

# Vers une ingénierie des exigences dirigée par les données : analyse automatique d'avis d'utilisateurs

Jialiang Wei\*, Anne-Lise Courbis\*, Thomas Lambolais\*, Binbin Xu\*,  
Pierre Louis Bernard\*\* and Gérard Dray\*

\*: EuroMov Digital Health in Motion, Univ Montpellier, IMT Mines Ales, Ales, France

\*\* : EuroMov Digital Health in Motion, Univ Montpellier, IMT Mines Ales, Montpellier, France

\* : `firstname.lastname@mines-ales.fr` \*\* : `firstname.lastname@umontpellier.fr`

## Résumé

Ces travaux s'inscrivent dans le cadre de l'ingénierie des exigences dirigée par les données et notamment les avis d'utilisation. Les commentaires en ligne d'utilisateurs d'applications sont une source importante d'informations pour en améliorer leur fonctionnement et en extraire de nouveaux besoins. Nous proposons une analyse automatisée en utilisant CamemBERT, un modèle de langue en français qui fait aujourd'hui état de l'art. Afin d'affiner ce modèle, nous avons créé un jeu de données de classification multi-labels de 6000 commentaires issus de trois applications du domaine de l'activité physique et la santé<sup>1</sup>. Les résultats sont encourageants et permettent d'identifier les avis concernant des demandes de nouvelles fonctionnalités.

## Mots-clés

Ingénierie des exigences, Ingénierie guidée par les données, TALN, CamemBERT, Apprentissage profond

## Abstract

We are concerned by Data Driven Requirements Engineering, and in particular the consideration of user's reviews. These online reviews are an important source of information for extracting new needs and improvement requests. In this paper, we provide an automated analysis using CamemBERT, which is a state-of-the-art language model in French. In order to fine tune the model, we created a multi-label classification dataset of 6000 user reviews from three applications in the Health & Fitness field. The results are encouraging and make it possible to identify automatically the reviews concerning requests for new features.

## Keywords

Requirements Engineering, Data Driven Requirements Engineering, NLP, CamemBERT, Deep Learning

1. Données disponible en ligne : <https://github.com/Jl-wei/APIA2022-French-user-reviews-classification-dataset>

## 1 Introduction

L'ingénierie des exigences (IE) est l'une des phases du cycle de développement des systèmes, visant à élaborer un cahier des charges aussi clair et complet que possible, à partir des interviews de différentes parties prenantes (clients, utilisateurs, donneurs d'ordre). Il s'agit d'une des phases les plus critiques [1], jouant un rôle fondamental pour obtenir un logiciel de qualité. Les activités principales de l'IE sont : la conduite des interviews, l'élicitation, la modélisation du domaine et l'analyse de faisabilité. L'étape d'élicitation a pour objectif de mettre en exergue les besoins réels des parties prenantes [2]. Les approches traditionnelles visant à établir des modèles explicites d'exigences à partir d'interviews, brainstorming, observations, etc. sont enrichies par de nouvelles approches, visant à exploiter les retours des utilisateurs mis en ligne sur les stores d'applications ou les réseaux sociaux. Ainsi, la communauté d'IE propose de relever de nouveaux défis [3] consistant à développer une ingénierie des exigences dirigée par les données permettant de traiter un volume important d'avis d'utilisateurs.

Les stores d'applications, comme Google Play® et App Store®, sont devenus des plate-formes de communication entre utilisateurs et développeurs assurant la collecte d'avis sur chacune des applications en téléchargement. Ces avis sont riches en information car ils contiennent des critiques et des préférences, des retours d'expérience, des rapports d'erreur et des demandes de nouvelles fonctionnalités. Par exemple, l'application Facebook reçoit plus de 4000 commentaires journaliers dont 30% peuvent être considérés comme une source pour identifier de nouveaux besoins [4]. Exploiter manuellement de telles sources serait laborieux. Nous proposons d'effectuer un Traitement Automatique du Langage Naturel (TALN) pour filtrer les avis et cibler les plus pertinents en vue d'identifier de nouvelles exigences. Plus précisément, nous nous sommes intéressés à BERT (*Bidirectional Encoder Representations from Transformers*) [5], qui est un modèle d'apprentissage profond basé sur une architecture de type *Transformer*. BERT peut être affiné pour effectuer différentes tâches telles que la classification de textes, la réponse aux questions, l'inférence en langage naturel, etc. Ce sont les modèles basés

sur BERT qui ont obtenu les meilleures résultats sur la plupart des tâches de la communauté TALN. BERT étant entraîné en anglais, nous nous sommes tournés vers CamemBERT [6], un modèle de type BERT qui a été entraîné sur le corpus OSCAR en français afin d’avoir de meilleures performances sur les commentaires écrits en français.

