

## ملخص

تؤثر اضطرابات الصحة النفسية مثل الاكتئاب، والقلق، واضطراب ثنائي القطب، والتوتر، واضطرابات الشخصية، والأفكار الانتحارية على ملايين الأشخاص حول العالم، ولا تزال عملية اكتشافها في مراحلها المبكرة تمثل تحديًا كبيرًا. وقد أتاحت التطورات الحديثة في مجال معالجة اللغة الطبيعية (NLP) التحليل الآلي للنصوص التي ينشئها المستخدمون بهدف تقييم الصحة النفسية.

تبحث هذه الأطروحة في استخدام **التعلم متعدد المهام (MTL)** من أجل تصنيف اضطرابات الصحة النفسية انطلاقًا من النصوص التي يكتبها المستخدمون، حيث يتم تعلم التنبؤ بالاضطرابات بشكل مشترك مع **تحليل المشاعر** باعتباره مهمة مساعدة. تم تقييم العديد من معماريات التعلم العميق، بما في ذلك النماذج المعتمدة على آليات الانتباه، والنماذج القائمة على المحولات (Transformers)، والمقاربات الهجينة، وذلك باستخدام مجموعتين من البيانات المتاحة بشكل عام حول الصحة النفسية.

تُظهر النتائج التجريبية أن معماريات المحولات تتفوق بشكل ملحوظ على الأساليب التقليدية، حيث حقق نموذج **DeBERTa-base** أفضل أداء، ببلوغ دقة **94.06%** ودرجة **F1-Score macro** بنسبة **93.09%**. كما تدرس هذه الدراسة تأثير التعلم متعدد المهام، وخيارات تصميم النماذج، واستراتيجيات التدريب على أداء عملية التصنيف.

## Abstract

Mental health disorders such as depression, anxiety, bipolar disorder, stress, personality disorders, and suicidal ideation affect millions of people worldwide and remain difficult to identify at an early stage. Recent advances in Natural Language Processing (NLP) have enabled the automatic analysis of user-generated text for mental health assessment. This thesis investigates the use of Multi-Task Learning (MTL) for mental health disorder classification from user-written text, where disorder prediction is learned jointly with sentiment analysis as an auxiliary task. Several deep learning architectures were evaluated, including attention-based models, transformer-based models, and hybrid approaches, using two publicly available mental health datasets. Experimental results show that transformer architectures significantly outperform traditional approaches, with DeBERTa-base achieving the best performance, reaching 94.06% accuracy and 93.09% macro F1-score. The study also examines the impact of multi-task learning, model design choices, and training strategies on classification performance. The findings confirm the effectiveness of transformer-based models for mental health text classification and contribute to the development of accurate and scalable computational mental health screening systems.

## Résumé

Les troubles de la santé mentale tels que la dépression, l'anxiété, le trouble bipolaire, le stress, les troubles de la personnalité et les idées suicidaires touchent des millions de personnes dans le monde et demeurent difficiles à identifier à un stade précoce. Les récentes avancées en traitement automatique du langage naturel (TALN) ont permis l'analyse automatisée de textes rédigés par les utilisateurs à des fins d'évaluation de la santé mentale. Ce mémoire étudie l'application de l'apprentissage multi-tâches (Multi-Task Learning, MTL) à la classification des troubles mentaux à partir de textes rédigés par les utilisateurs, où la prédiction du trouble est réalisée conjointement avec l'analyse de sentiments en tant que tâche auxiliaire. Plusieurs architectures d'apprentissage profond ont été évaluées, notamment des modèles à mécanisme d'attention, des modèles basés sur les transformateurs et des approches hybrides, en utilisant deux jeux de données publics relatifs à la santé mentale. Les résultats expérimentaux montrent que les architectures à base de transformateurs surpassent significativement les approches traditionnelles, le modèle DeBERTa-base obtenant les meilleures performances avec une exactitude de 94,06% et un score macro F1 de 93,09%. Cette étude examine également l'impact de l'apprentissage multi-tâches, des choix architecturaux et des stratégies d'entraînement sur les performances de classification. Les résultats confirment l'efficacité des modèles transformateurs pour la classification de textes liés à la santé mentale et contribuent au développement de systèmes de dépistage computationnels précis et évolutifs.