



**HAL**  
open science

## Plateforme d'extraction et d'analyse de conversations

Jacky Casas, Elena Mugellini, Omar Abou Khaled

► **To cite this version:**

Jacky Casas, Elena Mugellini, Omar Abou Khaled. Plateforme d'extraction et d'analyse de conversations. Workshop sur les Affects, Compagnons artificiels et Interactions, Jun 2020, Saint Pierre d'Oléron, France. hal-02933485

**HAL Id: hal-02933485**

**<https://inria.hal.science/hal-02933485>**

Submitted on 8 Sep 2020

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# Plateforme d'extraction et d'analyse de conversations

Jacky Casas  
HES-SO  
Fribourg, Switzerland  
jacky.casas@hes-so.ch

Elena Mugellini  
HES-SO  
Fribourg, Switzerland  
elena.mugellini@hes-so.ch

Omar Abou Khaled  
HES-SO  
Fribourg, Switzerland  
omar.aboukhaled@hes-so.ch

## ABSTRACT

Dans le cadre d'une étude visant à développer un agent conversationnel empathique, une plateforme a été développée afin de collecter et analyser des conversations de personnes depuis plusieurs applications de messagerie couramment utilisées. Cet article donne un aperçu de la conception et du développement de cette plateforme web qui va être testée prochainement avec de vrais utilisateurs.

## KEYWORDS

analyse de données, traitement automatique du langage, détection d'émotion, personnalité, anonymisation, extraction d'entités nommées

### ACM Reference Format:

Jacky Casas, Elena Mugellini, and Omar Abou Khaled. 2020. Plateforme d'extraction et d'analyse de conversations. In *WACAI 2020: Workshop sur les Affects, Compagnons Artificiels et Interactions, June 03–05, 2020, Île d'Oléron, France*. ACM, New York, NY, USA, 3 pages. <https://doi.org/10.1145/1122445.1122456>

## 1 INTRODUCTION

Lors de la création d'un agent conversationnel, des outils de traitement et de compréhension du langage naturel sont utilisés afin de comprendre l'intention de l'utilisateur. Afin d'entraîner ces outils, plusieurs techniques existent. La première manière est d'utiliser un set de données existant. Cela donne un résultat généraliste et souvent utilisé pour des discussions de type "chit-chat", ou bavardage. La seconde façon consiste à créer de toutes pièces le set de données. Lorsque l'on veut développer des conversations bien spécifiques, c'est vers cette seconde technique que l'on se tourne en général. Pour générer un set de données, il est possible de créer soi-même des questions/réponses, mais afin de générer de la diversité il est indispensable de regrouper les efforts de plusieurs personnes grâce à des outils comme Chatbotstrap [2]. Des services tels que ClickWorker ou Amazon Mechanical Turk permettent d'atteindre de grandes audiences pour générer des réponses en échange de rémunération.

Le parti pris de notre plateforme est d'extraire des conversations existantes d'utilisateurs sur les applications de messagerie instantanée. Des analyses de conversations Whatsapp ont déjà été faites par le passé [7, 8]. Cette technique nous permet d'avoir de vraies conversations et non des conversations forgées expressément dans

le but de créer un set de données. Nous espérons rassembler des échanges plus vrais, réels qu'avec les autres techniques. C'est à quoi la plateforme que nous allons décrire va servir.

## 2 OBJECTIFS

Le but est de développer une plateforme web d'analyse de conversations où une personne peut se connecter, importer ses données et voir les résultats des analyses faites.

L'utilisation de la plateforme se fait en plusieurs étapes. La première étape consiste à importer les conversations d'un utilisateur sur la plateforme. Les conversations peuvent provenir de quatre applications de messagerie différentes, à savoir Whatsapp, Telegram, Messenger et Instagram. Les données sont anonymisées et sauvegardées dans un format commun aux diverses applications afin d'en faciliter l'analyse a posteriori. Vient ensuite l'analyse des conversations qui a pour but d'extraire l'émotion transmise dans chaque message et de déduire la personnalité de la personne grâce à toutes ses conversations.

### 2.1 Exportation des données

Grâce à l'application du RGPD<sup>1</sup> en Europe, les entreprises doivent donner la possibilité à leurs utilisateurs d'extraire leurs données personnelles. Grâce à cela, chacun peut demander à recevoir ses conversations des applications de messagerie instantanée. Les quatre applications choisies le permettent donc, mais chaque application a son format bien défini. Par exemple Whatsapp permet d'extraire une conversation à la fois et retourne un fichier texte avec un format simple où chaque ligne comporte un message. À l'inverse, Telegram permet de télécharger en une fois une archive complète de toutes les conversations, où chaque conversation est un fichier en format JSON (JavaScript Object Notation). Chaque application a son propre format.

Nous avons donc défini notre propre format de données et transformons les conversations de chaque application dans notre format afin de pouvoir ensuite les traiter de la même façon, indépendamment de la plateforme initiale.