Pour affiner le modèle BERT, il est nécessaire de l’entraîner avec un ensemble de données annoté. Il existe plusieurs jeux de données de commentaires annotés pour effectuer la classification [7–13]. La plupart de ces jeux de données sont en anglais. Certains sont multi-langues [8, 13]. Mais aucun d’eux n’intègre suffisamment de commentaires rédigés en français. Nous proposons donc de créer un jeu de données en français et d’explorer les résultats obtenus. Notre sujet d’étude étant à terme le développement selon une approche dirigée par les données d’applications de suivi de séniors pour « *bien vieillir en santé* », nous nous sommes intéressés aux commentaires de trois applications de la catégorie « Health & Fitness » de Google Play.

Dans la partie suivante nous présentons le jeu de données constitué ainsi que la méthode mise en œuvre pour conduire notre expérimentation. Les résultats de classification obtenus sont discutés dans la troisième partie. Enfin, dans la dernière partie, nous exposons les perspectives envisagées sur ces travaux.

## 2 Méthode mise en œuvre pour l’apprentissage

### 2.1 Jeu de données et son annotation

L’usage de CamemBERT pour classifier les avis d’utilisateurs écrits en français nécessite un jeu de données annoté. En l’état actuel de nos connaissances, il n’en existe pas. Nous en avons donc créé un. Nous avons tout d’abord collecté sur la plateforme Google Play des avis rédigés en français concernant les applications Garmin Connect, Huawei Health et Samsung Health. Le nombre de commentaires collectés et la taille choisie pour constituer le jeu de données pour la phase d’apprentissage sont présentés dans le Tableau 1. Nous avons ensuite associé manuellement des labels aux avis. Nous avons choisi d’utiliser quatre labels, comme cela est proposé dans [12] : *Évaluation*, *Rapport d’erreur*, *Demande de nouvelles fonctionnalités* et *Expérience utilisateur*. L’évaluation est généralement un texte simple qui exprime le sentiment général de l’utilisateur sous forme d’éloge, de critique ou de dissuasion. Le *rapport d’erreur* est relatif aux problèmes rencontrés lors de l’utilisation de l’application : perte de données, arrêt brutal de l’application, problème de connexion, etc. La *demande de nouvelles fonctionnalités* concerne de nouveaux services, de nouveaux contenus ou encore de nouvelles interfaces. Enfin, les avis de type *expérience utilisateur* sont des expériences relatées par les utilisateurs qui sont décrites par exemple comme des conseils d’utilisation, des fonctions ou des usages perçus comme très utiles ou faciles d’utilisation. Il est possible d’associer plusieurs labels à un même avis. Par exemple, l’avis : “*c’est une très bonne application. Elle*

App	#Avis	Échantillon
Garmin Connect	22880	2000
Huawei Health	10304	2000
Samsung Health	18400	2000

TABLEAU 1 – Applications et avis collectés pour la phase d’entraînement

*nous aide beaucoup à rester toujours actif.*” sera annoté dans les catégories *Évaluation* et *Expérience Utilisateur*. L’avis “*j’aimais bien cette application mais elle ne fonctionne plus : message d’erreur téléphone rooté!! faux et j’ai vérifié.*” sera annoté dans les catégories *Évaluation* et *Rapport d’erreur*. Les avis sont annotés par quatre auteurs de l’article, et révisés par Jialiang Wei. Le Tableau 2 indique le nombre d’avis classés dans chacune des catégories pour les trois applications cibles. La somme des avis classés n’est pas égale au total des avis puisque certains avis ont été affectés à plusieurs classes.

