurones.

#### **L'apprentissage profond**

L'apprentissage profond ou le deep learning (DL) est un sous-ensemble de l'apprentissage automatique (ML) qui utilise des réseaux de neurones à plusieurs couches, d'où le terme « profond » pour apprendre à partir de grandes quantités de données. Le DL est particulièrement efficace pour des tâches telles que la reconnaissance d'images et de parole, car il peut apprendre des motifs complexes dans les données. Il s'inspire de la structure et du fonctionnement du cerveau, en particulier des interconnexions entre les neurones. [12]

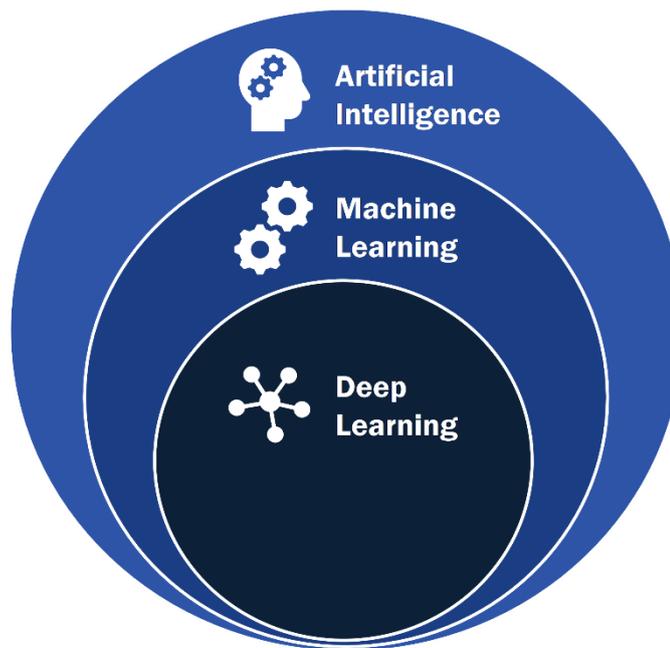


Figure II. 1. La relation entre l'IA, le ML et DL [14]

#### II.2.4. Mode de fonctionnement

Les algorithmes de l'apprentissage profond imitent la configuration naturelle du cerveau humain en utilisant des réseaux de neurones artificiels composés de multiples couches de nœuds interconnectés, appelés neurones artificiels ou unités. Chaque couche traite l'information venant de la couche précédente pour la transmettre à la couche suivante, ce qui permet une extraction plus fine des caractéristiques et des schémas.

Les modèles d'apprentissage profond sont entraînés à partir de grandes quantités de données étiquetées, appelées ensembles d'entraînement, pour apprendre comment reconnaître et classer des schémas. Il peut s'agir d'ensembles d'entraînement simples, comme un ensemble de données « chiens et chats » où la vision artificielle doit classer des photos selon qu'elles contiennent un chien ou un chat. Ces ensembles de données peuvent aussi être plus sophistiqués et couvrir par exemple l'appréciation du lait ou la détection de fausses informations dans des rapports authentiques.

Au cours de l'entraînement, les paramètres et les pondérations du réseau de neurones sont ajustés de sorte à réduire au minimum l'écart entre les sorties prévues et les sorties réelles. Au fil des multiples itérations, le modèle gagne en finesse jusqu'à être capable de formuler des prédictions ou d'exécuter des tâches avec un haut niveau d'exactitude et de précision [15].

L'apprentissage profond utilise l'extraction de caractéristiques pour reconnaître les caractéristiques similaires d'une même étiquette, puis utilise les limites de décision pour déterminer quelles caractéristiques représentent précisément chaque étiquette. Dans la classification des chiens et des chats, les modèles d'apprentissage profond extraient des informations telles que les yeux, le visage et la forme du corps des animaux et les divisent en deux classes.

Le modèle d'apprentissage profond se compose de réseaux neuronaux profonds. Le réseau neuronal simple se compose d'une couche d'entrée, d'une couche cachée et d'une couche de sortie. Les modèles d'apprentissage profond se composent de plusieurs couches cachées, avec des couches supplémentaires que la précision du modèle a améliorées.

Les couches d'entrée contiennent des données brutes et les transfèrent aux nœuds des couches cachées. Les nœuds des couches cachées classent les points de données sur la base d'informations cibles plus larges et, avec chaque couche suivante, la portée de la valeur cible se réduit pour produire des hypothèses précises. La couche de sortie utilise les informations de la couche cachée pour sélectionner l'étiquette la plus probable. Dans notre cas, il s'agit de prédire avec précision l'image d'un chien plutôt que celle d'un chat.

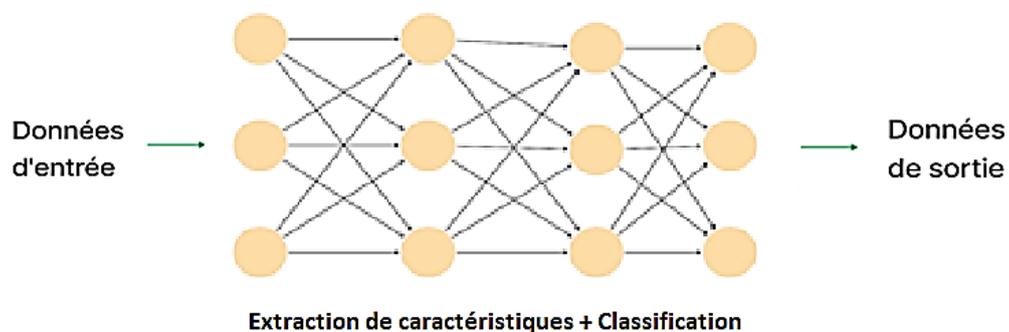


Figure II. 2. Mécanisme d'apprentissage profond.

## II.2.5. Types d'apprentissage profond

### a. L'apprentissage supervisé

L'apprentissage supervisé utilise un ensemble de données étiquetées pour former des modèles permettant de classer des données ou de prédire des valeurs. L'ensemble de données contient des caractéristiques et des étiquettes cibles, qui permettent à l'algorithme d'apprendre au fil du temps en minimisant la perte entre les étiquettes prédites et les étiquettes réelles. L'apprentissage supervisé peut être divisé en problèmes de classification et de régression.

**Classification** - L'algorithme de classification divise l'ensemble de données en plusieurs catégories sur la base d'extractions de caractéristiques. Les modèles d'apprentissage profond les plus populaires sont ResNet50 pour la classification des images et BERT pour la classification des textes.

**Régression** - Au lieu de diviser l'ensemble des données en catégories, le modèle de régression apprend la relation entre les variables d'entrée et de sortie pour prédire le résultat. Les modèles de régression sont couramment utilisés pour l'analyse prédictive, les prévisions météorologiques et la prévision des performances boursières. LSTM et RNN sont des modèles de régression d'apprentissage profond appréciés. [16]

**b. L'apprentissage non supervisé**

Les algorithmes d'apprentissage non supervisé apprennent le modèle au sein d'un ensemble de données non étiqueté et créent des clusters. L'apprentissage non supervisé est utilisé pour le regroupement de diverses espèces, l'imagerie médicale et les études de marché. Le modèle d'apprentissage profond le plus courant pour le clustering est l'algorithme de clustering intégré profond.

**c. L'apprentissage par renforcement**

L'apprentissage automatique par renforcement (RL) consiste à enseigner aux agents différents comportements en fonction de leur environnement. Ces actions aléatoires sont réalisées par cet agent et lui valent des récompenses. L'agent acquiert la capacité d'atteindre ses objectifs en expérimentant et en commettant des erreurs dans un environnement complexe sans l'intervention humaine. Récemment, le RL a connu une forte demande d'automatisation en raison des progrès réalisés dans le domaine de la robotique, des voitures autonomes, de la victoire sur des joueurs professionnels et de l'atterrissage de fusées sur la terre. [16].

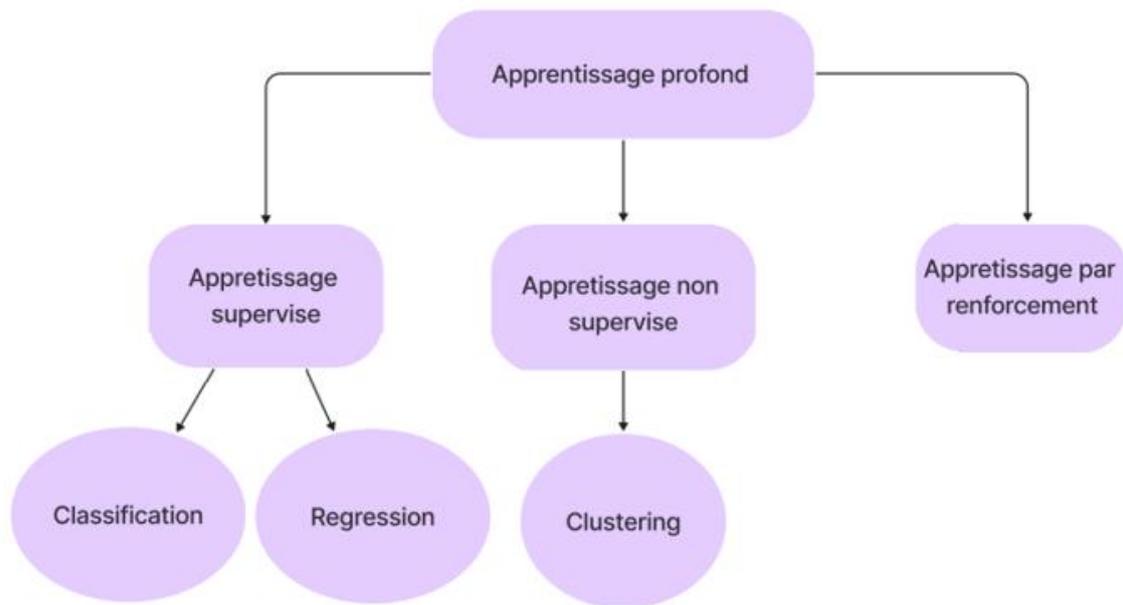


Figure II. 3. Types d'apprentissage profond

### II.2.6. Avantages de l'apprentissage profond

L'apprentissage profond présente plusieurs avantages par rapport aux méthodes traditionnelles d'apprentissage automatique, parmi lesquels [17]:

**Apprentissage automatique des caractéristiques** - Les algorithmes de DL capables d'apprendre automatiquement des caractéristiques, ce qui élimine la nécessité d'une intervention manuelle. Cela est particulièrement utile pour les tâches dont les propriétés sont difficiles à définir, telles que la reconnaissance d'images.

**Traitement d'ensembles de données énormes et complexes** - Les algorithmes de DL permettent de traiter des ensembles de données énormes et complexes que les algorithmes traditionnels d'apprentissage automatique auraient du mal à comprendre. Cette caractéristique en fait un outil puissant qui peut être exploité pour obtenir des informations à partir d'une quantité colossale de données et d'énormes ensembles de données.

**Amélioration des performances** - Les algorithmes de DL se sont révélés plus performants grâce à leur intégration dans une série d'applications telles que la reconnaissance d'images et de sons, le traitement du langage naturel et la vision par ordinateur.

**Traitement des relations non linéaires** - L'un des plus grands avantages de DL est sa capacité à identifier les relations non linéaires dans les données, ce qui n'est pas le cas des méthodes précédentes qui sont difficiles et complexes à discerner.

**Traitement de différents types de données** - Les algorithmes de DL ont la capacité de traiter des données structurées et non structurées telles que des images, des textes et des fichiers audios.