Sur le tableau de bord, l'utilisateur sélectionne l'application de messagerie qu'il souhaite et une marche à suivre est affichée afin qu'il puisse extraire ses conversations et les importer dans notre plateforme. Il répètera l'opération pour les autres applications de messagerie s'il le souhaite.

### 2.2 Anonymisation

Lors de l'importation, une première anonymisation est faite sur les noms des protagonistes de la conversation. Les noms sont remplacés par d'autres noms piochés dans une liste librement accessible sur

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. Copyrights for components of this work owned by others than ACM must be honored. Abstracting with credit is permitted. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee. Request permissions from [permissions@acm.org](https://www.acm.org).

WACAI 2020, June 03–05, 2020, Île d'Oléron, France

© 2020 Association for Computing Machinery.

ACM ISBN 978-1-4503-XXXX-X/18/06... \$15.00

<https://doi.org/10.1145/1122445.1122456>

<sup>1</sup>Règlement Général sur la Protection des Données, <https://gdpr-info.eu>

Internet de plus de 11’000 noms. À cette étape, rien n’est anonymisé dans les messages des conversations.

Vient alors la partie "Named entities extraction" ou "NER" qui permet d’extraire d’un message les entités nommées. Trois types d’entités ont été définis: PER (les noms de personnes), LOC (les noms de lieux) et ORG (les noms d’entreprises). Afin d’extraire ces entités des messages, nous utilisons SpaCy<sup>2</sup>, une bibliothèque logicielle de traitement de texte utilisant des modèles d’apprentissage automatique pré-entraînés sur de grands sets de données. Notre système supporte actuellement l’anglais, avec le modèle `en_core_web`, et le français avec le modèle `fr_core_news`. Lorsque le modèle a extrait les entités des phrases, l’utilisateur peut les visualiser sur le tableau de bord. L’utilisateur a la possibilité d’améliorer la classification des modèles en labellisant manuellement les entités mal classifiées, et de réentraîner le modèle en cliquant sur un bouton. Les utilisateurs suivants profiteront automatiquement du modèle amélioré. La labellisation se fait avec l’outil open-source Doccano<sup>3</sup>.

Lorsque l’utilisateur est satisfait de l’extraction des entités nommées, il peut volontairement déclencher l’anonymisation des conversations en cliquant sur un bouton. Cela va simplement remplacer toutes les entités personnes par d’autres noms de personnes, les lieux par d’autres lieux et les entreprises par d’autres entreprises.

## 2.3 Emotions

L’analyse des émotions est divisée en deux parties. La première se concentre sur les emojis utilisés dans les messages et la seconde sur le texte des messages et son sens (champ lexical, vocabulaire, intention) [5]. Le modèle utilisé pour les émotions est celui de Paul Ekman [3] qui considère six émotions principales: la tristesse, la joie, la colère, la peur, le dégoût et la surprise.

L’analyse des emojis se base sur une liste de 118 emojis<sup>4</sup> couramment utilisés, accompagnés d’une polarité entre -5 (négatif) et 5 (positif). Pour chacun de ces emojis, nous avons ajouté l’émotion correspondante parmi celles du modèle d’Ekman en nous fiant au nom de l’emoji (et non à sa représentation car celle-ci change en fonction de la plateforme utilisée). Pour chaque conversation, les emojis utilisés sont listés, comptés et la polarité moyenne de la conversation est calculée. Des statistiques et graphiques sont disponibles sur le site pour l’utilisateur.

Concernant l’analyse d’émotions à partir du texte du message, nous avons fait le choix d’utiliser différentes méthodes pour le français et l’anglais. Pour le français, la bibliothèque PyFeel<sup>5</sup> basée sur le lexique FEEL [1] a été utilisée. Ce lexique contient les mots chargés en émotion de la langue française étiquetés selon le modèle d’Ekman. PyFeel retourne, pour une chaîne de caractères donnée, le taux de chacune des six émotions, ainsi que la polarité (positive ou négative).

Pour la version anglaise, l’API de Senpy<sup>6</sup> est utilisée. Elle nous retourne les pourcentages des différentes émotions et est basée sur WordNet-Affect [6], un lexique d’émotions pour l’anglais. Par contre, ce lexique ne référence pas l’émotion "surprise", que nous ignorons donc dans l’analyse.

<sup>2</sup><https://spacy.io>

<sup>3</sup><https://github.com/doccano/doccano>

<sup>4</sup><https://github.com/words/emoji-emotion>

<sup>5</sup><https://github.com/AdilZouitine/pyFeel>

<sup>6</sup><http://senpy.gsi.upm.es>

Cette analyse des émotions, autant avec les emojis qu’avec le texte, nous permet de générer une vue d’ensemble d’une conversation sur la plateforme web. Un graphique d’évolution des émotions de la personne au fil du temps est également généré.

