
Modèle de compréhension du besoin en information pour la RI conversationnelle

Wafa Aissa – Laure Soulier – Ludovic Denoyer

Sorbonne Université, CNRS, Laboratoire d'informatique de Paris 6, LIP6, F-75005 Paris, France – prenom.nom@lip6.fr

RÉSUMÉ. La RI repose sur un cadre standard qui interroge des collections de documents à partir d'un besoin en information exprimé sous la forme d'un ensemble de mots-clés. Notre contribution vise à dépasser ce paradigme habituel en traitant directement le besoin en information exprimé en langage naturel pour tendre vers une nouvelle génération de systèmes de RI axés sur l'aspect conversationnels (appelés aussi "search oriented conversational systems"). Une première étape réside alors dans la formulation de requêtes à partir de besoins en information exprimés en langage naturel. Nous proposons dans ce papier un modèle de formulation de requêtes capable 1) d'apprendre la traduction des expressions en langage naturel en requêtes de type mots-clés de manière supervisée, et 2) d'injecter les retours de pertinence dans le processus d'apprentissage (apprentissage par renforcement). Pour pallier au manque de données d'apprentissage, nous considérons le modèle de traduction comme un modèle de sélection de mots. Notre modèle est évalué sur deux collections TREC démontrant ainsi son efficacité.

ABSTRACT. IR is based on a standard framework that queries document collections through an information need expressed as a set of keywords. Our contribution aims at overpassing this usual paradigm by starting the retrieval process from the natural language expression of the information need; giving rise to a new generation of IR systems based on conversational features (also called "search-oriented conversational systems"). Therefore, the first step focuses on the query formulation from the information need expressed in natural language. In this paper, we propose a query formulation model able of 1) translating natural language expressions to keyword queries in a supervised manner, and 2) injecting relevance feedback in the learning process through reinforcement learning technics. To overcome the lack of training data, we consider the translation model as a word selection process. Our model is evaluated on two TREC collections to demonstrate its effectiveness.

MOTS-CLÉS : Recherche d'information conversationnelle- traduction automatique - apprentissage par renforcement

KEYWORDS: Conversational Information retrieval - machine translation - reinforcement learning

1. Introduction

L'intelligence artificielle, et plus particulièrement l'apprentissage profond, ont ouvert de nombreuses perspectives quant au raisonnement sur la sémantique textuelle pour de nombreuses tâches, telles que la traduction automatique (Lample *et al.*, 2017), les systèmes conversationnels (Bordes et Weston, 2016), la complétion de la base de connaissances (Lin *et al.*, 2015) ou l'extraction d'information (Hoffmann *et al.*, 2011). Le domaine connexe de la recherche d'information (RI) en a également bénéficié en intégrant dans son paradigme traditionnel d'appariement document-requête les techniques d'apprentissage profond (Guo *et al.*, 2016 ; Severyn et Moschitti, 2015). Cependant, la formulation de la requête exprimée sous forme de mots-clés est depuis toujours connue comme une tâche difficile (Vakulenko *et al.*, 2017 ; Agichtein *et al.*, 2006 ; Joachims, 2002) qui peut appauvrir la sémantique du besoin en information. Pour résoudre cet enjeu, la perspective d'interagir avec les moteurs de recherche grâce au langage naturel a émergé depuis peu au travers d'un nouveau paradigme de RI : la *recherche d'information conversationnelle* (Burtsev *et al.*, 2017 ; Joho *et al.*, 2018). L'objectif à long terme de ce paradigme est de développer des systèmes de conversation permettant de rechercher de l'information en réponse à un besoin en information (ou une séquence d'interactions) exprimé(es) en langage naturel.

Pour l'instant, les systèmes de conversation sont limités à de simples interactions conversationnelles ("*chit-chat bots*") (Li *et al.*, 2016a ; Ritter *et al.*, 2011) ou à la résolution de tâches précises ("*task-oriented chatbots*"). Dans ce dernier cas, l'univers de la tâche est généralement réduit à des mondes fermés ; le système est alors guidé par des patrons d'interactions ou des bases de connaissances (Dhingra *et al.*, 2017). Par exemple, pour l'organisation d'un voyage, le système conversationnel est formaté selon une chronologie de sous-actions (réserver un avion, puis un hôtel, etc.) définie préalablement. Pour aborder des tâches sur des "mondes ouverts" (données textuelles sur le web ou dans de larges collections de documents) où les besoins en information sont souvent formulés sans connaissance préalable de la représentation réelle des réponses, il est nécessaire d'intégrer des approches issues de la RI. Les systèmes conversationnels pour la RI sont alors une réponse à cet enjeu car ils permettent d'interagir avec l'utilisateur en langage naturel sur plusieurs itérations, facilitant ainsi la compréhension du besoin.

Pour ce faire, nous imaginons un système conversationnel pour la RI comme un système hybride où le système de dialogue interagit avec le système de RI (voir Figure 1). Un tel système permettrait de bénéficier à la fois des traces utilisateur (aussi appelés logs de recherche) pour améliorer le processus de recherche et également des interactions en langage naturel entre le système de dialogue et l'utilisateur pour améliorer la compréhension du besoin en information. Entre autres, un des enjeux de ces systèmes pour la RI réside dans la compréhension du besoin en information exprimé en langage naturel afin de formuler une requête sous la forme de mots-clés pour permettre au système de RI d'identifier les documents pertinents. Un exemple de requête en langage naturel est "*How to connect my tablet to tv ?*"; sa requête mots-clés associée est alors "*tablet tv connector*" (Yin *et al.*, 2017). Deux lignées de travaux,




Figure 1. Aperçu du système conversationnel pour la RI

pouvant être complémentaires, se distinguent dans cette optique : 1) la modélisation du problème comme un problème de traduction permettant d’obtenir des formulations de besoin en information sous la forme de mots-clés (Nogueira et Cho, 2017 ; Song *et al.*, 2017 ; Yin *et al.*, 2017) et 2) la prise en compte de la dynamique des actions des utilisateurs permettant de raffiner la compréhension du besoin, comme initialement réalisé en RI (Agichtein *et al.*, 2006 ; Joachims, 2002).

Dans cet article, nous proposons de nous intéresser au problème de traduction sans prise en compte des interactions des utilisateurs, qui a été récemment initié dans la communauté. Les premiers travaux se sont intéressés à l’exploitation des modèles d’apprentissage profond pour l’alignement des besoins en information exprimés en langage naturel avec ceux formulés au travers de mots-clés (Song *et al.*, 2017 ; Yin *et al.*, 2017). Cependant, ces modèles apprennent un modèle de formulation de requêtes indépendamment de la tâche de recherche en cours. Pour dépasser cette limite, (Nogueira et Cho, 2017) ont proposé un modèle de reformulation de requêtes exploitant les techniques d’apprentissage par renforcement. Les termes sont alors pondérés en fonction de la récompense mesurant la performance du système de RI.