**Capacité accrue compte tenu de leur complexité** - Les réseaux neuronaux de DL avec plusieurs couches cachées, conviennent parfaitement aux problèmes à grande échelle et de haute dimension. Cela s'explique par le grand nombre de paramètres. Il peut simuler des corrélations non linéaires complexes dans les données, ce qui le rend particulièrement adapté aux ensembles de données complexes.

**Apprentissage non supervisé et automatisé** – Le DL permet d'entraîner à apprendre des représentations de données et à effectuer des tâches ou à initialiser des modèles d'apprentissage supervisés à l'aide d'un apprentissage de représentation non supervisé. Il peut également fournir des fonctionnalités ou des compétences précieuses et importantes sans nécessiter d'intervention humaine.

**Adaptabilité et évolutivité** - Les modèles de DL sont hautement adaptables. Les modèles peuvent être affinés ou adaptés à de nouvelles tâches avec une quantité limitée de données étiquetées en utilisant et en exploitant les informations acquises lors de tâches précédentes. Cet avantage s'avère utile dans les exigences d'application ou de cas d'utilisation où il y a une pénurie de données étiquetées.

**Capacité à gérer les données manquantes ou manquantes** - Un autre avantage du DL est sa capacité à fonctionner même lorsque les données font défaut. Un modèle spécifique peut gérer les données manquantes ou absentes en apprenant à imputer automatiquement les valeurs manquantes. Cela en fait un outil approprié et idéal pour les scénarios impliquant des données incomplètes ou déformées.

### **II.2.7. Inconvénients de l'apprentissage profond**

Malgré ses avantages, l'apprentissage profond est également connu pour poser des problèmes inhérents à sa mise en œuvre en raison de problèmes techniques. Examinons également en détail les inconvénients potentiels de l'apprentissage profond.

**Nécessite une grande quantité de données** - Une quantité importante de données de haute qualité est nécessaire au bon fonctionnement d'un modèle d'apprentissage profond. Cette exigence massive nécessite beaucoup de temps et de ressources pour l'obtention des données.

**Besoins de ressources informatiques étendus** - L'apprentissage d'un modèle spécifique avec d'énormes ensembles de données nécessite davantage de ressources informatiques que d'autres modèles d'apprentissage automatique. Parmi les exemples, les processeurs centraux et les unités de traitement graphique puissants, les grandes quantités de stockage et les mémoires vives, etc.

**Tendances au surajustement** – Dans ce cas, le modèle donne de bons résultats sur les données d'apprentissage, mais des résultats comparativement médiocres sur les données non utilisées. Le modèle peut alors fournir des réponses non pertinentes ou incorrectes.

**Problèmes d'interprétation** - Les modèles de DL peuvent être compliqués à interpréter ou à expliquer, contrairement à ce qui se passe avec les algorithmes et les modèles d'apprentissage automatique traditionnels. Certaines personnes peuvent avoir du mal à comprendre le mécanisme de fonctionnement du modèle ou ses processus de prise de décision.

**Préoccupations juridiques et éthiques** – Les modèles de DL peuvent refléter, voire exacerber, les biais existants dans les données d'apprentissage. Les résultats obtenus à partir de données biaisées sont biaisés. De plus, l'utilisation de données privées et de la propriété intellectuelle soulève des questions juridiques complexes. Ces difficultés doivent être prises en compte lors de la création et de la mise en œuvre des systèmes d'apprentissage.

**Expertise inadéquate dans le domaine** - Pour mettre en œuvre le DL, il est nécessaire d'avoir une connaissance approfondie du domaine et du problème en question. En l'absence d'expertise dans le domaine, la tâche consistant à déterminer le problème à résoudre et à sélectionner un algorithme approprié sera difficile.

## **II.2.8. Domaines d'application**

L'apprentissage profond a un large éventail d'applications dans plusieurs secteurs et domaines. Certaines des applications les plus courantes incluent [16]:

**La traduction automatique :** Les modèles de DL sont utilisés dans le domaine de la traduction automatique afin d'améliorer la qualité des traductions. Ils tirent des connaissances à partir de vastes ensembles de données plurilingues et traduire des textes de manière précise.

**Traitement du langage naturel (NLP)** - C'est un domaine où le DL se démarque. Il offre la possibilité de concevoir des modèles capables de saisir et de produire du texte. Le NLP

basé sur le DL est utilisé par les chatbots, les assistants virtuels et les systèmes de recommandation.

**Reconnaissance faciale** – Le DL est utilisé dans l'identification des individus à partir d'observations visuelles ou de vidéos. Il existe des utilisations dans ce sens, pour la sécurité, la surveillance et les réseaux sociaux.

**Marketing et recommandations personnalisées** : Les entreprises font appel au DL pour analyser les données des clients, anticiper leurs préférences et adapter les recommandations de produits ou de services.

**Robotique** : Le DL est utilisé dans la robotique pour la perception, la planification et le contrôle des robots. Il permet aux robots d'apprendre à manipuler des objets, à naviguer dans des environnements complexes et à interagir avec leur environnement.

**Les voitures autonomes** : Le DL joue un rôle essentiel dans la croissance des voitures autonomes. Les réseaux de neurones sont employés dans les systèmes de perception des véhicules afin de repérer les piétons, les panneaux de signalisation, les autres véhicules, et ainsi de suite.

**La reconnaissance d'images** : Le DL est utilisé dans le domaine de la reconnaissance d'images. Les systèmes ont la capacité de repérer et de classer des objets, des visages, des animaux, et ainsi de suite. L'utilisation de cette technologie se fait dans les domaines de la sécurité, de la médecine (analyse d'images médicales) et de la conduite autonome.

**Diagnostic médical** : Le DL est utilisé pour l'analyse d'imagerie médicale (exemple : la radiographie et l'IRM), diagnostic de maladies, découverte de médicaments, prédiction de résultats, cliniques, etc.

## **II.3. Modèles d'apprentissage profond**

### **II.3.1. Réseaux de neurones artificiels simples**

Les réseaux de neurones artificiels sont un type de modèle d'apprentissage automatique inspiré par la structure et la fonction du cerveau humain. Ils sont composés de nœuds interconnectés ou "neurones" qui traitent et transmettent des informations. Les nœuds sont organisés en couches, et chaque couche exécute une fonction spécifique dans le traitement des données d'entrée.

**Perceptron** - C'est l'unité fondamentale d'un réseau de neurones, semblable à un neurone dans le cerveau humain. Il reçoit des signaux d'entrée, les traite et produit un signal de sortie. Le perceptron est composé de valeurs d'entrée  $E$ , de poids  $P$ , d'un *biais*(seuil) et d'une fonction d'activation  $f$ . Tel que :

$$\text{sortie} = f(\sum(E_i * P_i) + \text{biais})$$

**Réseaux de Perceptrons Multicouches (MLP)** - Ce sont des réseaux de neurones comportant une ou plusieurs couches cachées entre les couches d'entrée et de sortie. Chaque couche est composée de perceptrons et ils sont capables d'apprendre des relations non linéaires. Les MLP sont largement utilisés pour des tâches complexes telles que la reconnaissance d'images et de parole.

**Fonctions d'Activation** - Ces fonctions déterminent la sortie d'un nœud (ou neurone) de réseau de neurones étant donné une entrée ou un ensemble d'entrées. Parmi les fonctions d'activation courantes [18], on trouve :

- **ReLU (Unité Linéaire Rectifiée)** : elle ne laisse passer que les valeurs positives, désactivant efficacement les valeurs négatives. Elle est représentée comme suit :  $f$

$$f(x) = \max(0, x).$$

- **Sigmoïde** : cette fonction écrase les valeurs d'entrée dans une plage entre 0 et 1, ce qui est utile pour la classification binaire. Elle est représentée comme suit :

$$S(x) = \frac{1}{1 + e^{-x}}$$

- **Tanh (Tangente Hyperbolique)** : elle est similaire à la sigmoïde, mais avec des valeurs de sortie allant de -1 à 1.

### II.3.2. Réseaux de neurones artificiels complexes

Une variété de réseaux de neurones se distingue par leurs architectures et leurs rôles spécifiques. Dans ce qui suit, nous examinerons quelques types de réseaux de neurones complexes qui sont fréquemment intégrés dans le domaine de deep learning [19]:

**Réseaux de neurones convolutifs** - Les Réseaux de neurones convolutifs CNNs sont des architectures informatiques spécialisées dans le traitement visuel, capables de distinguer et d'identifier divers objets au sein d'une image. Ils trouvent leur utilité dans des domaines tels que la détection de formes, l'identification d'éléments visuels et la reconnaissance d'objets. Un CNN est structuré en trois niveaux principaux : la couche de convolution, qui réalise

l'essentiel des opérations mathématiques ; la couche de pooling, qui simplifie les informations en réduisant les dimensions des données ; et la couche complètement connectée, qui interprète et classe les informations traitées.

**Réseaux de neurones génératifs** - Les réseaux génératifs adverses (GAN) sont capables de créer de nouvelles données qui semblent si réalistes qu'elles pourraient être confondues avec de véritables données issues de l'ensemble sur lequel elles ont été formés. Ces systèmes sont notamment utilisés pour produire des œuvres d'art artificielles qui imitent les styles artistiques connus, résultant en des créations qui peuvent être difficiles à distinguer de celles réalisées par des artistes humains.

**Réseaux de neurones récurrents** - Les Réseaux de neurones récurrents (RNN), quant à eux, sont conçus pour gérer des séquences de données, ce qui les rend idéaux pour des applications telles que la traduction linguistique, la reconnaissance de la parole, l'analyse sémantique du langage et la description d'images. On retrouve les RNN dans des dispositifs comme les assistants vocaux intelligents et les commandes vocales sur smartphones. Leur particularité réside dans leurs boucles de rétroaction, qui leur permettent de retenir des informations de manière analogue à la mémoire humaine.

**Réseaux LSTM** - Les réseaux de neurones LSTM (Long Short-Term Memory) représentent une évolution des réseaux de neurones récurrents, développés initialement par Hochreiter et Schmidhuber. Ces réseaux sont particulièrement performants pour les tâches de prédiction impliquant des séquences, grâce à leur aptitude à identifier et à retenir des dépendances sur de longues périodes. Les LSTM trouvent leur utilité dans des domaines nécessitant l'analyse de données séquentielles ou temporelles. Leur principal atout est leur capacité à appréhender des relations séquentielles importantes, ce qui les rend indispensables pour des applications complexes comme la traduction automatique ou la reconnaissance de la parole.

## **II.4. Modèle d'apprentissage profond utilisé**

Le modèle d'apprentissage profond utilisé pour la résolution du problème de détection de stress dans les réseaux sociaux est le réseau LSTM. Dans ce qui suit, une description détaillée de ce modèle avancé va être donnée :

### **II.4.1. Caractéristiques des réseaux LSTM**

Les LSTMs sont un type de (RNN) conçu pour capturer les dépendances à long terme dans les données séquentielles. Les LSTM sont équipés d'une cellule mémoire capable de

maintenir les informations sur de longues périodes, ce qui les rend particulièrement efficaces pour les tâches impliquant des données de séries chronologiques, le traitement du langage naturel et la reconnaissance vocale.

Les LSTMs résolvent le problème du gradient de disparition des RNN traditionnels en introduire des mécanismes de contrôle qui régulent le flux d'informations à travers le réseau, leur permettant d'apprendre et de mémoriser des modèles sur des séquences étendues [20].

## **II.4.2. Architecture du LSTM**

L'architecture du LSTM est composée de plusieurs éléments clés qui lui permettent d'apprendre et de mémoriser des informations sur de longues périodes.