App	Total	(Ev)	(R)	(D)	(Exp)
Garmin Connect	2000	1260	757	170	493
Huawei Health	2000	1068	819	384	289
Samsung Health	2000	1324	491	486	349

TABLEAU 2 – Classification manuelle des avis en quatre familles : (Ev)aluation, (R)apport d’erreur, (D)emande de fonctions, (Exp)érience utilisateur

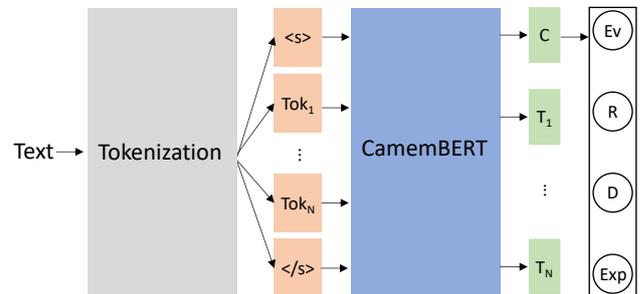


FIGURE 1 – Vue d’ensemble du modèle CamemBERT pour la classification multilabels

### 2.2 Modèle de classification

La classification des avis d’utilisateurs est un problème de classification de type TALN [14]. Ces dernières années, de nombreuses méthodes d’apprentissage statistique ont été appliquées à la classification d’avis. Maalej et al. [12] utilise des réseaux bayésiens, des arbres de décision et régression logistique multinomiale pour effectuer la classification des avis dans ces mêmes quatre catégories : *évaluation*, *rapport d’erreur*, *demande de fonctionnalités* et *expérience utilisateur*. Restrepo Henao et al. [15] applique BERT pour faire la classification des avis dans les catégories : *rapport de problèmes*, *demande de fonctionnalités*, et *avis non pertinent* ; ils comparent les performances des modèles d’apprentissage BERT et d’un réseau de neurones convolutif à apprentissage profond et concluent que BERT obtient les

meilleures taux de précision et de rappel. Mekala et al. [16] comparent la performance dans le domaine du *crowdsourcing* (production participative) de BERT avec des modèles de Machines à Vecteurs de Support, des classificateurs de type FastText et ELMo sur des avis d'utilisateurs classés en deux catégories : *inutile* et *utile*. BERT obtient également les meilleurs résultats. Les bonnes performances de BERT ont guidé notre choix sur sa version française CamemBERT. CamemBERT ne peut utiliser du texte brut en entrée. Une phase de pré-traitement est nécessaire : chaque avis est découpé en un ensemble de termes, ou jetons [17]. Les balises  $\langle s \rangle$  et  $\langle /s \rangle$  sont ajoutées pour marquer respectivement le début et la fin de l'avis. Les avis sont ensuite formatés à la longueur 512 en complétant ceux qui sont de taille inférieure avec la balise  $\langle \text{PAD} \rangle$ . Ceux qui sont de taille supérieure sont tronqués. Un masque est alors associé à chaque avis afin de repérer les symboles  $\langle \text{PAD} \rangle$  (valeur 0) et les termes (valeur 1). Puis, on attribue à chaque terme un identifiant numérique. Enfin, pour adapter CamemBERT à la tâche de classification souhaitée, nous modifions son architecture en ajoutant à son dernier niveau une couche linéaire à quatre sorties, comme le montre la Figure 1.

### 3 Expérimentations et résultats

Nous avons utilisé la bibliothèque PyTorch pour la mise en œuvre CamemBERT. Le modèle a été entraîné avec trois epochs, le paramètre `batch_size` et l'optimiseur AdamW avec un taux d'apprentissage fixé à  $2e^{-5}$ . Le modèle a été entraîné sur un ordinateur de 48 Go de mémoire RAM, muni d'un processeur Intel i7-7820HQ et d'une carte graphique NVIDIA Quadro M2200 de 4 Go de VRAM. L'évaluation de la performance de CamemBERT sur la classification des avis s'est faite sur deux expérimentations. Dans la première, les modèles sont entraînés sur une partie des avis des trois applications et testés sur l'autre partie. Dans la seconde expérimentation, les modèles sont entraînés sur les avis de deux applications et évalués sur ces applications et sur la troisième application.

#### 3.1 Apprentissage à partir des trois applications

Pour cette expérimentation, nous avons sélectionné 60% des avis des trois applications comme ensemble d'apprentissage, 20% comme ensemble de validation et 20% comme ensemble de test en utilisant un échantillonnage stratifié. Cette opération a été répétée 10 fois. Les critères d'évaluation de performance des modèles sont : la précision, le rappel et la F1-Mesure. Les résultats moyens obtenus sur les 10 apprentissages sont présentés dans le Tableau 3.