Dans ce travail, nous proposons de relier ces deux approches : 1) la traduction automatique pour apprendre des alignements entre les besoins en information exprimés en langage naturel et les besoins en information formulés à l’aide des mots-clés (Song *et al.*, 2017 ; Yin *et al.*, 2017), et 2) l’apprentissage par renforcement pour injecter l’objectif de la tâche de RI dans le modèle de traduction automatique (Nogueira et Cho, 2017). Plus particulièrement, nous proposons un modèle de traduction supervisé augmenté par des techniques de renforcement qui permettent de raffiner la compréhension du besoin. Cette double approche requiert à la fois de disposer d’un jeu de données incluant 1) des paires de besoins en information exprimés en langage naturel vs. exprimés en mots-clés et 2) une collection de documents et des jugements de pertinence associés à ces besoins en information. A notre connaissance, les jeux de données TREC sont les seuls à exprimer une telle contrainte, mais le nombre de paires de besoins exprimés en langage naturel/mots-clés est toutefois limité. Par conséquent, nous formulons notre modèle de traduction comme un modèle de sélection de mots

visant à identifier les mots de l'expression en langage naturel pouvant être utilisés pour construire la requête ; plutôt qu'un modèle génératif où la requête peut être constituée de n'importe quel mot du vocabulaire. Les expérimentations sur deux jeux de données TREC montrent l'efficacité de la combinaison de l'apprentissage par renforcement avec des modèles de traduction automatique.

Le reste du papier est organisé comme suit. La section 2 présente les travaux de l'état de l'art. La section 3 détaille notre modèle de traduction automatique. La section 4 présente le protocole d'évaluation. Les résultats sont mis en évidence et discutés dans la section 5. La section 6 conclue le papier et énonce les perspectives.

2. État de l'art

Nous présentons dans ce qui suit les travaux de l'état de l'art relatifs à notre contribution. Dans un premier temps, nous donnons un bref aperçu des systèmes de conversation. Ensuite, nous nous intéressons à la problématique de la compréhension du besoin en information pour des systèmes de RI conversationnels.

2.1. Systèmes conversationnels

Les systèmes conversationnels font l'objet d'une attention croissante ces dernières années du fait de l'efficacité des modèles d'apprentissage profond pour le traitement de texte. Plus particulièrement, on distingue deux catégories principales de systèmes conversationnels. 1) Les systèmes de discussion ("*chit-chat bots*") (Yan *et al.*, 2016) qui ont pour but d'interagir avec l'utilisateur dans le cadre de discussions ouvertes. Ces derniers fournissent des réponses en fonction de la discussion et des interactions avec l'utilisateur. On trouve deux catégories de modèles : ceux reposant sur une approche de RI retournant la meilleure réponse possible parmi un ensemble de réponses candidates (Agarwal *et al.*, 2012); et ceux basés sur des modèles génératifs tels que les modèles "*seq-to-seq*" (Sordani *et al.*, 2015). D'autres recherches récentes dans ce domaine ont exploré les techniques d'apprentissage profond par renforcement (Li *et al.*, 2016b) et les réseaux adverses génératifs (Li *et al.*, 2017) pour la génération de dialogue. 2) Les systèmes orientés tâches (Bordes et Weston, 2016), qui interrogent généralement des bases de connaissances où sont stockés des faits importants afin d'extraire les informations précises, par exemple les noms de restaurants pouvant être réservés et leurs propriétés dans le cas d'un système de dialogue pour la réservation de restaurants. Par exemple, (Bordes et Weston, 2016) proposent un système de dialogue basé sur un réseau à mémoire (appelé aussi "*memory network*") qui fait appel à une base de connaissance pour générer des réponses et mener une conversation.

Les systèmes conversationnels reposent généralement sur trois composants : la compréhension du langage naturel, la gestion du dialogue et la génération de réponses (Vinyals et Le, 2015). La première composante ("compréhension du langage naturel") est primordiale pour assurer l'efficacité du système de dialogue. Habituellement, cette

tâche est divisée en trois sous-tâches : deux tâches de classification (à savoir la détection du domaine et la détection d'intention) (Xu et Sarikaya, 2014) et la sous-tâche de remplissage de patrons (détection d'objet d'intérêt) (Tur, 2011). Les approches utilisées pour traiter ces tâches peuvent être divisées en trois catégories : i) approches basées sur des règles ou patrons (Campillos Llanos *et al.*, 2015), ii) approches basées sur des données telles que des approches statistiques ou neuronales (Dinarelli *et al.*, 2012 ; Vukotic *et al.*, 2015), iii) approches hybrides combinant règles/patrons et approches neuronales (Bordes et Weston, 2016). Ces approches fournissent de bons résultats mais ont leurs propres limites. En effet, les approches basées sur les données nécessitent une quantité importante de données annotées, tandis que les approches basées sur les règles (ou connaissances) nécessitent un expert. De plus, les systèmes conversationnels demeurent sous-exploités pour des tâches de RI offrant de nombreuses perspectives pour la communauté.

2.2. Vers la compréhension du besoin exprimé en langage naturel pour des systèmes conversationnels de RI

Un des enjeux des systèmes conversationnels pour la RI consiste en la compréhension du besoin en information exprimé en langage naturel pour formuler une requête composée de mots-clés. D'un point de vue du domaine de la RI, cette problématique peut être vue comme de la reformulation ou de suggestion de requêtes en se basant sur un processus de ré-injection de pertinence (Joachims, 2002 ; Jones *et al.*, 2006 ; Kraft et Zien, 2004 ; Baeza-Yates *et al.*, 2005). Cependant, ces travaux reposent sur une formulation à base de mots-clés pour la requête initiale. Le nouvel enjeu des systèmes conversationnels est de dépasser cette contrainte en considérant des interactions exprimées en langage naturel, et plus particulièrement, dans notre cas de traduire un besoin en langage naturel vers une requête composée de mots-clés. Nous présentons dans ce qui suit les travaux émergents qui sont les plus proches de notre contribution.

