



HAL
open science

Apprentissage d'agents conversationnels pour la gestion de relations clients

Benoit Favre, Frédéric Béchet, Géraldine Damnati, Delphine Charlet

► **To cite this version:**

Benoit Favre, Frédéric Béchet, Géraldine Damnati, Delphine Charlet. Apprentissage d'agents conversationnels pour la gestion de relations clients. 24e Conférence sur le Traitement Automatique des Langues Naturelles (TALN), 2017, Orleans, France. hal-01773218

HAL Id: hal-01773218

<https://amu.hal.science/hal-01773218v1>

Submitted on 21 Apr 2018

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.

Apprentissage d'agents conversationnels pour la gestion de relations clients

Benoit Favre¹ Frédéric Béchet¹ Géraldine Damnati² Délphine Charlet²

(1) LIF/CNRS, Aix-Marseille Université, France

(2) Orange Labs, Lannion, France

prenom.nom@univ-amu.fr, prenom.nom@orange.com

RÉSUMÉ

Ce travail démontre la faisabilité d'entraîner des chatbots sur des traces de conversations dans le domaine de la relation client. Des systèmes à base de modèles de langage, de recherche d'information et de traduction sont comparés pour la tâche.

ABSTRACT

Training chatbots for customer relation management

This work demonstrates the feasibility of training chatbots on customer relation conversation traces. Systems based on language models, information retrieval and machine translation are compared.

MOTS-CLÉS : Agents conversationnels, LSTM, GRU, seq2seq.

KEYWORDS: Chatbots, LSTM, GRU, seq2seq.

1 Agents conversationnels

En collectant de grandes quantités de discussions textuelles dans le cadre des services de relations client en ligne, il est aujourd'hui possible d'entraîner des agents conversationnels sur les traces de ces conversations (Shawar & Atwell, 2003). Ces "chatbots" peuvent être utilisés pour simuler le service (résoudre les problèmes des clients) lorsque des agents ne sont pas disponibles, ou simuler un client afin d'entraîner des agents débutants.

Les modèles à base d'apprentissage profond permettent de créer des agents conversationnels, en considérant le problème comme de la traduction (traduire l'historique du dialogue en l'intervention suivante), des modèles de langages (générer du texte étant donné un historique), ou de la recherche d'information (trouver l'intervention la plus propice dans la base d'apprentissage étant donné l'historique du dialogue).

La plupart des approches testées jusqu'ici s'intéressent à des échanges courts (Vinyals & Le, 2015), de type question / réponse, sans considérer les longs contextes des dialogues à finalité précise. Ces approches sont entraînées sur des traces issues de conversations IRC, de sous-titres de films ou de tweets (Lowe *et al.*, 2015). La contribution de ce travail est d'entraîner des agents conversationnels sur de grandes quantités de conversations liées à une même tâche pour explorer l'utilité de tels systèmes dans un contexte beaucoup plus réaliste, et ainsi d'en voir les limites.

2 Description des systèmes

Nous avons construit trois systèmes qui peuvent être comparés. Le premier est un modèle de langage dit "alternant". Ce modèle est entraîné à prédire la séquence de mots de la conversation, en séparant les tours des participants par un symbole spécial. Ce modèle génère une distribution de probabilité pour le mot suivant étant donné le mot courant et un état caché. Après l'entraînement, l'état caché est mis à jour sur les mots de l'humain pour ensuite générer les mots de la machine. Ces derniers sont tirés aléatoirement dans la distribution prédite jusqu'à génération d'un changement de participant. Ce modèle est implémenté dans TensorFlow comme un réseau de neurones récurrent LSTM à deux couches (Sundermeyer *et al.*, 2012), avec des couches cachées de taille 650, un vocabulaire de taille 30 000.

Le second modèle est un système à base de recherche d'information. Il crée des représentations de taille fixe pour l'historique et la prochaine intervention (appelée réponse) et est entraîné de manière à ce que les paires (historique, réponse) aient une représentation proche alors qu'elles doivent être éloignées lorsque la paire n'a pas été observée en entraînement. De cette manière, on peut rechercher la réponse la plus proche d'un historique donné pour continuer la conversation. Le désavantage de cette méthode est qu'elle ne permet pas de générer du texte nouveau, mais le concepteur de la base de réponses à un contrôle total des réponses possibles, ce qui est une contrainte pour de nombreuses applications industrielles. Ce système est implémenté dans Keras et entraîné par maximisation de la marge dans un triplet (historique, réponse, bruit). Les représentations sont extraites avec des RNN de type GRU, et ont une taille de 128. L'historique est limité aux 64 mots précédents.

Le troisième système est un système de traduction avec un mécanisme d'attention qui lui permet d'apprendre à localiser dans l'historique les mots les plus pertinents. Il fonctionne essentiellement comme le premier modèle sauf que les poids du modèle de l'historique ne sont pas partagés avec ceux du modèle pour la génération, et que le mécanisme d'attention permet de mieux tirer parti de l'historique lointain. Le système de traduction est fondé sur OpenNMT (Klein *et al.*, 2017) dans son paramétrage par défaut. L'historique est limité aux 64 mots précédents.

Remerciements Ce travail a été financé par l'Agence Nationale pour la Recherche au sein des projets suivants : ANR-15-CE23-0003 (DATCHA), ANR-16-CONV-0002 (ILCB), ANR-11-LABX-0036 (BLRI) et ANR-11-IDEX-0001-02 (A*MIDEX).

Références

- KLEIN G., KIM Y., DENG Y., SENELLART J. & RUSH A. M. (2017). Opennmt : Open-source toolkit for neural machine translation. *arXiv preprint arXiv :1701.02810*.
- LOWE R., POW N., SERBAN I. & PINEAU J. (2015). The ubuntu dialogue corpus : A large dataset for research in unstructured multi-turn dialogue systems. *arXiv preprint arXiv :1506.08909*.
- SHAWAR B. A. & ATWELL E. (2003). Using dialogue corpora to train a chatbot. In *Proceedings of the Corpus Linguistics 2003 conference*, p. 681–690.
- SUNDERMEYER M., SCHLÜTER R. & NEY H. (2012). Lstm neural networks for language modeling. In *Interspeech*, p. 194–197.
- VINYALS O. & LE Q. (2015). A neural conversational model. *arXiv preprint arXiv :1506.05869*.