Comme le montre le Tableau 3, les résultats obtenus sont corrects dans l'ensemble : la moyenne de la F1-Mesure est de 0,89. Les résultats concernant le critère *Expérience Utilisateur* sont inférieurs aux trois autres. Ceci s'explique de deux façons. Tout d'abord les avis concernant ce critère sont plus variés, de nature moins homogène que les autres critères, ce qui rend plus difficile l'apprentissage des caractéristiques. Aussi, il serait nécessaire de faire un apprentis-

	Précision	Rappel	F1
Évaluation	0,88	0,93	0,91
Rapport d'erreur	0,92	0,93	0,93
Demande de fonctions	0,85	0,83	0,84
Expérience utilisateur	0,81	0,73	0,77
<b>Moyenne pondérée</b>	<b>0,88</b>	<b>0,89</b>	<b>0,89</b>

TABLEAU 3 – Résultats de la classification des avis des trois applications

sage sur un ensemble plus important d'avis pour améliorer les résultats. La seconde raison réside vraisemblablement dans le fait que quatre personnes ont participé à l'annotation des avis et leur interprétation du critère *Expérience Utilisateur* peut influencer les performances du modèle.

#### 3.2 Apprentissage à partir de deux applications

Dans cette expérimentation, nous avons utilisé la même stratégie d'échantillonnage stratifié : 60% des avis de deux applications comme base d'apprentissage, 20% comme validation. Les tests s'appliquent sur les 20% restants et également sur tous les avis de la troisième application. Nous avons fait ceci pour les trois combinaisons possibles d'applications sélectionnées pour l'apprentissage versus le test. Par exemple, une de ces combinaisons a consisté à réaliser l'apprentissage / validation sur 1600 avis de Garmin Connect et 1600 de Huawei Health et le test sur 800 avis de ces applications et les 2000 avis de Samsung Health. Pour chaque combinaison, 10 expériences ont été réalisées. Les résultats moyens des 30 apprentissages ( $3 \times 10$ ) sont présentés dans les Tableaux 4 et 5.

	Précision	Rappel	F1
Évaluation	0,88	0,93	0,90
Rapport d'erreur	0,91	0,93	0,92
Demande de fonctions	0,85	0,81	0,83
Expérience utilisateur	0,79	0,72	0,76
<b>Moyenne pondérée</b>	<b>0,87</b>	<b>0,88</b>	<b>0,88</b>

TABLEAU 4 – Résultats de classification des avis pour les 20% restants de deux applications

	Précision	Rappel	F1
Évaluation	0,88	0,92	0,90
Rapport d'erreur	0,85	0,92	0,88
Demande de fonctions	0,80	0,74	0,75
Expérience utilisateur	0,77	0,69	0,73
<b>Moyenne pondérée</b>	<b>0,86</b>	<b>0,86</b>	<b>0,85</b>

TABLEAU 5 – Résultats de classification des avis : apprentissage sur deux applications et test sur la troisième application

Les résultats présentés dans le Tableau 4 sont légèrement inférieurs à ceux du Tableau 3. Ils montrent que l'on peut obtenir de bonnes performances de classification avec un jeu de données restreint. Dans le Tableau 5, on peut obser-

ver que la moyenne de la précision et du rappel pour lesquels les modèles n'ont pas été entraînés sont inférieurs de 1-2% par rapport aux modèles ayant servi pour l'entraînement. Cette expérimentation montre que les résultats restent de très bonne qualité en entraînant le modèle sur un sous-ensemble d'applications.

## 4 Discussion et travaux futurs

Dans ce travail, nous avons créé un jeu de données pour la classification multi-labels d'avis rédigés en français d'utilisateurs d'applications de suivi d'activité physique. Nous avons utilisé le modèle CamemBERT pour classifier ces avis et les résultats obtenus montrent de bonnes performances. Les expérimentations d'entraînement et de test sur des applications distinctes montrent qu'il est possible de généraliser le modèle sur des applications de même champ applicatif. Ces résultats nous encouragent à poursuivre nos travaux relatifs à l'ingénierie des exigences dirigée par les données pour le développement de différentes versions d'une application de prévention des effets du vieillissement par le suivi de l'activité physique des seniors pour bien vieillir en santé. Nous envisageons d'affiner la classification des demandes de nouvelles fonctionnalités en permettant d'identifier, par une approche non supervisée, les concepts du domaine de l'application cible, comme par exemple, les vitesses et temps de marche, les déséquilibres ou le suivi du sommeil. Cette classification pourrait être présentée visuellement pour indiquer au concepteur quelles sont les fonctionnalités principalement demandées par les utilisateurs. L'objectif global sera de (i) regrouper les demandes et propositions par catégorie de besoins, (ii) mettre en correspondance ces besoins avec les modèles présents dans le cahier des charges, afin de pouvoir les prendre en compte plus facilement dans la conception.