La première catégorie s'intéresse à la formulation de requêtes comme un modèle de traduction supervisée (Song *et al.*, 2017). Le principal travail a été initié récemment (Song *et al.*, 2017). Les auteurs présentent un modèle d'apprentissage profond de type encodeur-décodeur basé sur un mécanisme d'attention permettant de se concentrer sur les mots les plus informatifs de la requête. Ce modèle est évalué sur un jeu de données artificiel composé de 828.826 paires de requêtes exprimées en langage naturel vs. sous la forme de mots-clés, où les requêtes en langage naturel sont construites à partir du titre du premier document retourné à l'aide d'un moteur de recherche. Cependant, ce modèle n'apprend qu'un alignement entre les deux expressions du besoin en information, sans prendre en compte l'objectif de la tâche.

Pour résoudre cette limite, une deuxième catégorie de travaux émerge afin d'intégrer l'objectif de la tâche dans le processus de formulation de requête (Nogueira et Cho, 2017 ; Yin *et al.*, 2017). Par exemple, (Yin *et al.*, 2017) ont proposé le modèle DeepProbe pour formuler une requête de façon interactive dans le cas d'une recherche de produits. En plus d'apprendre la traduction de l'expression en langage naturel, ils

formulent un modèle interactif qui interroge le moteur de recherche grâce à la requête formulée par le modèle. En fonction de l'efficacité de la formulation, le système pose des questions pour mieux comprendre le besoin de l'utilisateur. Ces questions sont basées sur les attributs du produit (tels que la taille, la couleur, etc.) et permettent d'enrichir la représentation du besoin en langage naturel pour raffiner la formulation de la requête. Une deuxième technique qui émerge dans la littérature repose sur l'apprentissage par renforcement (Sutton *et al.*, 1999) permettant de booster la fonction de coût par une récompense liée à la tâche. Cette technique a été appliquée dans la génération de dialogue (Li *et al.*, 2016b), la génération de questions à partir du texte (Kumar *et al.*, 2018), la reformulation des requêtes (Nogueira et Cho, 2017) ou encore la reformulation active des questions (Buck *et al.*, 2017). Proches de notre contribution, (Nogueira et Cho, 2017) proposent un système d'apprentissage par renforcement permettant de reformuler les requêtes en bénéficiant d'un processus de réinjection de pertinence à partir des termes inclus dans les documents retournés. La fonction objectif a alors pour but de maximiser l'efficacité de l'ordonnancement réalisé à partir de la requête générée. Pour ce faire, les représentations vectorielles des requêtes, de chaque terme candidat et de son contexte sont concaténées afin de calculer la probabilité de sélectionner un terme candidat.

En outre, plusieurs études ont montré l'intérêt de considérer le contexte des conversations. Par exemple, (Sordoni *et al.*, 2015 ; Serban *et al.*, 2016) exploite les requêtes soumises précédemment pour générer des réponses, tandis que (Yan *et al.*, 2016) exploite un contexte caractérisé par les questions/réponses des utilisateurs pour extraire une réponse dans un ensemble prédéfini de réponses possibles.

2.3. Positionnement

Notre contribution se distingue des précédents travaux selon plusieurs aspects. Tout d'abord, contrairement à la plupart des systèmes conversationnels (Chen *et al.*, 2017), notre travail s'intéresse à un nouveau paradigme se focalisant sur les systèmes conversationnels pour la RI qui s'attaquent à la problématique de la gestion des interactions dans un monde informationnel ouvert (Burtsev *et al.*, 2017 ; Joho *et al.*, 2018). Dans le cadre de notre problématique de compréhension et satisfaction du besoin, une des difficultés réside dans le fait que le système de dialogue ne dispose pas de réponses pré-définies candidates comme (Yan *et al.*, 2016). De plus, à l'inverse 1) des travaux basés sur la traduction automatique ou la génération de requêtes (Yin *et al.*, 2017) qui reposent sur une supervision de paires d'expression du besoin en information sans prise en compte de l'efficacité de l'approche et 2) des modèles basés sur l'apprentissage par renforcement guidés par une récompense mais connus pour être instables et difficiles à entraîner (Mnih *et al.*, 2015), notre approche propose de combiner le bénéfice de ces deux approches. Enfin, en opposition aux précédents travaux qui exploient soit des jeux de données propriétaires (Yin *et al.*, 2017) ou des jeux de données artificiels construits sur la base de requêtes-titres et qui ne correspondent ni à des besoins conversationnels ni de réelles paires appariées de requête-langage naturel (Song

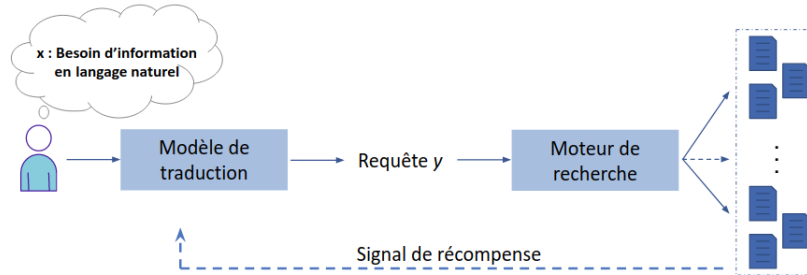


Figure 2. Aperçu du modèle de formulation de requêtes combinant l'approche de traduction et d'apprentissage par renforcement

et al., 2017), nous évaluons notre modèle sur les collections TREC incluant à la fois des formulations du besoin en langage naturel et sous la forme de mots-clés. Ces dernières comportent un jeu de données moins important mais nous semblent les plus proches de notre problématique afin de réaliser des expérimentations réalistes.

3. Modèle de traduction automatique basé sur l'apprentissage par renforcement

Nous présentons ici notre modèle de formulation de requêtes à partir d'un besoin exprimé en langage naturel afin de satisfaire une tâche de RI. Nous modélisons ce travail comme un problème de sélection de mots à partir de l'expression en langage naturel pour former la requête associée.

3.1. Préliminaires

Besoin en information. Le besoin en information d'un utilisateur est une expression du sujet pour lequel on souhaite identifier des documents pertinents. Dans cet article, on distingue deux types de besoins en information :

- *Le besoin en information exprimé en langage naturel.* On note ce besoin en information x qui est modélisé par une séquence de n mots ($x = x_1, \dots, x_i, \dots, x_n$).

- *Le besoin en information exprimé sous la forme de mots-clés, appelés aussi requête.* On note y la requête formulée sous la forme de mots-clés et associée au besoin en information exprimé en langage naturel x . La requête y est modélisée par un vecteur binaire $y \in \{0, 1\}^n$ de taille n . Chaque élément $y_j \in y$ est égal à 1 si le mot $x_j \in x$ existe dans la requête y et à 0 sinon. Par exemple, si nous considérons l'expression en langage naturel "Identify documents that discuss sick building syndrome or building related illnesses" et la requête de type mots-clés "sick building syndrome", la requête sera formulée comme suit : $y = (0, 0, 0, 0, 1, 1, 1, 0, 1, 0, 0)$.