**L'État de la Cellule** - L'état de la cellule est le composant central de l'architecture LSTM. C'est un vecteur qui est mis à jour à chaque pas de temps et qui contient les informations dont le LSTM doit se souvenir. L'état de la cellule est mis à jour par les portes, qui sont responsables de contrôler le flux d'informations dans et hors de l'état de la cellule.

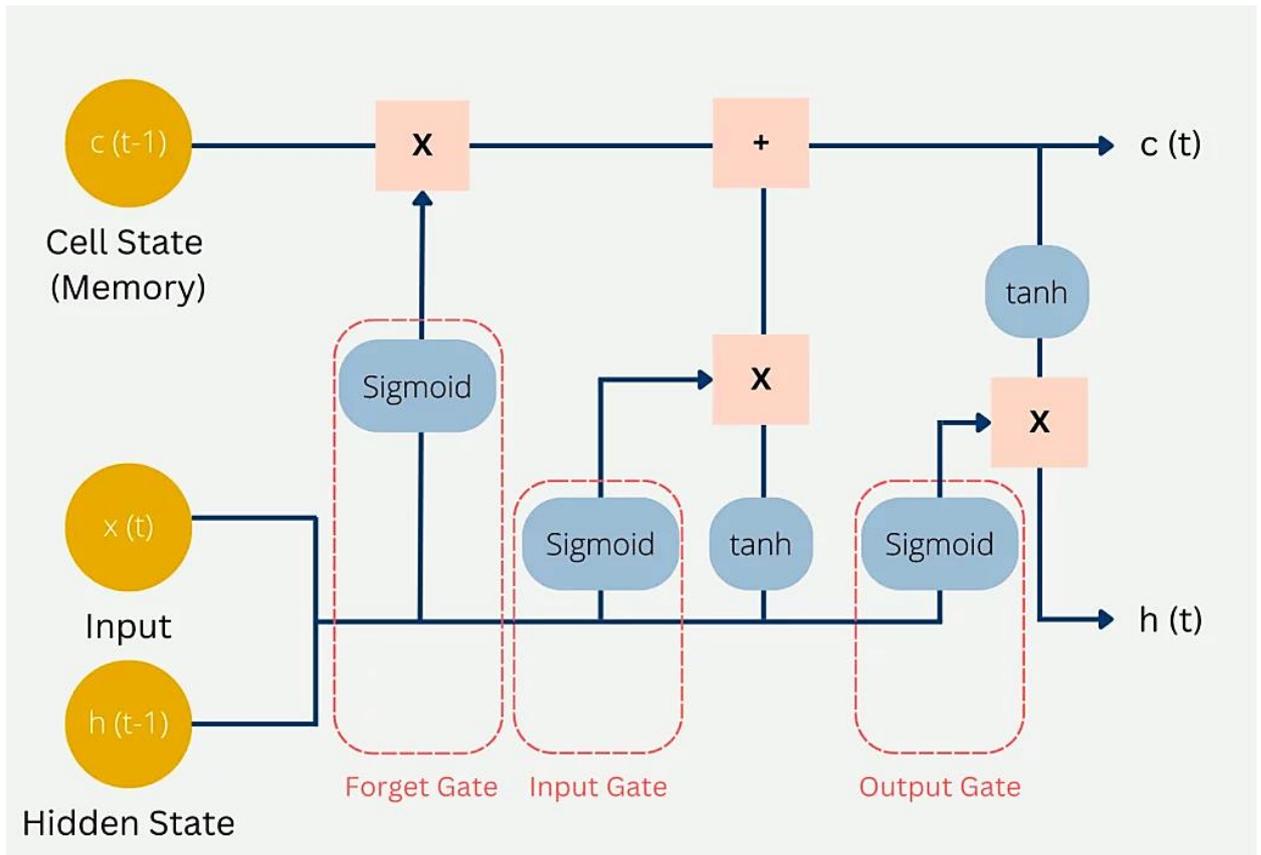
**Les portes** - Le LSTM possède trois portes : la porte d'entrée, la porte de sortie et la porte d'oubli. Ces portes sont responsables de contrôler le flux d'informations dans et hors de l'état de la cellule.

## **II.4.3. Fonctionnement du LSTM**

Une explication étape par étape du fonctionnement du LSTM [21]:

- a. Porte d'Entrée :** La porte d'entrée détermine quelles sont les nouvelles informations ajoutées à l'état de la cellule. Elle le fait en multipliant le vecteur d'entrée avec la sortie de la couche sigmoïde.
- b. Mise à jour de l'État de la Cellule :** L'état de la cellule est mis à jour en ajoutant les nouvelles informations de la porte d'entrée à l'état de la cellule précédente.
- c. Porte d'Oubli :** La porte d'oubli détermine quelles informations oublier de l'état de la cellule. Elle le fait en multipliant l'état de la cellule avec la sortie de la couche sigmoïde.
- d. Porte de Sortie :** La porte de sortie détermine quelles informations sortir de l'état de la cellule. Elle le fait en multipliant l'état de la cellule avec la sortie de la couche sigmoïde.
- e. Sortie :** La sortie du LSTM est la sortie de la porte de sortie.

Figure II. 4. Architecture et fonctionnement de LSTM [22]



#### II.4.4. Avantages et inconvénients du LSTM

##### Avantages

Parmi les avantages des réseaux de neurones LSTM il y a [20] :

- Les dépendances à long terme qui peuvent être capturées par les réseaux LSTM. Ils disposent d'une cellule mémoire capable de stocker des informations à long terme.
- Dans les RNN traditionnels, il existe un problème de disparition et d'explosion des gradients lorsque les modèles sont entraînés sur de longues séquences. En utilisant un mécanisme de contrôle qui rappelle ou oublie sélectivement des informations, les réseaux LSTM résolvent ce problème.
- LSTM permet au modèle de capturer et de mémoriser le contexte important, même lorsqu'il existe un intervalle de temps important entre les événements pertinents de la séquence. Ainsi, là où la compréhension du contexte est importante, les LSTMs sont utilisés, par exemple dans la traduction automatique.

##### Inconvénients du LSTM

Malgré les avantages importants des LSTM, il y a aussi plusieurs inconvénients [20]. Parmi ceux-ci, on cite :

- Comparés à des architectures plus simples telles que les réseaux de neurones à action directe, les réseaux LSTM sont plus coûteux en termes de calcul. Cela peut limiter leur évolutivité pour des ensembles de données à grande échelle ou des environnements contraints.
- La formation des réseaux LSTM peut prendre plus de temps que celle des modèles plus simples en raison de leur complexité informatique. Ainsi, la formation des LSTM nécessite souvent plus de données et des temps de formation plus longs pour atteindre des performances élevées.
- Puisqu'il est traité mot par mot de manière séquentielle, il est difficile de paralléliser le travail de traitement des phrases.

### **II.4.5. Applications des réseaux LSTM**

Les réseaux LSTM sont des outils puissants dans le domaine de l'intelligence artificielle, utilisés pour une variété de tâches complexes. En résumé, ils sont essentiels pour [20]:

- **Modélisation du langage** : Créer des textes cohérents et traduire des langues en apprenant les relations entre les mots.
- **Reconnaissance vocale** : Transcrire la parole et reconnaître des commandes vocales en identifiant des motifs dans le langage parlé.
- **Prévisions de séries temporelles** : Prédire des tendances futures dans des données temporelles comme les marchés financiers, la météo ou la consommation d'énergie.
- **Détection d'anomalies** : Identifier des comportements atypiques ou des activités suspectes pour la détection de fraudes ou de cyberattaques.
- **Systèmes de recommandation** : Analyser les habitudes des utilisateurs pour offrir des recommandations personnalisées.
- **Analyse vidéo** : Reconnaître des objets et des activités en combinant les LSTM avec d'autres architectures neuronales comme les CNN.

## **II.5. Conclusion**

Nous avons couvert tout ce qu'est l'apprentissage profond, certaines des bases de l'apprentissage profond, son fonctionnement et ses applications. Nous avons également appris comment fonctionnent les réseaux de neurones profonds et les différents types de modèles d'apprentissage profond. Enfin, nous discuterons du modèle que nous avons utilisé pour notre application de détection du stress.

Dans le chapitre suivant, nous aborderons les étapes de conception de notre système de détection du stress.

# *Chapitre III : Conception du système*

### III.1. Introduction

Les modèles de Deep Learning, tels que les réseaux neuronaux profonds, sont capables d'analyser parfaitement de grandes quantités de données textuelles et de comportements en ligne. Donc, l'objectif principal de ce travail est d'explorer les meilleures méthodes des réseaux neuronaux de DL pour concevoir un système capable d'analyser le contenu des réseaux sociaux, en particulier les publications des utilisateurs, afin de détecter les signes de stress. Ce qui permet d'identifier précocement les problèmes de santé mentale chez les utilisateurs des médias sociaux et faire une intervention rapide et une meilleure prise en charge des individus en situation de stress.

Dans ce chapitre, nous présenterons une vue d'ensemble de notre système en mettant en avant ses aspects conceptuels et méthodologiques. Ensuite, nous examinerons en détail chaque étape du projet en identifiant les principaux algorithmes et techniques employées.

### III.2. Classification du texte

En premier temps, avant d'entrer et d'approfondir dans les détails de la conception du projet, il est essentiel de mettre en lumière un point très important qui est la classification du texte. C'est une tâche fondamentale en apprentissage profond qui consiste à assigner des catégories ou des étiquettes à des documents textuels en fonction de leur contenu. Afin d'accomplir cela, différentes techniques d'apprentissage automatique sont utilisées pour former des modèles capables de repérer les caractéristiques des textes et de les lier à des catégories précises.

Les méthodes d'apprentissage pour la classification de texte consistent à entraîner des modèles sur un ensemble de données textuelles étiquetées, où chaque texte est lié à une catégorie prédéfinie. On utilise fréquemment des algorithmes d'apprentissage supervisé comme les réseaux neuronaux. Cependant la plupart de ces méthodes contiennent les tâches suivantes :

- a. Prétraitement du Texte** - avant la classification, le texte subit un prétraitement pour nettoyer les données, les tokenizer, les normaliser et les transformer en vecteurs numériques, afin de les adapter aux algorithmes d'apprentissage automatique. La vectorisation du texte consiste à représenter les mots ou les phrases sous forme de vecteurs numériques, ce qui permet aux modèles d'apprentissage automatique de traiter efficacement et d'analyser le texte.

**b. Entraînement du modèle** - les modèles sont entraînés sur des ensembles de données textuelles annotées, où les caractéristiques du texte sont associées aux catégories correspondantes. Les modèles apprennent à reconnaître les schémas et les relations entre les mots pour effectuer une classification précise.

**c. Évaluation des Modèles** - une fois entraînés, les modèles sont évalués sur des ensembles de données de test pour mesurer leur performance en termes de précision, de rappel, de F1-score. Ces mesures jouent un rôle crucial dans l'évaluation des performances des modèles de classification. Voici une explication de chacun : [23, 24]

- **Précision** : c'est l'écart entre les prédictions positives correctes et toutes les prédictions positives. La formule illustre la capacité du modèle à détecter de manière adéquate les exemples positifs :

$$\text{Précision} = \text{True Positives} / (\text{True Positives} + \text{False Positives})$$

$$\text{Précision} = TP/TP+FP$$

- **Le rappel** – c'est la part des prédictions positives qui sont correctes par rapport à toutes les instances positives réelles. La formule permet de représenter la capacité du modèle à trouver tous les exemples positifs :

$$\text{Recall} = \text{True Positives} / (\text{True Positives} + \text{False Negatives})$$

$$\text{Ou: Rappel} = TP/TP+FN$$

- **Le F1 Score** - la mesure harmonieuse de la précision et du rappel, appelée F1 Score, permet de donner une valeur unique qui combine les deux métriques, et peut être représentée par la formule :

$$\text{F1-Score} = 2 * (\text{Précision} * \text{Rappel}) / (\text{Précision} + \text{Rappel})$$

$$\text{Ou: F1-Score} = 2 * P * R / P + R$$

- **La matrice de confusion** - elle est utilisée pour visualiser la performance d'un modèle de classification. Le tableau suivant illustre le nombre de vrais positifs, de vrais négatifs, de faux positifs et de faux négatifs.