## Références

- [1] A. van Lamsweerde, *Requirements Engineering : From System Goals to UML Models to Software Specifications*. Wiley, January 2009.
- [2] A. Bennaceur, T. Than Tun, Y. Yu, and B. Nuseibeh, "Requirements Engineering," in *Handbook of Software Engineering*. Springer Verlag, 2019, pp. 1–44.
- [3] X. Franch, "Data-Driven Requirements Engineering : A Guided Tour," in *Communications in Computer and Information Science*, vol. 1375. Springer, 2021, pp. 83–105.
- [4] D. Pagano and W. Maalej, "User feedback in the appstore : An empirical study," in *2013 21st IEEE International Requirements Engineering Conference (RE)*, 2013, pp. 125–134.
- [5] J. Devlin, M. W. Chang, K. Lee, and K. Toutanova, "BERT : Pre-training of deep bidirectional transformers for language understanding," in *NAACL HLT 2019 — 2019 Conference of the North American Chapter of the Association for Computational Linguistics : Human Language Technologies — Proceedings of the Conference*, vol. 1, October 2019, pp. 4171–4186.
- [6] L. Martin, B. Muller, and P. J. e. a. Ortiz Suárez, "CamemBERT : a Tasty French Language Model," in *58th Annual Meeting of the Association for Computational Linguistics*, Seattle, United States, July 2020.
- [7] G. Williams and A. Mahmoud, "Mining Twitter Feeds for Software User Requirements," in *2017 IEEE 25th International Requirements Engineering Conference (RE)*, 2017, pp. 1–10.
- [8] S. Scalabrino, G. Bavota, B. Russo, M. D. Penta, and R. Oliveto, "Listening to the Crowd for the Release Planning of Mobile Apps," *IEEE Transactions on Software Engineering*, vol. 45, no. 1, pp. 68–86, 2019.
- [9] E. Guzman, M. El-Haliby, and B. Bruegge, "Ensemble Methods for App Review Classification : An Approach for Software Evolution," in *2015 30th IEEE/ACM International Conference on Automated Software Engineering (ASE)*, 2015, pp. 771–776.
- [10] F. Palomba, M. Linares-Vásquez, and G. e. a. Bavota, "Crowdsourcing user reviews to support the evolution of mobile apps," *Journal of Systems and Software*, vol. 137, pp. 143–162, 2018.
- [11] A. Ciurumelea, A. Schaufelbühl, S. Panichella, and H. C. Gall, "Analyzing reviews and code of mobile apps for better release planning," in *2017 IEEE 24th International Conference on Software Analysis, Evolution and Reengineering (SANER)*, 2017, pp. 91–102.
- [12] W. Maalej, Z. Kurtanović, H. Nabil, and C. Stanik, "On the automatic classification of app reviews," *Requirements Engineering*, vol. 21, no. 3, pp. 311–331, 2016.
- [13] C. Stanik, M. Haering, and W. Maalej, "Classifying Multilingual User Feedback using Traditional Machine Learning and Deep Learning," in *2019 IEEE 27th International Requirements Engineering Conference Workshops (REW)*, 2019, pp. 220–226.
- [14] S. Minaee, N. Kalchbrenner, E. Cambria, N. Nikzad, M. Chenaghlu, and J. Gao, "Deep Learning–Based Text Classification : A Comprehensive Review," *ACM Comput. Surv.*, vol. 54, no. 3, April 2021.
- [15] P. R. Henao, J. Fischbach, D. Spies, J. Frattini, and A. Vogel-sang, "Transfer Learning for Mining Feature Requests and Bug Reports from Tweets and App Store Reviews," in *2021 IEEE 29th International Requirements Engineering Conference Workshops (REW)*, 2021, pp. 80–86.
- [16] R. R. Mekala, A. Irfan, E. C. Groen, A. Porter, and M. Lindvall, "Classifying User Requirements from Online Feedback in Small Dataset Environments using Deep Learning," in *2021 IEEE 29th International Requirements Engineering Conference (RE)*, 2021, pp. 139–149.
- [17] R. Sennrich, B. Haddow, and A. Birch, "Neural machine translation of rare words with subword units," in *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1 : Long Papers)*. Berlin, Germany : Association for Computational Linguistics, August 2016, pp. 1715–1725.