Formulation du problème. Comme présenté dans la Figure 2, l’objectif de notre modèle est de construire la requête y associée au besoin en information x afin d’identifier les documents pertinents associés. Pour cela, nous proposons un modèle de sélection de mots f_θ (avec θ étant les paramètres de notre modèle) dont l’objectif est d’estimer la probabilité $p(y|x)$ de générer le vecteur binaire y étant donné l’expression en langage naturel x . En supposant que les termes ne sont pas indépendants dans la génération des expressions en langage naturel et des requêtes, la sélection d’un mot x_i est donc conditionnée par la séquence de décisions prises concernant les mots précédents $y_{<i}$. Ainsi, la probabilité $P(y|x)$ s’écrit comme suit :

$$p(y|x) = \prod_{y_i \in y} p(y_i | y_{<i}, x) \quad [1]$$

Guidé par les mérites et les limites des modèles de traduction et des techniques d’apprentissage par renforcement, nous proposons d’apprendre cette probabilité en combinant ces deux approches. Plus particulièrement, cette probabilité est d’abord apprise selon un estimateur du maximum de vraisemblance sur la base de paires d’expressions en langage naturel et de requêtes (section 3.2). Ensuite, cette probabilité est raffinée à l’aide des techniques d’apprentissage par renforcement (section 3.3). Nous présentons ensuite l’architecture neuronale utilisée pour apprendre cette probabilité.

3.2. *Modèle supervisé de traduction automatique : du langage naturel vers des requêtes*

La première étape de notre approche repose sur un modèle de traduction automatique supervisé qui sélectionne les mots du vocabulaire disponible dans le besoin en information exprimé en langage naturel x .

Plus particulièrement, étant donné un ensemble D de N paires de besoins en information en langage naturel vs. mots-clés $D = \{(x^1, y^1), \dots, (x^k, y^k), \dots, (x^N, y^N)\}$, l’objectif de cette étape est de formuler la requête y^k maximisant la vraisemblance des données, chaque mot x_i^k dans l’expression en langage naturel x^k est conditionné par sa probabilité de sélection $p(\hat{y}_i^k = y_i^k | \hat{y}_{<i}^k, x^k)$. En d’autres termes, le modèle prédit si chaque mot x_i^k dans l’expression en langage naturel x^k doit être inclus dans la requête y^k . La probabilité $p(\hat{y}_i^k = y_i^k | \hat{y}_{<i}^k, x^k)$ est calculée pour chaque mot y_i^k et prédit s’il doit être sélectionné ou non ($\hat{y}_i^k = y_i^k$) étant donné les sélections (ou absences de sélection) sur les mots précédents $\hat{y}_{<i}^k$ et l’expression en langage naturel x^k . Cette probabilité est modélisée à l’aide d’une distribution de Bernoulli où les paramètres sont estimés par la distribution de probabilité des sorties du modèles.

Définissons pour une instance de langage naturel et requête (x^k, y^k) la fonction $f_\theta(x^k) = \sum_{y_i^k \in y^k} \log(p(\hat{y}_i^k = y_i^k | \hat{y}_{<i}^k, x^k))$. Le modèle de traduction automatique

est entraîné en maximisant la vraisemblance sur l'ensemble D des paires de langage naturel et requête (x_k, y_k) :

$$L_{SMT} = \sum_{(x^k, y^k) \in D} \log(f_\theta(x^k)) \quad [2]$$

3.3. Intégration de l'objectif de la tâche par apprentissage par renforcement

Pour intégrer l'objectif de la tâche de RI dans le modèle de traduction automatique, nous proposons d'améliorer le processus de la création des requêtes par le biais des techniques d'apprentissage par renforcement. Nous nous appuyons sur le fait que les requêtes générées peuvent être évaluées via un système de RI, et plus particulièrement via l'ordonnancement obtenu à partir de ces requêtes. La qualité de l'ordonnancement peut alors être mesurée par une métrique d'évaluation (e.g., MAP, P@k, R@k) qui peut servir d'indicateur de direction dans l'apprentissage du modèle de traduction. Les quatre composants de notre modèle d'apprentissage par renforcement sont :

- *Action* : Nous avons défini notre problème comme un processus de sélection donc l'espace des actions possibles est limité à la sélection ou non de chaque mot x_i constituant le besoin en langage naturel x . Ainsi on note une action $a \in \{1, 0\}$, où 1 représente l'action de la sélection et 0 sinon.

- *État* : Les états sont les représentations cachées du modèle qui englobent les représentations vectorielles des besoins en langage naturel et les mots précédents.

- *Politique* : La politique est définie par les paramètres θ du modèle $f_\theta()$.

- *Récompense* : Nous évaluons les requêtes générées \hat{y} grâce à un moteur de recherche et nous obtenons la précision moyenne (également appelée "MAP"). Pour chaque expression en langage naturel x et la requête prédite associée \hat{y} , nous disposons d'un ensemble \mathcal{D}_x de documents pertinents (dans notre cas, fournis par les collections d'évaluation). De ce fait, l'efficacité de l'ordonnancement obtenu peut être estimée à l'aide d'une mesure basée sur l'efficacité (par exemple, la précision moyenne "AP"). Ainsi, la récompense R pour une requête générée \hat{y} en fonction de la paire de retour de pertinence (x, \mathcal{D}_x) est obtenue comme suit :

$$R(\hat{y}) = AP(\hat{y}, \mathcal{D}_x) \quad [3]$$

Le problème d'apprentissage par renforcement peut alors être formulé comme un problème d'optimisation dont l'objectif est de maximiser l'espérance de l'efficacité de la recherche des requêtes prédites \hat{y} sur l'ensemble GT des n paires $(x; \mathcal{D}_x)$. :

$$L_{RL}(\theta) = \arg \max_{\theta} \mathbb{E}_{\substack{(x; \mathcal{D}_x) \in GT \\ \hat{y} \sim f_\theta(x)}} [R(\hat{y}) - \bar{R}] \quad [4]$$

Où \hat{y} est la requête prédite par le modèle de la traduction $f_\theta(x)$ et \bar{R} est la récompense moyenne de l'époque précédente, c'est une régularisation de la récompense qui pousse le modèle à améliorer les résultats obtenus par rapport aux époques précédentes. Cette

fonction objectif est maximisée selon les techniques de descente de gradient (Baxter *et al.*, 1999). La récompense est injecté dans le processus d'apprentissage comme une pondération de l'erreur de l'entropie croisée donc la fonction de coût pour une paire k de langage naturel et requête est calculée comme suit :

$$L_{RL}(\theta) = \sum_{i=1}^n -\log p(\hat{y}^k | x^{(k)}) \times [R(\hat{y}) - \bar{R}] \quad [5]$$

3.4. Architecture du modèle

Le modèle est un réseau de neurones récurrent de type encodeur-décodeur (aussi appelé "seq-to-seq"), comme le montre la figure 3, formulant une requête \hat{y} à partir de l'entrée x . En particulier, chaque élément x_i de x est modélisé par un plongement de mots ("embeddings") w_{x_i} ; résultant en une séquence w_x de mots pour l'entrée x .