**Tableau III. 1.** Les différentes catégories pour une matrice de confusion

	<b>Class Positive (Réelle)</b>	<b>Class Négative (Réelle)</b>
<b>Class Positive (Prédit)</b>	True Positives (TP)	False Positives (FP)
<b>Class Négative (Prédit)</b>	False Negative (FN)	True négative (TN)

- **La courbe ROC** – elle est utilisée pour évaluer la performance d'un modèle de classification binaire en comparant le pourcentage de vrais positifs avec le pourcentage de faux positifs pour différents seuils de classification. On peut la représenter par cette formule :

$$TPR (True Positive Rate) = TP/TP+FN$$

$$FPR (False Positive Rate) = FP/TN+FP$$

### III.3. Architecture générale du système

Le système à développer utilise l'apprentissage profond pour détecter les signes de stress. Le système prend en entrée une base de commentaires brute ainsi que leurs caractéristiques. Ensuite, cette base de données brutes sera transformée à une base de données pratique pour la phase d'apprentissage. Cette transformation est appelée prétraitement, elle effectue différentes tâches telles que le nettoyage, le filtrage, l'encodage.

La base de données prétraitées est divisée en deux parties. L'une est destinée à l'entraînement et l'autre au test. La base d'entraînement et un algorithme d'apprentissage sont utilisés dans le module d'entraînement pour créer un modèle de décision, lequel est ensuite appliqué sur la base de test. Dans la phase de test, si le modèle atteint un taux de reconnaissance satisfaisant, il est validé pour une utilisation ultérieure, sinon les paramètres de l'algorithme d'apprentissage sont ajustés pour améliorer la performance du modèle.

La figure ci-dessous illustre le processus complet de notre système :

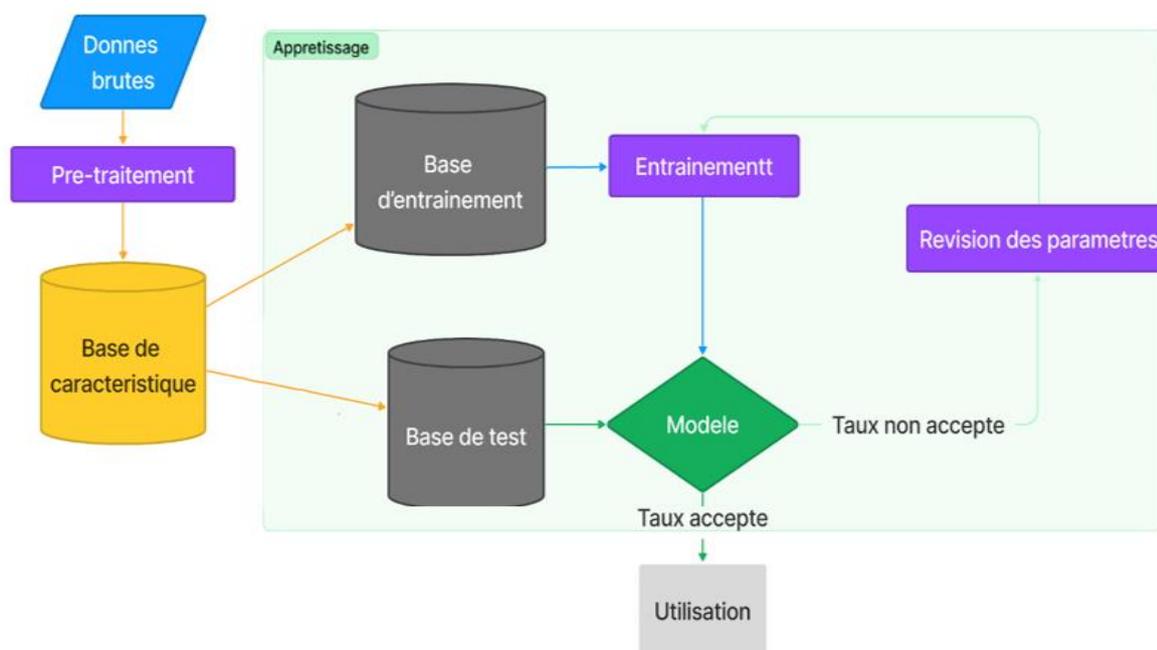


Figure III. 1. Architecture générale du système

### III.4. Architecture détaillée du système

D'abord et avant de commencer la description détaillée des étapes de ce système, il est essentiel de souligner l'étape d'acquisition des données. Nous avons utilisé une base de données de la plateforme Kaggle [25] pour entraîner notre modèle de détection de stress, qui propose différents ensembles de données liés aux réseaux sociaux et aux comportements des utilisateurs. Ces données comprennent des publications textuelles, des informations métadonnées sur les utilisateurs et des commentaires sur les niveaux de stress.

Dans ce qui suit, nous exposons en détail chaque étape de ce système.

#### III.4.1. Prétraitement de données

Le prétraitement des données joue un rôle important dans la classification du texte, il vise à éliminer tout bruit présent dans le texte analysé tel que les mots superflus, les redondances, les chiffres, les préfixes et les suffixes, etc. Un prétraitement efficace des données peut significativement améliorer les performances de classification. Les principales étapes du prétraitement sont [26] :

- a. **Enlever les espaces supplémentaires** - une fonction qui permet de retirer tous les espaces en surplus ou inutiles dans un texte.

- b. Nettoyage des caractères spéciaux** - une fonction visant à éliminer tous les caractères spéciaux tels que la ponctuation, les parenthèses, les guillemets, les tirets, les points d'interrogation, etc., pour simplifier le texte et le rendre plus lisible.
- c. Conversion des chiffres en lettres** - une fonction permettant de remplacer tous les chiffres présents dans le texte par leur équivalent en lettres, facilitant ainsi la compréhension du contenu.
- d. Élimination des URL** - une fonction conçue pour supprimer tous les liens URL présents dans le texte, éliminant ainsi les références externes et les hyperliens.
- e. Élimination des hashtags** - une fonction destinée à supprimer tous les hashtags présents dans le texte, souvent précédés du symbole "#", utilisés pour identifier des sujets spécifiques, afin de simplifier l'analyse du contenu.
- f. Suppression des Emojis** - une fonction qui permet de retirer tous les émojis présents dans le texte, utilisés pour exprimer des émotions ou des sentiments, afin de se concentrer sur le texte brut et son analyse.
- g. Suppression des ponctuations** - une fonction qui supprime tous les signes de ponctuation d'une chaîne de caractères, tels que les virgules, les points, les points-virgules, les points d'exclamation, etc.
- h. Tokenization (segmentation)** - une fonction qui découpe une chaîne de caractères en mots individuels, ou "tokens", afin de faciliter leur traitement et leur analyse. Cette fonction peut prendre en compte différents critères pour déterminer les limites entre les mots, tels que les espaces, les signes de ponctuation, les caractères spéciaux, etc.

### III.4.2. Apprentissage du système

Le processus d'apprentissage se compose de deux modules principaux, à savoir, l'entraînement et l'évaluation. Ces modules utilisent chacun une partie distincte de la base de caractéristiques, divisée en deux sections qui sont la base d'entraînement et la base de test.

#### Module d'entraînement

Ce module utilise la base d'entraînement pour créer un modèle de décision. L'algorithme d'apprentissage analyse les données d'entraînement, apprend les caractéristiques pertinentes et génère un modèle capable de détecter les signes de stress.

Dans le système de classification développé, un réseau neurone récurrent LSTM est utilisé pour effectuer une classification de texte sur un ensemble de données. Les étapes détaillées de ce processus sont :

- a. **Imputation moyenne** : pour gérer les valeurs manquantes dans notre ensemble de données, nous avons utilisé l'imputation moyenne.
- b. **Tokenisation des commentaires** : les commentaires stockés dans la colonne « new-comments » ont été tokenisés pour convertir le texte en séquences entières.
- c. **Padding des séquences** : les séquences ont été complétées (padding) pour garantir une longueur uniforme, avec une longueur de séquence maximale de 2 000 tokens.

L'ensemble de données est divisé en ensemble d'entraînement et de tests, en utilisant un rapport de répartition de 80-20.

Le modèle LSTM a été défini avec une architecture séquentielle composée des couches suivantes [27] :

- a. **Embedding Layer** - cette couche convertit les indices de mots en vecteurs denses de taille 100.
- b. **LSTM Layer** - cette couche contient 128 unités pour capturer les dépendances temporelles dans les séquences de texte.
- c. **Dense Layer** - une couche dense avec 64 unités utilisant la fonction d'activation ReLU pour introduire la non-linéarité.
- d. **Output Dense Layer** - une couche de sortie avec un seul neurone utilisant la fonction d'activation sigmoïde pour la classification binaire.

### Module d'évaluation

Une fois le modèle de décision généré, il est évalué à l'aide de la base de test. Ce module applique le modèle aux données de test pour mesurer sa performance et sa capacité à généraliser. Les résultats de cette évaluation déterminent si le modèle est suffisamment précis pour être utilisé.

## Révision des paramètres

Cette opération vise à améliorer le modèle en ajustant les paramètres de l'algorithme d'apprentissage profond. Les techniques couramment utilisées incluent l'ajustement des hyperparamètres et l'ajustement des méthodes de validation.

- a. Ajustement des hyperparamètres** - cette étape consiste à affiner les hyperparamètres du modèle de Deep Learning, tels que le taux d'apprentissage, la taille des batchs, le nombre de couches, et le nombre de neurones par couche. L'objectif est de trouver la configuration optimale qui maximise la performance du modèle.
- b. Modification des méthodes de validation** - pour évaluer et améliorer la robustesse du modèle, différentes techniques de validation croisée peuvent être utilisées. Par exemple, la validation croisée k-folds peut être ajustée en modifiant la valeur de k. D'autres méthodes comme la validation croisée stratifiée peuvent également être explorées pour garantir une évaluation plus fiable. Les hyperparamètres les plus importants dans les modèles d'apprentissage profond incluent :
  - **Taux d'apprentissage** : contrôle la vitesse à laquelle le modèle ajuste ses poids pendant l'entraînement.
  - **Nombre d'époques** : détermine combien de fois le modèle passera sur l'ensemble des données d'entraînement.
  - **Taille des batchs** : indique le nombre d'échantillons (samples) que le modèle voit avant de mettre à jour les poids.
  - **Architecture du réseau** : inclut la profondeur (nombre de couches) et la largeur (nombre de neurones par couche) du réseau.

### III.4.3. Utilisation du système

Il s'agit de la phase finale du système développé, après avoir obtenu le taux de reconnaissance le plus élevé et élaboré le modèle optimal lors des phases précédentes. Ce modèle peut être appliqué à de nouvelles données non étiquetées. Ces nouvelles informations passent par le même processus de prétraitement que les données d'entraînement, afin d'extraire les caractéristiques nécessaires. Le modèle de classification obtenu offre la possibilité de prédire la classe des nouvelles informations, indiquant si elles sont fausses ou vraies, avec une certaine marge de confiance [28] qui reflète la certitude du modèle quant à sa prédiction, basé sur les caractéristiques des données analysées.

