

La classification des sentiments dans la traduction indirecte

Alberto Poncelas

Le progrès technique a simplifié la communication à grande échelle. Des personnes issues de communautés linguistiques différentes et ayant des profils culturels variés peuvent à présent partager facilement leurs points de vue. Cette situation a provoqué une augmentation et une diversification des ressources linguistiques. Cependant, cette diversité linguistique complique l'analyse textuelle. Par exemple, certains travaux nécessitent une bonne connaissance de plusieurs langues pour exploiter les données textuelles disponibles. Il est donc plus judicieux de commencer par unifier ces données en traduisant tous les textes en une seule langue.

Bien souvent, la traduction directe d'un texte en une autre langue est une tâche ardue. On peut éprouver des difficultés à trouver des traducteurs professionnels maîtrisant les langues auxquelles on est confronté... ou à obtenir les ressources nécessaires à la création d'un moteur de traduction automatique. Pour résoudre ce problème, on peut notamment opter pour une traduction indirecte, en passant par une langue intermédiaire. Cependant, dans de nombreux cas, on s'éloignera de la langue source pour privilégier le sens général du message à transmettre [1]. Un exemple type de cette situation est l'analyse des sentiments dans les commentaires de clients. La collecte de commentaires a pour objectif d'obtenir le ressenti général de chaque client, qu'il soit positif ou négatif. Dans les interfaces manipulées par des clients provenant de nombreux pays, les systèmes de saisie et des commentaires sont disponibles pour une multitude de langues. Mais les compétences linguistiques des personnes devant traiter ces commentaires sont rarement suffisantes. Dans ce cas, comment comprendre tous les messages reçus ? L'une des solutions envisageables consiste à traduire tous les commentaires reçus en une seule langue. Ensuite, le traitement des commentaires peut s'effectuer en utilisant cette langue. Cependant, comme nous l'avons vu, il n'est pas toujours possible d'effectuer une traduction directe. On peut alors opter pour une traduction indirecte, en utilisant une langue pivot.

La qualité d'une traduction indirecte ne sera pas aussi bonne que celle d'une traduction directe (ou que celle du texte source), car chaque étape peut altérer le message. Cependant, l'objectif n'est pas d'obtenir une traduction parfaite, mais de transmettre le ressenti général de l'auteur d'un commentaire. Nous allons donc nous poser les questions suivantes : (1) Que reste-t-il du sentiment initialement exprimé dans un commentaire après sa traduction ? (2) L'utilisation d'une langue pivot peut-elle nuire à l'efficacité d'une classification des sentiments ? (3) L'utilisation de différentes langues pivots affecte-t-elle la classification des sentiments ?

Afin de répondre à ces questions, nous traduisons un recueil d'évaluations effectuées par les utilisateurs d'un logiciel [2]. Ces évaluations sont classées en cinq catégories [3] : « Comment » / « Remarque » (commentaire positif ou neutre sur le logiciel), « Complaint » / « Plainte » (commentaire négatif), « Request » / « Réclamation » (le client réclame l'amélioration du logiciel), « Bug » / « Bogue » (un problème technique dégrade les performances du logiciel), ou « Undetermined » / « Indéterminé » (le message reçu n'est pas considéré comme un commentaire à proprement parler). Les commentaires collectés ont été rédigés en : anglais, français, espagnol et japonais.

La première étape consiste à de créer une classification de sentiments automatique qui place automatiquement chaque commentaire dans la bonne catégorie. Pour y parvenir, nous utilisons un moteur de traduction neuronale. Nous utilisons notamment un réseau LSTM (Long short-term memory) ou « réseau de neurones récurrents à mémoire court-terme et long terme ». Son avantage réside dans le fait qu'une phrase y est présentée comme un vecteur et non comme un assemblage de mots. Les représentations de type « bag of words » ou « sac de mots » ne prennent pas en compte l'ordre des mots. Cela peut engendrer des complications en cas de négations dans la source. Par exemple, les phrases « The software is slow, I do not like it. » (« Je n'aime pas ce logiciel, il est lent. ») et « The software is not slow, I do like it. » (« J'aime ce logiciel, il n'est pas lent. ») sont composées des mêmes mots (en anglais), mais les sentiments exprimés sont diamétralement opposés.

Puis le texte est traduit à l'aide d'un moteur de traduction automatique neuronale. Nous produisons des traductions directes et indirectes (en utilisant différentes langues pivots). Ensuite, nous classons ces traductions dans les catégories mentionnées auparavant. Nous voulons voir si la catégorie de base reste la même quand nous utilisons la traduction automatique. En plus de cela, nous étudions les langues pivots afin de déterminer laquelle est la plus apte à transmettre le sentiment général. Bien qu'utiliser des langues proches peut améliorer la précision de la traduction, nous voulons voir si cela reste vrai lorsque l'objectif est de transmettre un sentiment plutôt que d'effectuer une traduction normale.

[1] Pintu Lohar, Haithem Afli, Andy Way. Maintaining Sentiment Polarity in Translation of User-Generated Content

[2] CH Liu, Y Moriya, A Poncelas, D Groves. IJCNLP-2017 Task 4: Customer Feedback Analysis

[3] CH Liu, D Groves, A Hayakawa, A Poncelas, Q Liu. Understanding Meanings in Multilingual Customer Feedback