– *Encodeur* : l'encodeur est un LSTM bidirectionnel (Hochreiter et Schmidhuber, 1997) permettant de transformer la séquence d'entrée w_x en une représentation continue cachée h_n . Chaque état caché h_i est représenté par les états cachés en avant et en arrière tel que $h_i = [\vec{h}_i; \overleftarrow{h}_i]$, $\vec{h}_i = LSTM(\vec{h}_{i-1}, x_i)$ et $\overleftarrow{h}_i = LSTM(\overleftarrow{h}_{i-1}, x_i)$.

– *Décodeur* : Le décodeur est un LSTM où chaque mot x_i est injecté pour estimer la probabilité de sélection des mots $p(y_i | y_{<i}, x)$ en fonction du vecteur caché h_n appris avec l'encodeur et le mot actuel x_i ; dans le but d'estimer la probabilité $p(y_i | y_{<i}, x_i, h_i)$.




Figure 3. Architecture neuronale du modèle de transduction

4. Protocole d'évaluation

Nous présentons dans ce qui suit le protocole expérimental permettant d'évaluer les requêtes générées directement dans une tâche de RI.

	TREC Robust(2004)	TREC Web(2000-2001)
# de paires	250	100
Longueur moyenne des BILN	15.33	11.47
# moyen de mots redondants dans les BILN	1.108	0.65

Tableau 1. Statistiques sur les jeux de données séparés en fonction des collections des documents. BILN : Besoin en Information exprimé en Langage Naturel.

Requête (Titre TREC)	BILN (Description TREC)
Term limits	What are the pros and cons of term limits ?
Toronto film awards	Find documents that discuss the toronto film festival awards.

Tableau 2. Exemples de formulation de requêtes. BILN : Besoin en Information exprimé en Langage Naturel.

4.1. Jeux de données

Pour évaluer notre modèle, nous avons besoin d'un jeu de données incluant des 1) des paires de besoins en information exprimés en langage naturel et en mots-clés (requêtes), 2) une collection de documents associées et 3) des jugements de pertinence associés aux besoins en information. La plupart des précédents travaux reposant sur des modèles d'apprentissage profond et nécessitant par conséquent un grand nombre de données se sont principalement reposés sur des jeux de données propriétaires (Yin *et al.*, 2017) ou des jeux de données artificiels (Song *et al.*, 2017). Nous proposons dans ce papier d'utiliser les jeux de données de TREC (notamment Robust 2004 et Web 2000-2001) qui nous semblent les mieux adaptés à notre problématique. Afin de créer des paires de besoin en information exprimés en langage naturels et de requête, pour chaque sujet TREC, nous utilisons les titres pour former l'ensemble des requêtes et les descriptions pour les besoins en informations exprimés en langage naturel. Le vocabulaire étant très important, la construction des requêtes binaires y pour la supervision fournit un vecteur peu dense ("sparse"). Afin de résoudre ce problème et permettre un apprentissage des requêtes du jeu de données, nous avons normalisé le vocabulaire réduisant ainsi la dimensionnalité des représentations des requêtes. De plus, la collection de documents a été -par erreur- augmentée en incluant en plus le dossier "the Congressional Record", justifiant ainsi valeurs de MAP non similaires à celles de l'état de l'art. Nous soulignons que ces choix expérimentaux ont été appliqués à tous les scénarios et modèles de référence évalués et n'ont donc pas a priori d'impact sur les comparaisons des modèles. Nous présentons dans le tableau 1 les statistiques de ces jeux de données ainsi que dans le tableau 2 des exemples de ces paires de besoin en information.

Nous sommes conscients que l'utilisation des ensembles de données TREC est biaisée dans le sens où elle ne correspondent pas exactement à l'expression des besoins en informations en langage naturel dans le contexte des systèmes conversationnels,

mais nous pensons que la description est suffisamment verbeuse pour évaluer l'impact de notre modèle de prédiction de requêtes dans ce travail exploratoire. D'autres expériences avec des jeux de données plus importants et éventuellement générés seront effectuées dans des prochains travaux.

Du fait que notre modèle est formalisé comme un modèle de sélection de mots à partir de l'expression en langage naturel, nous avons analysé la fréquence des mots redondants dans les descriptions TREC. Dans la pratique, les doublons peuvent conduire à sélectionner plusieurs fois le même mot pour construire la requête et donc, influencer directement les performances de RI. Comme indiqué dans le tableau 1, le ratio des mots redondants dans les descriptions TREC est très faible (1,1 mot en moyenne dans chaque BILN pour TREC Robust et 0,65 pour TREC Web). Cela suggère que ce problème est mineur dans les jeux de données utilisés. Nous avons donc décidé de ne pas traiter cette problématique dans ce travail.

4.2. Métriques et modèles de référence

Pour évaluer notre approche, nous mesurons l'efficacité des requêtes prédites directement sur une tâche de RI. Pour ce faire, pour chaque requête prédite, nous utilisons le modèle BM25 via un système de RI (à savoir, PyLucene¹) pour obtenir un ordonnancement des documents. Notre objectif à long terme étant de faire interagir un système de dialogue et un moteur de recherche, les étapes de normalisation et de suppression des mots vides sur les requêtes fournies au système de RI sont appliquées, comme dans tout protocole standard de recherche d'information. Ce dernier est évalué via la métrique de la précision moyenne (MAP).

Pour montrer la pertinence de notre approche, nous comparons nos requêtes générées à celles disponibles sur le jeu de données (avec ou sans modification) :

- **NL** : Les besoins en information exprimés en langage naturel qui correspondent aux descriptions TREC dans les jeux de données après la normalisation du vocabulaire comme décrit dans la section 4.1.

- **Q** : Les requêtes sous la forme de mots-clés qui correspondent aux titres TREC dans les jeux de données après la normalisation du vocabulaire comme décrit dans la section 4.1.