### **III.5. Conclusion**

Au cours de ce chapitre, nous avons exposé les objectifs et la conception de notre système pour la détection du stress via les réseaux sociaux à l'aide de techniques de deep learning. Les fonctionnalités du système sont expliquées en détail, allant de l'acquisition des données au prétraitement, en passant par le développement et l'entraînement des modèles LSTM, jusqu'aux métriques de qualité de classification qui permettent de mesurer les performances du système développé, notamment l'exactitude, la précision, le rappel et le score F1.

Dans le prochain chapitre, nous approfondirons les aspects techniques de la mise en œuvre du système développé. Ainsi que la présentation des résultats obtenus à partir des expériences, l'analyse de ces résultats et l'évaluation des performances du système.

*Chapitre IV :*  
*Implémentation et*  
*résultats*

## IV.1. Introduction

Ce chapitre se compose de deux parties. Tout d'abord, nous décrivons l'environnement de développement et les outils qui ont été utilisés pour créer le système de classification, ainsi que la liste des bibliothèques importées et la base de données utilisées dans l'apprentissage. La deuxième partie est dédiée à la présentation et à l'analyse des résultats obtenus. Nous avons également comparé le modèle développé qui est basé sur la méthode LSTM avec d'autres modèles de classification tels que SVM et Naïve baise.

## IV.2. Environnement et outils de développement

### IV.2.1. Matériels utilisés

Le tableau suivant représente les caractéristiques et les performances de matériels utilisés pour implémenter le système développé.

**Tableau IV. 1.** Caractéristiques du matériel

Caractéristiques	Poste de travail N°01
PC	Asus
Système d'exploitation	Windows 11 Professionnel
Processeur	Intel(R) Core(TM) i7-8550U CPU @ 1.80GHz 1.99 GHz
RAM	8,00 Go
Type de système	SE 64 bits

### IV.2.2. Langages, logiciels et librairies utilisés

#### a. Langage de programmation

**Python-** toute une variété de langages de programmation peut mettre en œuvre des algorithmes de l'apprentissage profond. Le plus populaire parmi ces langages est le langage Python pour sa simplicité, sa lisibilité et le grand nombre de « librairies » disponibles (des paquets de code préécrits qui facilitent la résolution des problèmes pour les développeurs). Par exemple, TensorFlow et PyTorch sont des librairies très connues et préférées pour la richesse des outils

et des fonctionnalités qu'elles offrent pour construire et entraîner des modèles d'apprentissage profond [29].

### **b. Environnement de développement**

Nous avons utilisé deux environnements de programmation pour développer ce projet :

**Visual Studio Code** - dans ce travail nous avons utilisé l'environnement Visual Studio Code (VS Code) qui est un éditeur de code source polyvalent, léger et hautement extensible, offrant une expérience de développement riche et productive pour une large gamme de projets logiciels, du développement web au cloud computing en passant par la data science.

**Notebook Jupyter** - un environnement de programmation interactif basé sur le Web qui permet aux utilisateurs de créer des documents contenant du code, du texte, des images, des graphiques et équations mathématiques. Les documents Jupyter Notebook sont créés à l'aide de cellules, où chaque cellule peut contenir du code exécutable, du texte formaté ou des images. Les utilisateurs peuvent exécuter les cellules séparément et voir immédiatement les résultats affichés dans le document. Jupyter Notebook. En plus, il prend en charge de nombreuses bibliothèques populaires pour l'analyse de données, l'apprentissage automatique, visualisation de données, etc. [30]

### **c. Librairies importées**

**Pytorch** - une librairie d'apprentissage profond open source. Elle fournit un large éventail de fonctionnalités pour créer des réseaux de neurones, notamment des modules pour créer des couches, des fonctions de perte et des optimiseurs. Elle offre un style de programmation impératif qui prend en charge le code en tant que modèle, facilite le débogage et est cohérente avec d'autres bibliothèques de calcul scientifique populaires, tout en restant efficace et en prenant en charge les accélérateurs matériels tels que les GPU (Graphics Processing Unit) [31].

**Tensorflow** - un framework d'apprentissage automatique open source développé par Google, connu pour son évolutivité et sa préparation à la production. Il propose à la fois des API de haut niveau, comme Keras, pour le prototypage rapide, ainsi que des API de niveau inférieur pour un contrôle précis de l'architecture et de la formation des modèles. [32]

**Transformers** - la bibliothèque de Hugging Face a révolutionné le langage naturel traitement (NLP) en démocratisant l'accès aux modèles de pointe tels que BERT, GPT, et T5. Avec

Transformers, les chercheurs et les praticiens peuvent facilement tirer parti des formations préformées modèles pour diverses tâches PNL telles que la classification de texte, la reconnaissance d'entités nommées et génération de langage. La bibliothèque fournit également des outils pour affiner ces modèles sur des données spécifiques au domaine, permettant le développement rapide de solutions PNL personnalisées. [33]

**Pandas** - c'est une bibliothèque fondamentale pour la manipulation et l'analyse de données en Python. Il offre des structures de données intuitives, principalement Data Frame et Séries, qui permettent une manipulation aisée des données structurées. Pandas excelle dans des tâches telles que le nettoyage, la transformation et l'exploration des données, le rendant indispensable pour le prétraitement des données avant de les intégrer dans l'apprentissage automatique des modèles. Son riche ensemble de fonctions d'indexation, de regroupement et d'agrégation simplifie les opérations de données complexes, rationalisant le flux de travail analytique. [34]

**Numpy** - Base au calcul scientifique en Python, offrant de puissants outils pour travailler avec des tableaux et des matrices multidimensionnels. Son orientation tableau les capacités informatiques facilitent les opérations numériques et mathématiques efficaces transformations, cruciales pour la mise en œuvre d'algorithmes d'apprentissage automatique. NumPy vaste collection de fonctions mathématiques, de générateurs de nombres aléatoires et de fonctions linéaires les routines d'algèbre en font une boîte à outils essentielle pour les tâches de calcul numérique à travers divers domaines. [35]

**Scikit-learn (sklearn)** - Une bibliothèque incontournable pour les tâches d'apprentissage automatique en Python, appréciée pour sa simplicité et sa facilité d'utilisation. Il fournit une API cohérente pour la mise en œuvre d'un large éventail d'algorithmes d'apprentissage supervisé et non supervisé, y compris la classification, la régression, le regroupement et la réduction de dimensionnalité. L'interface conviviale de Scikit-learn, couplée avec une documentation complète et un soutien communautaire étendu, en fait un outil idéal pour les débutants et les praticiens expérimentés de l'apprentissage automatique. [36]

**Matplotlib** - Bibliothèque pour créer des visualisations statiques, animées et interactives en Python. Il fournit un ensemble complet de fonctions de traçage pour générer une large gamme de graphiques, notamment des tracés linéaires, des graphiques à barres, des histogrammes, des nuages de points, etc. La flexibilité et les options de personnalisation de Matplotlib permettent aux utilisateurs de créer des visualisations de qualité publication adaptées à leurs besoins

spécifiques. Que vous exploriez des données lors d'une analyse exploratoire ou que vous présentiez des résultats dans un document de recherche, Matplotlib est indispensable pour une visualisation efficace des données. [37]

**Seaborn** - Une bibliothèque de visualisation de données Python basée sur matplotlib. Il fournit une interface de haut niveau pour dessiner des graphiques statistiques attrayants et informatifs. Seaborn est conçu pour faire de la visualisation la partie centrale de l'exploration et de la compréhension des données. Il s'intègre étroitement aux structures de données Pandas et s'appuie sur matplotlib pour créer une large gamme de graphiques statistiques, notamment des tracés relationnels, des tracés de distribution, des tracés catégoriels, des tracés de régression, des tracés matriciels et des grilles multi-tracés. [38]

**Nltk (Natural Language Toolkit)** - Une bibliothèque open source pour le langage de programmation Python, spécialisée dans le traitement automatique du langage naturel (NLP). Elle offre une gamme d'outils pour accomplir diverses tâches de NLP, notamment le traitement de texte brut, la tokenisation, la lemmatisation, l'analyse syntaxique et sémantique, ainsi que la classification de texte. NLTK est largement utilisée dans la recherche en NLP, l'enseignement et l'industrie pour développer des applications basées sur le traitement du langage naturel. [39]

**TQDM** - Une bibliothèque Python qui fournit une barre de progression pour les boucles et les intégrables. Il est conçu pour faciliter l'ajout d'un indicateur de progression à n'importe quelle boucle ou intégrable, avec une surcharge minimale et une API simple. [40]

### **IV.3. Base de données utilisées**

#### **IV.3.1. Informations générales sur l'ensemble des données**

L'exploration des ensembles de données est une tâche essentielle pour comprendre leur structure et leurs caractéristiques avant de les utiliser pour entraîner des modèles.

Cette partie présente une analyse des ensembles de données obtenus de Reddit et Twitter, en se concentrant sur les titres, le corps des articles et les étiquettes.

Les caractéristiques sont présentées dans le tableau ci-dessous :

**Tableau IV. 2.**Caractéristiques de l'ensemble de données

Aspect analysé	Type	Description
Nombre total d'article	Entree	Nombre total d'article ou nombre total d'entrées de texte individuel (commentaires)
Valeurs uniques (label)	Liste des valeurs	Les valeurs uniques présentes chaque ensemble de données. Dans notre cas les valeurs peuvent être 0 pour Non stress et 1 pour stress
Distribution des classes	Pourcentage	La répartition des classes dans chaque ensemble de données
Longueur moyenne des textes	Variables	La longueur moyenne des textes dans chaque ensemble de données
Mots les plus fréquents	String liste des mots	Les mots les plus fréquents rencontrés dans chaque ensemble de données. Cette information peut donner un aperçu sur le thème

### IV.3.2. Distribution générale de classes

L'analyse de la distribution des étiquettes dans l'ensemble de données de Twitter et Reddit affiche un déséquilibre notable entre les classes positives et négatives.

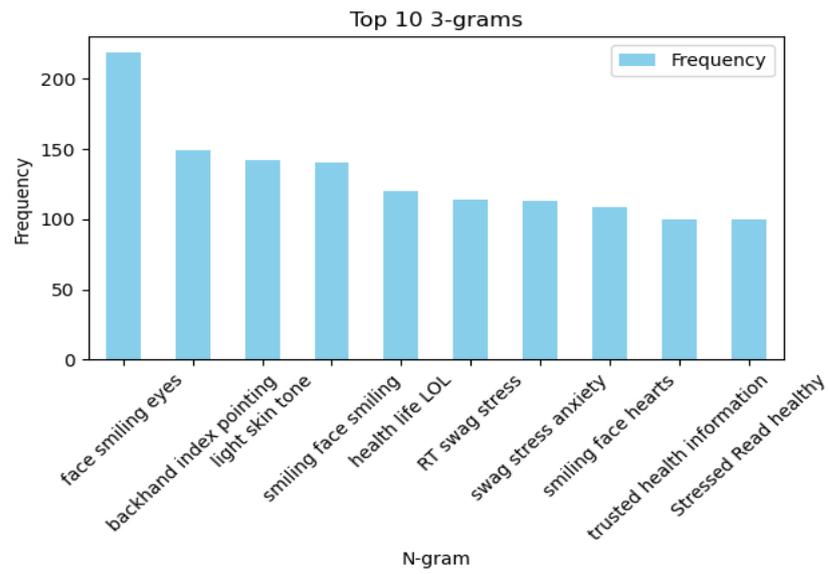
Dans la base de données de Twitter, il y avait 1207 exemples positifs et 760 exemples négatifs. Pour Reddit, il y avait 2736 exemples positifs et 374 exemples négatifs.