## 2.4 Personnalité

La dernière fonctionnalité de la plateforme consiste à extraire la personnalité de la personne qui a chargé ses conversations. Le modèle de personnalité utilisé est le modèle Big Five [4], qui évalue cinq traits de personnalités: l’ouverture à l’expérience, le caractère consciencieux, l’extraversion, l’agréabilité et le névrosisme.

*Personality Insights* d’IBM Watson<sup>7</sup> a été utilisé pour déterminer les taux de ces cinq traits. L’API accepte du texte en anglais jusqu’à 20MB. Les textes en français sont donc traduits en anglais et un échantillonnage est effectué dans les messages anglais et français traduits de l’utilisateur pour créer un document de moins de 20MB. L’API se charge ensuite de générer l’évaluation de personnalité.

L’analyse de personnalité, une fois terminée, est visible sur le tableau de bord. L’utilisateur peut répondre à un questionnaire de personnalité de type Big Five open-source<sup>8</sup> qui a été intégré au site. La personnalité extraite des messages est alors comparée à la personnalité extraite du questionnaire. Tout cela est directement visible sur la plateforme.

## 3 RÉALISATION

Pour réaliser cette plateforme, nous voulions créer un système accessible, clair et pratique. Le choix d’une application web a rapidement été fait pour l’accessibilité, puisqu’un simple navigateur et une connexion internet permet d’y accéder. Pour la mise en page, le choix s’est porté sur un site de type tableau de bord afin que les menus soient accessibles en tout temps sur la gauche de l’écran. La bibliothèque logicielle *Vue.js* a été utilisée pour le développement du site. Pour la clarté, les principes du *Material Design* ont été appliqués et le template *Vue Material Dashboard* utilisé.

Pour la partie serveur, une API REST a été développée en Python avec Flask afin de charger dynamiquement les données sur le tableau de bord. Toutes les données sont sauvegardées sous forme de documents dans une base de données MongoDB.

Des scripts opèrent en continu et effectuent toutes les tâches lourdes (extraction d’entités nommées, appel d’API externes, anonymisation, entraînement des modèles de langage, et autres). L’API et le tableau de bord fonctionnent séparément et ne sont donc pas impactés par ces activités, ce qui garantit une expérience fluide pour l’utilisateur.

## 4 PERSPECTIVES

Cette plateforme va servir d’outil de collecte de données utilisé dans le cadre de la création d’un set de données de conversations de vraies personnes. Elle permettra une analyse comparative de la personnalité des utilisateurs et une analyse des émotions dans les messages textuels. Il sera intéressant de savoir si la personnalité peut être extraite de courts messages. Les données récoltées seront destinées à améliorer les interactions automatisées d’un agent conversationnel futur.

<sup>7</sup><https://www.ibm.com/watson/services/personality-insights>

<sup>8</sup><https://github.com/Alheimsins/bigfive-web>

## ACKNOWLEDGMENTS

Merci à Samuel Torche, qui est le principal développeur de la plateforme.

## REFERENCES

- [1] Amine Abdaoui, Jérôme Azé, Sandra Bringay, and Pascal Poncelet. 2017. FEEL: a French Expanded Emotion Lexicon. *Language Resources and Evaluation* 51, 3 (Sept. 2017), 833–855. <https://doi.org/10.1007/s10579-016-9364-5>
- [2] Deeplink. 2020. Chatbotstrap - Training datasets for chatbots. <https://chatbotstrap.io>
- [3] Paul Ekman. 1992. An argument for basic emotions. *Cognition and Emotion* 6, 3-4 (May 1992), 169–200. <https://doi.org/10.1080/02699939208411068>
- [4] Lewis R. Goldberg. 1990. An alternative "description of personality": The Big-Five factor structure. *Journal of Personality and Social Psychology* 59, 6 (1990), 1216–1229. <https://doi.org/10.1037/0022-3514.59.6.1216>
- [5] Timo Spring, Jacky Casas, Karl Daher, Elena Mugellini, and Omar Abou Khaled. 2019. Empathic Response Generation in Chatbots. (2019), 10.
- [6] Carlo Strapparava and Alessandro Valitutti. 2004. WordNet-Affect: an Affective Extension of WordNet. (2004), 4.
- [7] Simone Ueberwasser and Elisabeth Stark. 2017. What's up, Switzerland? A corpus-based research project in a multilingual country. *Linguistik Online* 84, 5 (Sept. 2017). <https://doi.org/10.13092/lo.84.3849> Number: 5.
- [8] Lieke Verheijen and Wessel Stoop. 2016. Collecting Facebook Posts and WhatsApp Chats. In *Text, Speech, and Dialogue (Lecture Notes in Computer Science)*, Petr Sojka, Aleš Horák, Ivan Kopeček, and Karel Pala (Eds.). Springer International Publishing, Cham, 249–258. [https://doi.org/10.1007/978-3-319-45510-5\\_29](https://doi.org/10.1007/978-3-319-45510-5_29)