- **Q bin** : Les projections des requêtes **Q** sur le vocabulaire disponible dans leurs descriptions **NL**. Le jeu de données étant un peu biaisé, nous avons observé que dans certains cas un titre peut contenir des nouveaux mots qui ne figurent pas dans la description. En comparant **Q** et **Q bin**, nous mesurons l'impact des nouveaux mots sur l'efficacité de l'extraction d'informations.

- **Random** Les requêtes composées de 3 mots sélectionnés aléatoirement à partir des besoins en langage naturel.

1. <http://lucene.apache.org/pylucene/>

De plus, différentes variantes de notre modèle sont testées :

- **SMT** qui réfère à un scénario de traduction automatique supervisée qui ne considère que le premier composant de notre modèle (section 3.2). Cette variante peut être assimilée à l’approche proposée dans (Song *et al.*, 2017) dans le sens où la traduction automatique est effectuée indépendamment de l’objectif de la tâche effectuée.
- **RL** qui correspond au scénario incluant uniquement la fonction objectif basée sur l’apprentissage par renforcement (section 3.3) sans l’entraînement préalable du modèle de traduction automatique supervisée. Nous étudions ici une approche semblable à celle de (Nogueira et Cho, 2017) où les requêtes sont améliorées itérativement en fonction des récompenses obtenues.
- **SMT+RL** qui correspond à notre modèle complet dans lequel nous commençons par pré-entraîner le modèle en utilisant le modèle de traduction automatique supervisée (section 2.3), puis nous injectons le signal de récompense pour pondérer les probabilités de la sélection des mots (section 2.4).

4.3. Détails d’implantation

Pour transformer chaque mot x_i en sa représentation vectorielle w_{x_i} , nous utilisons les plongements des mots pré-appris de FastText² (Bojanowski *et al.*, 2017). L’encodeur et le décodeur ont chacun une couche cachée de taille 100. Nous avons utilisé la librairie Pytorch³ pour coder nos modèles. Pour entraîner notre modèle, nous effectuons une validation croisée en 10 échantillons et nous découpons les données en mini-batches de taille 12. Pour le modèle **SMT + RL**, nous commençons par pré-entraîner le modèle de traduction automatique supervisée pendant 100 itérations. L’apprentissage est ensuite poursuivie pour 1000 itérations incluant l’approche de l’apprentissage par renforcement. Dans ce dernier cas, la récompense, à savoir la métrique MAP, est estimée sur les ordonnancements des 1000 premiers documents obtenus pour l’ensemble des requêtes du mini-batch par le modèle BM25 de PyLucene (paramètres par défaut). Les modèles **SMT** et **RL** sont initialisés avec les mêmes paramètres mentionnés ci-dessus et convergent après environ 100 et 1000 itérations respectivement. Nous utilisons un algorithme de mini-batch Adam (Kingma et Ba, 2014) pour pré-entraîner les différents modèle et la SGD pour la partie de l’apprentissage par renforcement.

5. Résultats

Nous présentons dans cette section l’efficacité de notre approche visant à générer des requêtes à partir des besoins d’informations exprimés en langage naturel. Dans le tableau 3, nous présentons l’efficacité de la RI (selon la MAP) de notre modèle et

2. <https://github.com/facebookresearch/fastText/>

3. <https://pytorch.org/>

Baseline	TREC Robust		TREC Web	
	MAP	%Chg	MAP	%Chg
NL	0.08925	+15.25% ***	0.15913	+12.88% *
Q	0.09804	+4.92%	0.16543	+8.58%
Q bin	0.08847	+16.26% *	0.17402	+3.22%
Random	0.01808	+468.91% ***	0.04060	+342.44% ***
SMT	0.06845	+50.27% ***	0.08891	+102.04% ***
RL	0.08983	+14.51% ***	0.16474	+9.04%
SMT+RL	0.10286		0.17963	

Tableau 3. Analyse comparative de l'efficacité de notre approche. %Chg : amélioration de **SMT+RL** par rapport aux références correspondantes. signification du t-test par paires * : $0.01 < t \leq 0.05$; ** : $0.001 < t \leq 0.01$; *** : $t \leq 0.001$.

des différents modèles de référence (**NL**, **Q**, **Q bin**, **Random**, **SMT** et **RL**) décrits dans la section 4.2. D'un point de vue général, les résultats soulignent que le modèle proposé **SMT + RL** surpasse les différents modèles références avec des améliorations généralement significatives, allant de +3.22% à +468.91% pour les deux jeux de données.

Plus particulièrement, l'analyse de l'efficacité nous permet de tirer les conclusions suivantes :

- La performance globale des différentes approches est généralement supérieure à l'efficacité de la RI de la référence **NL**. Par exemple, sur TREC Robust, les requêtes générées par notre modèle permettent d'améliorer considérablement les performances de RI de +15, 25% par rapport aux besoins en informations exprimés en langage naturel (MAP : 0,10286 contre 0,08925). Ce résultat valide la motivation de ce travail qui consiste à formuler des requêtes à partir des expressions en langage naturel. Ceci est relativement intuitif car les expressions en langage naturel sont verbeuses par nature et peuvent inclure des mots non spécifiques qui ajoutent du bruit dans le processus de RI.

- Notre approche **SMT + RL** fournit des résultats similaires à ceux de **Q** et **Q bin**. Ces deux références peuvent être considérées comme des "oracles" puisque la fonction objectif de notre modèle est guidée par la requête initiale **Q** transformée en un vecteur binaire (**Q bin**). Cependant, en fonction des mots sélectionnés pour la construction de la requête, il est possible que notre modèle obtienne de meilleures performances, ce qui est le cas ici avec, par exemple, des améliorations significatives de +3, 22% à +16, 26%) comparativement à la requête binaire originale **Q bin** pour TREC Robust. Pour mieux comprendre dans quelle mesure nos requêtes générées sont différentes de celles utilisées dans les références **Q** et **Q bin**, nous illustrons quelques exemples dans le tableau 4. Tandis que les requêtes TREC originales **Q** contiennent les mots les plus importants menant à une requête exploratoire (par exemple, "steel productions"), notre modèle **SMT + RL** fournit des mots supplémentaires précisant la facette de la

Collection	NL	Q	Q bin	SMT+RL
Robust ID requête : 308	what are the advantages and or disadvantages of tooth implant	implant dentistry	implant	advantages disadvantages tooth implant
Robust ID requête : 413	what are new methods of producing steel	steel producing	producing steel	new methods of producing steel
Web ID requête : 473	find documents that discuss the toronto film festival awards	toronto film awards	toronto film awards	the toronto film festival awards
Web ID requête : 482	find documents that give growth rates of pine trees	where can i find growth rates for the pine trees	growth rates pine trees	growth rates of pine trees

Tableau 4. Exemples de formulation de requêtes en NL *NL*, les requêtes originales *Q*, les versions binaires *Q bin* des requêtes originales et notre modèle *SMT+RL*.

requête concernée (par exemple, "new methods of..."); ce qui explique l'amélioration des performances dans l'ordonnancement des documents.