Pour équilibrer les données, nous avons concaténé les classes négatives des deux plateformes, résultant en une distribution équilibrée avec 1207 exemples positifs et 1134 exemples négatifs dans la base de données combiné.

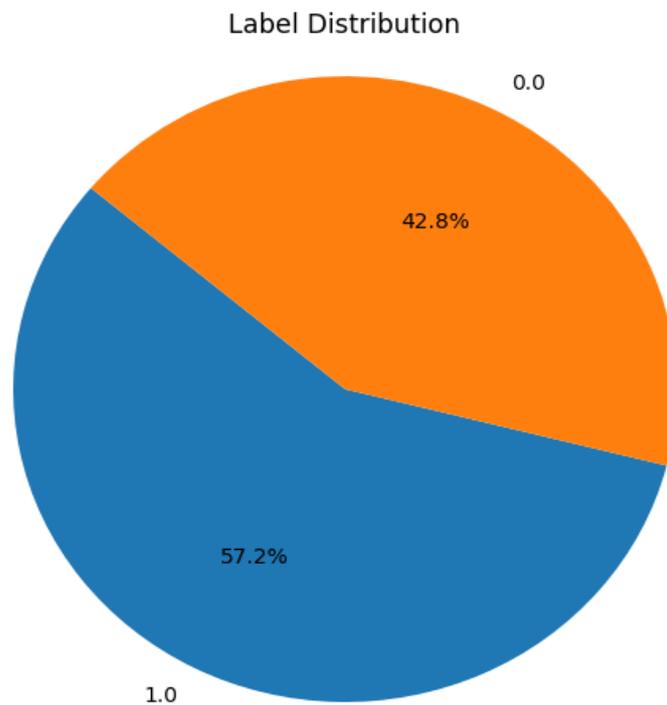
L'ensemble de données comprend 2341 commentaires, chacun étant étiqueté comme étant soit Stress Positif (1) soit Stress Négatif (0). Cette répartition est présentée dans les tableaux :



La figure suivante représente des séquences de n mots consécutifs (n-grams).



La figure suivante représente la distribution des classes. (Stress/Non Stres)



**Figure IV. 2.** Distribution des classes

## IV.4. Préparation de données pour la classification

### IV.4.1. Les méthodes de base

#### Sélection du modèle et prétraitement

Dans le but de la préparation d'un jeu de données pour la classification, nous avons suivi une série d'étapes détaillées :

**Prétraitement des textes** - Nous avons débuté le processus en prétraitant les textes, en supprimant les caractères spéciaux, les chiffres et la ponctuation, tout en convertissant l'intégralité des textes en minuscules pour garantir une uniformité. Nous avons également éliminé les mots vides (stop Word) et les termes peu fréquents qui n'apportent pas de valeur à la classification. Ensuite, les textes ont été divisés en mots individuels via la tokenisation, pour la vectorisation des données, nous avons utilisé la méthode TF-IDF afin d'évaluer l'importance de chaque terme dans chaque document par rapport à l'ensemble du corpus. Cela nous a permis de transformer chaque texte en un vecteur de caractéristiques TF-IDF, où chaque valeur représente le score TF-IDF d'un terme spécifique dans ce document.

**Tableau IV. 5.**Exemple de prétraitement de texte.

Texte brute	Texte prétraité
"I'm so stressed about my exams."	stressed exams
"What a beautiful sunny day today!"	beautiful sunny day today
"I feel overwhelmed by all my responsibilities."	feel overwhelmed responsibilities
"Just had a great time with friends."	great time friends
"My boss is very demanding, it stresses me out."	boss demanding stresses

**Entraînement et Évaluation** - Après avoir prétraité et vectorisé les données, nous les avons séparées en deux ensembles d'entraînement et de tests selon une répartition 80-20. Les performances des modèles sont évaluées en utilisant des métriques telles que la précision, le rappel, le F1-score et l'accuracy, en se basant sur les prédictions faites sur l'ensemble de test. Des métriques supplémentaires telles que les courbes Precision-Recall, ROC et les matrices de

confusion peuvent également être utilisées pour évaluer les modèles de manière plus approfondie.

#### **IV.4.2. Apprentissage profond**

**Architecture du modèle et prétraitement :** pour l'approche d'apprentissage en profondeur, nous avons implémenté un modèle de mémoire à long terme (LSTM) à l'aide de TensorFlow. Ce modèle visait à exploiter les capacités de traitement séquentiel des données pour classer le sentiment des commentaires textuels (stress). Nous avons commencé par charger l'ensemble de données et mapper les étiquettes sur des nombres entiers, en gérant les valeurs manquantes à l'aide de l'imputation moyenne. Les données texte ont été tokenisées à l'aide du Tokenizer du module de prétraitement Keras de Tensor Flow, et les séquences ont été complétées pour garantir une longueur uniforme. Les données ont été divisées en ensembles de formation et de test avec une répartition 80-20.

**Conception du modèle :** L'architecture du modèle LSTM comprend une couche d'intégration avec une dimension d'entrée correspondant à la taille du vocabulaire et une dimension de sortie de 100. Elle a été suivie par une couche LSTM avec 128 unités pour capturer les dépendances à long terme, une couche dense avec 64 unités et l'activation ReLU, et une couche dense finale avec un seul neurone et une activation sigmoïde pour la classification binaire.

**Entraînement :** Le modèle a été compilé à l'aide de l'optimiseur Adam et de la fonction de perte d'entropie croisée binaire. La formation a été menée sur 6 époques avec une taille de lot (batch-size) de 8 pour minimiser la fonction de perte.

**Évaluation :** Nous avons évalué les performances du modèle LSTM sur l'ensemble de test en utilisant des métriques standard, comme la précision, le rappel, le F1-score et l'exactitude (accuracy), ainsi que des techniques de visualisation pour une évaluation approfondie de sa performance.

## IV.5. Résultats et comparaison

### IV.5.1. Résultats obtenus

#### a. Méthodes de base

Tableau IV. 6. Les résultats de performance des méthodes de base

Métriques d'évaluation	Négative (0)			Positive (1)			Accuracy
	Précision	Recall	F1-score	Précision	Recall	F1-score	
Naïve baise	0.84	0.74	0.78	0.78	0.87	0.82	0.81
Svm	0.87	0.74	0.80	0.80	0.90	0.85	0.83
Régression logistique	0.90	0.73	0.80	0.79	0.93	0.85	0.83
Decision Tree	0.80	0.71	0.75	0.76	0.83	0.80	0.78
Random Forest	0.90	0.72	0.80	0.78	0.93	0.85	0.83

#### b. Apprentissage profond

Tableau IV. 7. Les résultats de performance de modèle LSTM.

	Négative (0)			Positive (1)			Accuracy
	Précision	Recall	F1-score	Précision	Recall	F1-score	
LSTM	0.94	0.62	0.75	0.74	0.96	0.83	0.80

## IV.6. Discussion des résultats

### IV.6.1. Évaluation des différents Classificateurs

Les résultats de la classification en utilisant de différentes méthodes sur le jeu de données montrent les performances variées en termes de précision, rappel et F1-score. Voici une analyse des résultats obtenus par chaque modèle utilisant la vectorisation TF-IDF :

**a. Naïve Bayes**

- Précision : 0.84 pour la classe 0, 0.78 pour la classe 1
- Rappel : 0.74 pour la classe 0, 0.87 pour la classe 1
- F1-score : 0.78 pour la classe 0, 0.82 pour la classe 1
- Exactitude (Accuracy) : 0.81

Le modèle Naïve Bayes montre une bonne performance générale avec une exactitude de 81%. Cependant, il a tendance à mieux détecter les articles de la classe 1 (Stress Positive) avec un rappel de 0.87 par rapport à la classe 0 (Stress Négatif) avec un rappel de 0.74.

**b. SVM**

- Précision : 0.87 pour la classe 0, 0.80 pour la classe 1
- Rappel : 0.74 pour la classe 0, 0.90 pour la classe 1
- F1-score : 0.80 pour la classe 0, 0.85 pour la classe 1
- Exactitude (Accuracy) : 0.83

Le SVM offre une précision élevée pour les deux classes, avec une meilleure performance pour la classe 1 en termes de rappel (0.90). Cela indique que le SVM est efficace pour détecter les articles qui contiennent le Stress (positive), bien qu'il ait une performance légèrement moindre pour les articles ne contenant pas Stress (Négatif) en termes de rappel.

**c. Régression logistique**

- Précision : 0.90 pour la classe 0, 0.79 pour la classe 1
- Rappel : 0.73 pour la classe 0, 0.93 pour la classe 1
- F1-score : 0.80 pour la classe 0, 0.85 pour la classe 1
- Exactitude (Accuracy) : 0.83

La régression logistique présente des résultats similaires à ceux du SVM, avec une excellente précision pour la classe 0. Le modèle est particulièrement performant pour la détection des articles Stress Positive, comme le montre le rappel élevé de 0.93.

**d. Arbre de Décision**

- Précision : 0.80 pour la classe 0, 0.76 pour la classe 1
- Rappel : 0.71 pour la classe 0, 0.83 pour la classe 1
- F1-score : 0.75 pour la classe 0, 0.80 pour la classe 1
- Exactitude (Accuracy) : 0.78

L'arbre de décision montre une performance acceptable, mais inférieure aux autres modèles. Il présente une précision et un rappel plus bas, ce qui se traduit par une F1-score moins élevée et une exactitude de 78%.

#### e. Forêt Aléatoire

- Précision : 0.90 pour la classe 0, 0.78 pour la classe 1
- Rappel : 0.72 pour la classe 0, 0.93 pour la classe 1
- F1-score : 0.80 pour la classe 0, 0.85 pour la classe 1
- Exactitude (Accuracy) : 0.83

Le modèle de forêt aléatoire montre des résultats très similaires à ceux de la régression logistique, avec une excellente performance pour la détection des articles Stress Positive, comme l'indique le rappel de 0.93. La précision pour la classe 0 est également élevée.

En résumé les modèles SVM, régression logistique, et forêt aléatoire offrent les meilleures performances en termes d'exactitude (accuracy) et de F1-score, particulièrement pour la classe 1 (Stress Positive). Le Naïve Bayes et l'arbre de décision ont des performances légèrement inférieures. Les modèles de régression logistique et de forêt aléatoire se distinguent par leur capacité à bien détecter les articles de stress positif avec un rappel très élevé. Ces résultats suggèrent que les méthodes basées sur TF-IDF combinées avec des modèles robustes comme le SVM et la régression logistique sont efficaces pour la classification du stress sur les réseaux sociaux.

### IV.6.1.1. Courbes ROC et PRC des différents Classificateurs

#### a. Courbe ROC

La courbe ROC montre notre capacité à distinguer entre les classes en traçant le taux de vrais positifs (True Positive Rate) contre le taux de faux positifs (False Positive Rate) à différents seuils de classification. Plus la courbe ROC est proche du coin supérieur gauche, la performance du modèle est meilleure.

- **Naïve Bayes (ROC AUC = 0.88)** - le modèle Naïve Bayes montre une bonne capacité de discrimination avec une courbe qui se rapproche du coin supérieur gauche.

- **SVM (ROC AUC = 0.90)** - le modèle SVM offre une excellente performance avec une courbe ROC très proche du coin supérieur gauche, indiquant un bon taux de vrais positifs et un faible taux de faux positifs.
- **Logistic Regression (ROC AUC = 0.91)** - la régression logistique a la meilleure performance parmi les modèles présentés, avec une courbe ROC presque parfaite.
- **Decision Tree (ROC AUC = 0.77)** - le modèle arbre de décision montre une performance inférieure, avec une courbe moins proche du coin supérieur gauche, indiquant une discrimination moins efficace.
- **Random Forest (ROC AUC = 0.89)** - la forêt aléatoire offre une très bonne performance, avec une courbe ROC similaire à celle du SVM.