- Les résultats de notre modèle **SMT + RL** sont beaucoup plus élevés que le modèle de traduction supervisée **SMT**, qui converge vers une valeur de MAP relativement basse (0,06845 et 0,08891 pour TREC Robust et Web, respectivement). Cela peut s'expliquer par le fait que nos jeux de données sont très petits (250 et 100 paires d'expressions en langage naturel-requêtes respectivement pour TREC Robust et TREC Web). En effet, de telles approches de traduction automatique nécessitent une grande masses de données; conduisant ainsi à une perte d'efficacité pour notre cadre expérimental. Les techniques d'apprentissage par renforcement peuvent être envisagées comme une solution pour surmonter ce problème puisqu'elles injectent des informations supplémentaires (à savoir la récompense) dans l'apprentissage du modèle.

- Le modèle de référence basé seulement sur l'apprentissage par renforcement **RL** permet d'obtenir des performances de RI relativement bonnes. Comme nous pouvons le constater sur TREC Web, le modèle **RL** obtient une MAP de 0.16474 contre 0.15913 pour lors de l'exploitation du besoin en information en langage naturel **NL**. La référence **RL** permet d'approcher les performances de RI des modèles de référence **Q** et **Q bin**, bien qu'ils obtiennent des résultats plus faibles. Cela renforce notre intuition que 1) l'application d'approches de traduction automatique doit être guidée par la tâche (tâche de RI dans notre contexte) et 2) les techniques d'apprentissage par renforcement fournissent de bonnes stratégies pour construire des requêtes efficaces, comme suggéré dans une précédente contribution (Nogueira et Cho, 2017).

- La comparaison de notre modèle **SMT + RL** par rapport aux variantes **SMT** et **RL** indique que les techniques d'apprentissage par renforcement sont plus utiles

lors d'un pré-entraînement. Dans notre contexte, la convergence de l'estimateur du maximum de vraisemblance lors du pré-entraînement supervisé effectué à l'aide du modèle **SMT** (section 3.3) permet au modèle d'avoir plus d'information sur les différents contextes des mots ce qui le rend plus général et efficace. La structure des paires de données encourage le modèle à générer des phrases courtes. De façon complémentaire, la supervision atténuée l'instabilité du processus de l'apprentissage par renforcement ; démontrant ainsi l'efficacité de notre approche.

Il est à noter que nous avons également entraîné, dans le cadre d'expériences préliminaires, des modèles de traduction automatique de l'état de l'art, tels que les réseaux de neurones récurrents (RNN) de type encodeur-décodeur génératif avec le mécanisme d'attention, comme indiqué dans les papiers de (Yin *et al.*, 2017 ; Song *et al.*, 2017). Nous n'avons pas reporté les résultats car le modèle n'a pas été en mesure de généraliser lors de la phase de test par rapport aux nouvelles paires du jeu de données utilisées lors de la phase d'apprentissage. Ceci est probablement dû au fait que le nombre de paires d'entraînement n'est pas suffisant pour tenir compte des différents contextes du vocabulaire. Cependant, nous pensons que la combinaison de l'apprentissage par renforcement et le mécanisme d'attention pour la génération de requêtes est prometteuse.

6. Conclusion et perspectives

Nous proposons dans ce papier un modèle de traduction d'un besoin en information de l'utilisateur exprimé en langage naturel en une requête de type mots-clés afin d'améliorer l'efficacité de la RI dans un contexte de système conversationnel pour la RI. Notre modèle est formalisé comme un problème de sélection de mots et combine 1) la traduction automatique supervisée pour apprendre un alignement entre des besoins en information exprimés en langage naturel et des requêtes avec 2) l'apprentissage par renforcement pour optimiser le modèle en fonction de l'objectif de la RI et extraire des documents plus pertinents. Notre modèle a été évalué à l'aide de deux jeux de données TREC différents sur une tâche de RI. Nous avons obtenu des résultats prometteurs en termes d'efficacité de recherche. Notre approche présente certaines limites que nous prévoyons de travailler dans de futurs travaux. Premièrement, notre modèle est conçu comme un processus binaire de sélection de mots qui pourrait être transformé en un modèle génératif ou de pondération des termes. Deuxièmement, les expériences sont effectuées sur des petits ensembles de données (250 et 100 paires) qui pourraient être enrichies à l'aide du protocole d'évaluation proposé dans (Song *et al.*, 2017). À long terme, nous prévoyons de développer un système de RI mieux adapté à un contexte conversationnel et ceci en modifiant les systèmes de RI traditionnels pour bien gérer les expressions en langage naturel sans l'ajout d'un composant externe pour la reformulation de la requête.

7. Bibliographie

- Agarwal A., Raghavan H., Subbian K., Melville P., Lawrence R. D., Gondek D. C., Fan J., « Learning to Rank for Robust Question Answering », *Proceedings of the 21st ACM International Conference on Information and Knowledge Management, CIKM '12*, ACM, New York, NY, USA, p. 833-842, 2012.
- Agichtein E., Brill E., Dumais S., « Improving Web Search Ranking by Incorporating User Behavior Information », *SIGIR '06*, p. 19-26, 2006.
- Baeza-Yates R., Hurtado C., Mendoza M., « Query Recommendation Using Query Logs in Search Engines », in W. Lindner, M. Mesiti, C. Türker, Y. Tzitzikas, A. I. Vakali (eds), *Current Trends in Database Technology - EDBT 2004 Workshops*, 2005.
- Baxter J., Weaver L., Bartlett P., Direct Gradient-Based Reinforcement Learning : II. Gradient Ascent Algorithms and Experiments, Technical report, National University, 1999.
- Bojanowski P., Grave E., Joulin A., Mikolov T., « Enriching Word Vectors with Subword Information », *Transactions of the Association for Computational Linguistics*, vol. 5, p. 135-146, 2017.
- Bordes A., Weston J., « Learning End-to-End Goal-Oriented Dialog », *CoRR*, 2016.
- Buck C., Bulian J., Ciaranita M., Gajewski W., Gesmundo A., Houlsby N., Wang W., « Ask the Right Questions : Active Question Reformulation with Reinforcement Learning », 2017.
- Burtsev M., Chuklin A., Kiseleva J., Borisov A., « Search-Oriented Conversational AI (SCAI) », *ICTIR '17*, ACM, p. 333-334, 2017.
- Campillos Llanos L., Bouamor D., Bilinski E., Ligozat A.-L., Zweigenbaum P., Rosset S., « Description of the PatientGenesys Dialogue System », *Annual Meeting of the Special Interest Group on Discourse and Dialogue (SIGDIAL 2015)*, 2015.
- Chen H., Liu X., Yin D., Tang J., « A Survey on Dialogue Systems : Recent Advances and New Frontiers », 2017.
- Dhingra B., Li L., Li X., Gao J., Chen Y.-N., Ahmed F., Deng L., « Towards End-to-End Reinforcement Learning of Dialogue Agents for Information Access », *ACL' 17*, p. 484-495, 2017.
- Dinarelli M., Moschitti A., Riccardi G., « Discriminative Reranking for Spoken Language Understanding », *IEEE Transactions on Audio, Speech, and Language Processing*, 2012.
- Guo J., Fan Y., Ai Q., Croft W. B., « A Deep Relevance Matching Model for Ad-hoc Retrieval », *CIKM*, p. 55-64, 2016.
- Hochreiter S., Schmidhuber J., « Long Short-Term Memory », *Neural Comput.*, vol. 9, n° 8, p. 1735-1780, November, 1997.
- Hoffmann R., Zhang C., Ling X., Zettlemoyer L., Weld D. S., « Knowledge-based Weak Supervision for Information Extraction of Overlapping Relations », *HLT '11*, p. 541-550, 2011.
- Joachims T., « Optimizing Search Engines Using Clickthrough Data », *SIGKDD '02*, ACM, p. 133-142, 2002.
- Joho H., Cavedon L., Arguello J., Shokouhi M., Radlinski F., « CAIR'17 : First International Workshop on Conversational Approaches to Information Retrieval at SIGIR 2017 », *SIGIR Forum*, vol. 51, n° 3, p. 114-121, 2018.
- Jones R., Rey B., Madani O., Greiner W., « Generating Query Substitutions », *Proceedings of the 15th International Conference on World Wide Web, WWW '06*, 2006.

- Kingma D. P., Ba J., « Adam : A Method for Stochastic Optimization », *CoRR*, 2014.
- Kraft R., Zien J., « Mining Anchor Text for Query Refinement », *Proceedings of the 13th International Conference on World Wide Web*, WWW '04, p. 666-674, 2004.
- Kumar V., Ramakrishnan G., Li Y.-F., « A framework for automatic question generation from text using deep reinforcement learning », 2018.
- Lample G., Denoyer L., Ranzato M., « Unsupervised Machine Translation Using Monolingual Corpora Only », *CoRR*, 2017.
- Li J., Galley M., Brockett C., Gao J., Dolan B., « A Diversity-Promoting Objective Function for Neural Conversation Models », *HLT '16, ACL*, p. 110-119, 2016a.
- Li J., Monroe W., Ritter A., Galley M., Gao J., Jurafsky D., « Deep Reinforcement Learning for Dialogue Generation. », *CoRR*, 2016b.
- Li J., Monroe W., Shi T., Jean S., Ritter A., Jurafsky D., « Adversarial Learning for Neural Dialogue Generation. », in M. Palmer, R. Hwa, S. Riedel (eds), *EMNLP*, Association for Computational Linguistics, p. 2157-2169, 2017.
- Lin Y., Liu Z., Sun M., Liu Y., Zhu X., « Learning Entity and Relation Embeddings for Knowledge Graph Completion », *AAAI*, AAAI Press, p. 2181-2187, 2015.
- Mnih V., Kavukcuoglu K., Silver D., Rusu A. A., Veness J., Bellemare M. G., Graves A., Riedmiller M., Fidjeland A. K., Ostrovski G., Petersen S., Beattie C., Sadik A., Antonoglou I., King H., Kumaran D., Wierstra D., Legg S., Hassabis D., « Human-level control through deep reinforcement learning », *Nature*, vol. 518, n^o 7540, p. 529-533, February, 2015.
- Nogueira R., Cho K., « Task-Oriented Query Reformulation with Reinforcement Learning », *SCAI Workshop - ICTIR*, 2017.
- Ritter A., Cherry C., Dolan W. B., « Data-driven Response Generation in Social Media », *EMNLP '11*, 2011.
- Serban I. V., Sordoni A., Bengio Y., Courville A., Pineau J., « Building End-to-end Dialogue Systems Using Generative Hierarchical Neural Network Models », *Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence*, AAAI'16, AAAI Press, p. 3776-3783, 2016.
- Severyn A., Moschitti A., « Learning to rank short text pairs with convolutional deep neural networks », *SIGIR*, p. 373-382, 2015.
- Song H.-J., Kim A.-Y., Park S.-B., « Translation of Natural Language Query Into Keyword Query Using a RNN Encoder-Decoder », *SIGIR '17*, p. 965-968, 2017.
- Sordoni A., Galley M., Auli M., Brockett C., Ji Y., Mitchell M., Nie J.-Y., Gao J., Dolan B., « A Neural Network Approach to Context-Sensitive Generation of Conversational Responses », 2015.
- Sutton R. S., McAllester D., Singh S., Mansour Y., « Policy Gradient Methods for Reinforcement Learning with Function Approximation », *Proceedings of the 12th International Conference on Neural Information Processing Systems*, NIPS'99, MIT Press, Cambridge, MA, USA, p. 1057-1063, 1999.
- Tur G., *Spoken Language Understanding : Systems for Extracting Semantic Information from Speech*, John Wiley and Sons, January, 2011.
- Vakulenko S., Markov I., de Rijke M., « Conversational Exploratory Search via Interactive Storytelling », *NEUIR SIGIR'17*, 2017.
- Vinyals O., Le Q., « A Neural Conversational Model », 2015.

- Vukotic V., Raymond C., Gravier G., « Is it time to switch to Word Embedding and Recurrent Neural Networks for Spoken Language Understanding ? », *InterSpeech*, Dresde, Germany, 2015.
- Xu P., Sarikaya R., « Contextual domain classification in spoken language understanding systems using recurrent neural network », *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, p. 136-140, May, 2014.
- Yan R., Song Y., Wu H., « Learning to Respond with Deep Neural Networks for Retrieval-Based Human-Computer Conversation System », *ACM SIGIR Conference on Research and Development in Information Retrieval*, SIGIR '16, p. 55-64, 2016.
- Yin Z., Chang K., Zhang R., « DeepProbe : Information Directed Sequence Understanding and Chatbot Design via Recurrent Neural Networks », *SIGKDD' 17*, p. 2131-2139, 2017.