#### b. Courbe PRC

La courbe PRC est particulièrement utile pour évaluer nos modèles sur des ensembles de données déséquilibrés. Elle trace la précision (Precision) contre le rappel (Recall) à différents seuils de classification. Une courbe PRC plus élevée indique un meilleur équilibre entre précision et rappel.

- **Naïve Bayes** - Le modèle naïve bayes a une courbe PRC relativement élevée, ce qui montre un bon équilibre entre précision et rappel.
- **SVM** - Le SVM présente une courbe PRC élevée, indiquant une excellente performance en termes de précision et de rappel.
- **Logistic Regression** - la régression logistique a la meilleure courbe PRC parmi tous les modèles, confirmant sa capacité à maintenir un bon équilibre entre précision et rappel.
- **Decision Tree** - l'arbre de décision a une courbe PRC inférieure, ce qui reflète ses performances plus faibles en termes de précision et de rappel.
- **Random Forest** - la forêt aléatoire montre une courbe PRC élevée, indiquant une très bonne performance en termes de précision et de rappel.

En conséquence, les courbes ROC et PRC montrent que les modèles de Régression logistique et SVM sont les plus performants pour la détection du stress sur les réseaux sociaux, suivis de près par la forêt Aléatoire. Nous trouvons que le Naïve Bayes offre également de bonnes performances, bien qu'il soit légèrement en retrait par rapport aux trois premiers. L'Arbre de Décision, bien qu'utile, est le moins performant des modèles testés dans notre étude. Ces analyses confirment l'importance d'utiliser des mesures variées pour évaluer la performance des modèles de classification.

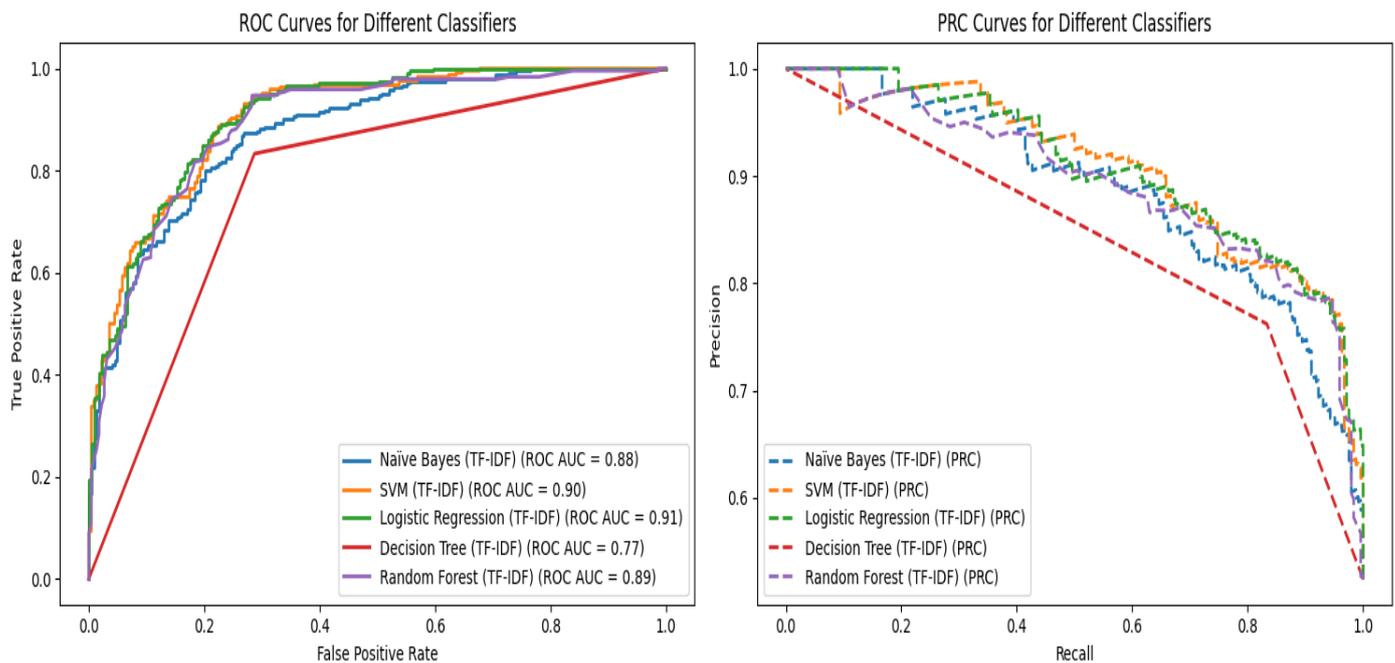


Figure IV. 3. Courbe ROC (gauche) et courbe PRC (droite) des méthodes de base.

La Figure suivante présente la matrice de confusion du modèle SVM, la méthode la plus performante dans l'approche de classification de base :

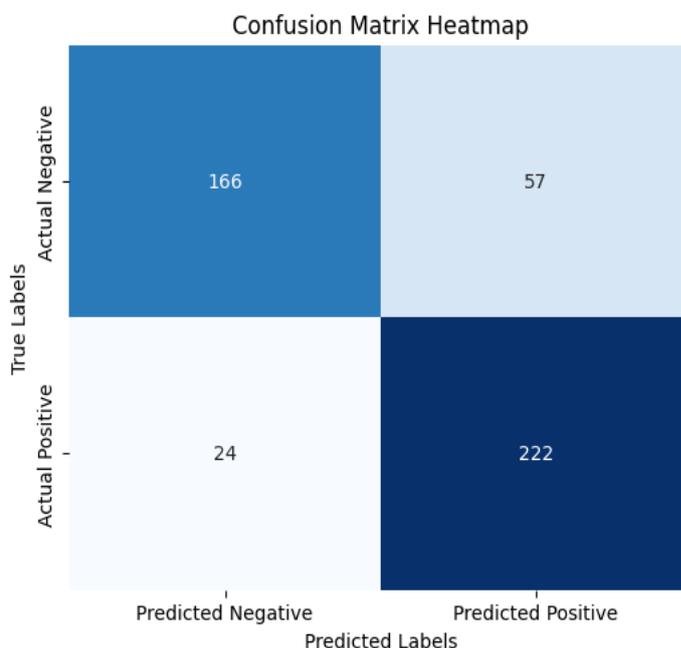


Figure IV. 4. Matrice de confusion du SVM

### IV.6.2. Évaluation du modèle LSTM

Les résultats d'évaluations du LSTM sont comme suit :

- Précision : 0.94 pour la classe 0, 0.74 pour la classe 1
- Rappel : 0.62 pour la classe 0, 0.96 pour la classe 1
- F1-Score : 0.75 pour la classe 0, 0.83 pour la classe 1
- Exactitude (Accuracy) : 0.80

**Précision et Rappel** - le LSTM montre une précision très élevée pour la classe 0 (0.94), indiquant une capacité à prédire correctement les instances de cette classe. Pour la classe 1, le modèle affiche un rappel exceptionnel (0.96), montrant sa capacité à identifier la grande majorité des instances de cette classe. Cependant, le rappel pour la classe 0 est relativement plus faible (0.62), ce qui signifie qu'il peut manquer un nombre significatif d'instances de cette classe.

**F1-Score** - le modèle LSTM offre un bon équilibre global entre précision et rappel, avec des F1-Scores de 0.75 pour la classe 0 et de 0.83 pour la classe 1.

**Exactitude (accuracy)** -l'exactitude globale du LSTM est de 0.80, qui est comparable aux meilleurs résultats de modèles précédents.

En conséquence, la régression logistique, le SVM et la forêt aléatoire offrent des performances solides lorsqu'ils sont combinés avec la vectorisation TF-IDF. Cependant, le modèle LSTM démontre également une capacité prometteuse, notamment en termes de rappel pour la classe 1, ce qui est crucial pour la détection de cas dans des contextes sensibles comme la détection de stress sur les réseaux sociaux.

Cette performance est notable, car elle est comparable à celle des meilleurs modèles TF-IDF évalués dans cette analyse. Malgré sa complexité et ses exigences en ressources, le LSTM parvient à rivaliser avec ces modèles classiques en termes de performance globale.

Ainsi, cette exactitude de 0.80 confirme la robustesse et l'efficacité du modèle LSTM dans la tâche de classification de données textuelles. Elle souligne également sa pertinence dans des applications où la précision de la classification est cruciale, telle que la détection de stress sur les réseaux sociaux. Cette précision accrue peut aider à identifier avec précision les cas de stress, contribuant ainsi à des interventions plus ciblées et efficaces.

#### **IV.6.2.1. Courbes ROC et PRC du modèle LSTM**

##### **a. Courbe ROC**

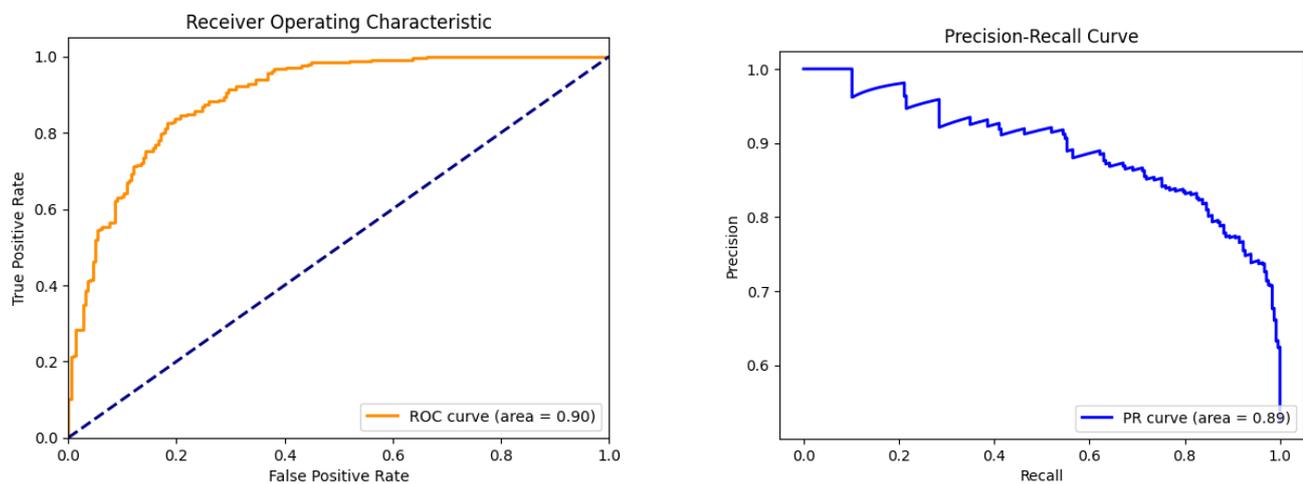
- Une valeur d'AUC-ROC de 0,90 est assez élevée, ce qui suggère que notre modèle LSTM a une capacité de discrimination solide entre les classes positives et négatives.
- Cela signifie que le modèle est capable de maintenir un bon taux de vrai positif tout en gardant le taux de faux positif relativement bas.

##### **b. Courbe PRC**

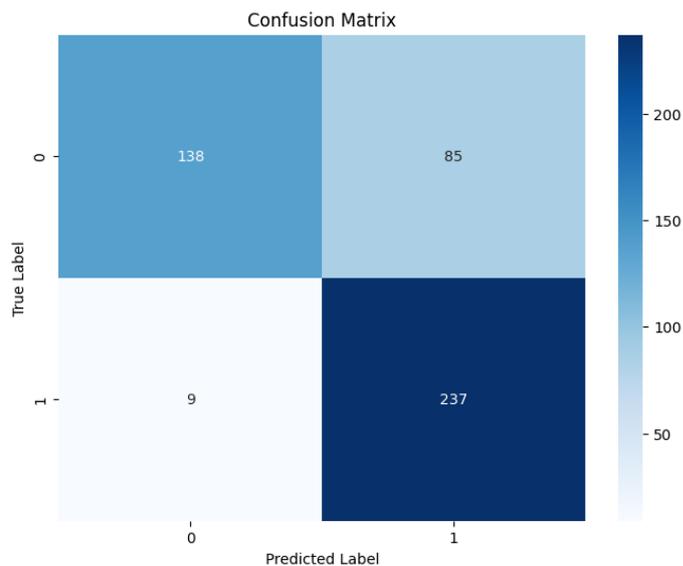
- Une valeur d'AUC-PRC de 0,89 indique également une bonne performance de notre modèle, surtout si vos classes sont déséquilibrées.
- Cela signifie que le modèle LSTM a une bonne capacité à classer correctement les exemples positifs tout en minimisant les faux positifs

Avec des valeurs élevées pour les deux métriques, nous pouvons être confiants dans la capacité de notre modèle LSTM à bien généraliser et à bien performer sur de nouveaux exemples. Cependant, il est toujours important de considérer le contexte spécifique de notre application et de vérifier si ces performances répondent à nos critères de succès spécifiques.

Bien que les valeurs d'AUC-ROC et d'AUC-PRC de 0,90 et 0,89 soient solides, il peut y avoir des possibilités d'amélioration supplémentaires. Nous pouvons explorer des techniques d'optimisation de modèle ou ajuster les hyper paramètres pour voir s'il est possible d'augmenter encore ces métriques. Nous pourrions également envisager d'examiner les points de données mal classés pour identifier les modèles d'erreur et améliorer encore la performance du modèle.



**Figure IV. 5.** Dourbes ROC ET PRC du LSTM



**Figure IV. 6.** Matrice de confusion du LSTM

En résumé, le modèle LSTM est le responsable en termes de précision et de perte pour la détection du stress sur les réseaux sociaux, surpassant les méthodes classiques telles que SVM, forêt aléatoire et Naïve Bayes. Le choix du modèle dépendra de l'importance que nous accordons à la précision et à la perte dans notre application spécifique, ainsi que de la complexité des données et des ressources disponibles pour le déploiement du modèle. Les modèles LSTM offrent une performance supérieure, mais nécessitent des ressources computationnelles plus importantes et une expertise en apprentissage profond pour une implémentation efficace.

## IV.7. Conclusion

Ce chapitre a couvert l'implémentation du système réalisé, les résultats des expériences d'utilisation du modèle principal qui est le LSTM et d'autres modèles de classification, ainsi que l'évaluation et la comparaison des performances de ces modèles qui aide à la détection de stress via les données de réseaux sociaux.

# *Conclusion générale*

## **Conclusion générale**

Dans cette étude, nous avons prouvé que l'utilisation des réseaux sociaux en collaboration avec des techniques d'apprentissage profond offre une approche prometteuse pour détecter le stress d'une manière précoce. Le modèle élaboré a démontré une grande précision dans l'identification des signes de stress à partir des données textuelles des réseaux sociaux, dépassant ainsi les méthodes traditionnelles de traitement du langage naturel et d'apprentissage automatique.

Les conclusions obtenues suggèrent que les modèles d'apprentissage profond, comme les LSTM, sont particulièrement performants pour identifier les liens temporels et contextuels présents dans les données. Toutefois, l'application de ces modèles requiert des ressources computationnelles importantes et une expertise en apprentissage profond, afin d'optimiser et d'utiliser ces modèles de manière efficace.

Au cours des prochaines études, nous suggérerons de continuer à améliorer le modèle en optimisant les hyper paramètres, en augmentant les données d'entraînement, et en explorant des techniques globales pour combiner les prédictions de différents modèles. De plus, il est possible d'étendre l'utilisation de ces techniques à d'autres secteurs de la santé mentale et à diverses plateformes de réseaux sociaux, ce qui permet d'effectuer des interventions plus précises et sur mesure afin d'améliorer le bien-être des personnes.

## Références

- [1] «L'évolution des médias sociaux et leurs usages,» [En ligne]. Available: <https://www.actifreso.fr/levolution-des-medias-sociaux-et-leurs-usages/>.
- [2] C. Hill, «Social-Networking,» 2017. [En ligne]. Available: <https://ils.unc.edu/cws/Handouts/Social%20Networking/Social-Networking.pdf>.
- [3] Livanie, «Les réseaux sociaux : définition et fonctionnement,» 2023. [En ligne]. Available: <https://blog.simplebo.fr/definition-reseaux-sociaux>.
- [4] A. B. Tzung-Pei Hong · Leticia Serrano-Estrada · Akрати Saxena, *Deep Learning for Social Media Data Analytics*, Warsaw, Poland: Polish Academy of Sciences, 2022.
- [5] «Les réseaux sociaux : les impacts de leur utilisation,» 2024. [En ligne]. Available: <https://digital.hec.ca/blog/reseaux-sociaux-impacts-medias-sociaux-html/>.
- [6] M. M. a. C.-É. N. N. Storme, «Réseaux sociaux et santé mentale en 2021, Psychiatrie,» 2021. [En ligne]. Available: <https://hal.science/hal-03911484>.
- [7] Q. L. E. C. Aryan Rastogi, «Stress Detection from Social Media Articles:New Dataset Benchmark and Analytical Study,» *International Joint Conference on Neural Networks (IJCNN)*, 2022.
- [8] S. Blog, «Sélection et suivi des indicateurs d'efficacité de votre stratégie de réseaux sociaux,» [En ligne]. Available: <https://fr.semrush.com/blog/indicateurs-efficacite-strategie-reseaux-sociaux/>.
- [9] M. M. a. C.-É. N. N. Storme, «Réseaux sociaux et santé mentale en 2021,,» 2021. [En ligne]. Available: <https://hal.science/hal-03911484>.
- [10] «The Importance of Sentiment Analysis in Healthcare,» [En ligne]. Available: <https://artera.io/blog/sentiment-analysis-in-healthcare/>.
- [11] «Deep Learning Evolution: The Complete History of AI Innovation,» [En ligne]. Available: <https://infinitesights.com/deep-learning/>.
- [12] «What is Deep Learning? A Tutorial for Beginners.,» [En ligne]. Available: <https://www.datacamp.com/tutorial/tutorial-deep-learning-tutorial>.
- [13] GeeksforGeeks, «Difference Between Artificial Intelligence vs Machine Learning vs Deep Learning,» [En ligne]. Available: <https://www.geeksforgeeks.org/difference-between-artificial-intelligence-vs-machinelearning-vs-deep-learning>.
- [14] O. Posts, «ai-vs-ml-vs-dl,» [En ligne]. Available: <https://blog.oursky.com/2020/05/07/artificial-intelligence-ai-for-businesses-what-you-needto-know-before-starting-an-ai-project/ai-vs-ml-vs-dl/>.
- [15] FasterCapital, «Apprentissage profond : la mécanique de la magie,» [En ligne]. Available: <https://www.iso.org/fr/intelligence-artificielle/apprentissage-profond-deep-learning#toc2>.
- [16] datacamp, «What is Deep Learning? A Tutorial for Beginners,» [En ligne]. Available: <https://www.datacamp.com/tutorial/tutorial-deep-learning-tutorial>.
- [17] careerera, «Exploring the Advantages and Disadvantages of Deep Learning,» 2023. [En ligne]. Available: <https://www.careerera.com/blog/advantages-and-disadvantages-of-deep-learning>.
- [18] «Activation Functions in Neural Networks,» 2017. [En ligne]. Available: <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>.
- [19] Coursera, «8 Common Types of Neural Networks,» [En ligne]. Available: <https://www.coursera.org/in/articles/types-of-neural-networks>.
- [20] GeeksforGeeks, «Deep Learning | Introduction to Long Short Term Memory,» [En ligne]. Available: <https://www.geeksforgeeks.org/deep-learningintroduction-to-long-short-term-memory/>.
- [21] A. A. Rahman, «LSTM Networks,» 2023. [En ligne]. Available: <https://www.linkedin.com/pulse/lstm-networks-abdullah-al-rahman>.
- [22] D. Basecamp, «Long Short-Term Memory Networks (LSTM)- simply explained!,» [En ligne]. Available: <https://databasecamp.de/en/ml/lstms>.
- [23] D. Raihan, «Deep Learning Techniques for Text Classification,» 2021. [En ligne]. Available: <https://towardsdatascience.com/deep-learning-techniques-for-textclassification-78d9dc40bf7c>.
- [24] F. W. X. H. Y. M. H. C. a. M. T. M. Zheng, «A Method for Analyzing the Performance Impact of Imbalanced Binary Data on Machine Learning Models,» *Statistical Methods and Applications*, 2022.
- [25] kaggle, «Datasets,» [En ligne]. Available: <https://www.kaggle.com/datasets>.

- [26] «Prétraitement des données dans le NLP (Natural Language Processing),» [En ligne]. Available: <https://fr.linkedin.com/pulse/pr%C3%A9traitement-desdonn%C3%A9es-dans-le-nlp-natural-language-flo-masdoum-bgnpe>.
- [27] A. C. S. R. a. C. K. M. Wankhade, «A survey on sentiment analysis methods, A survey on sentiment analysis methods,», 2022.
- [28] W. B. A. F. a. A. F. S. Henning, «A Survey of Methods for Addressing A Survey of Methods for Addressing,» 2023.
- [29] M. F. Sanner, «Python: a programming language for software integration and development,» *Journal of Molecular Graphics and Modelling*, 1999.
- [30] L. M. V. B. a. J. F. J. F. Pimentel, «A Large-Scale Study About Quality A Large-Scale Study About Quality,» chez *International Conference on International Conference on*, Montreal, 2019.
- [31] A. P. e. al., «PyTorch: An Imperative Style, High-Performance Deep Learning Library,» 2019.
- [32] M. A. e. al., «TensorFlow: A system for large-scale machine learning,» 2016.
- [33] M.-W. C. K. L. a. K. T. J. Devlin, «BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding,» 2019.
- [34] M. Sarda, «Data Analysis Using Pandas In Python | K21Academy , Cloud Training Program,» [En ligne]. Available: <https://k21academy.com/datascienceblog/introduction-to-pandas>.
- [35] mit.edu, «numpybook.pdf,» [En ligne]. Available: <https://web.mit.edu/dvp/Public/https://web.mit.edu/dvp/Public>.
- [36] F. P. e. al., «Scikit-learn: Machine Learning in Python,» *Journal of Machine Learning Research*, 2011.
- [37] J. D. Hunter, «Matplotlib: A 2D Graphics Environment,» *IEEE*, 2007.
- [38] M. Waskom, «seaborn: statistical data visualization,» *J. Open Source Softw*, 2021.
- [39] «Developer Experience (DevEx) - Engineering Fundamentals Playbook,» [En ligne]. Available: <https://microsoft.github.io/code-with-engineeringplaybook/developer-experience/>.
- [40] C. d. C.-L. e. al, «tqdm: A fast, Extensible Progress Bar for Python and CLI,» *The Journal of Open Source Software*, 2019.
- [41] GeeksforGeeks, «Deep Learning | Introduction to Long Short Term Memory,» [En ligne]. Available: <https://www.geeksforgeeks.org/deep-learningintroduction-to-long-short-term-memory/>.