

Q-learning pour la résolution des anaphores pronominales en langue arabe

Saoussen Mathlouthi Bouzid¹ Chiraz Ben Othmane Zribi¹

(1) RIADI, ENSI Campus Universitaire de la Manouba, 2010 Manouba, Tunisie
Mathlouthi.saw@gmail.com, Chiraz.zribi@ensi-uma.tn

RÉSUMÉ

La résolution d'anaphores est une tâche fondamentale pour la plupart des applications du TALN. Cette tâche reste un problème difficile qui nécessite plusieurs sources de connaissances et des techniques d'apprentissage efficaces, notamment pour la langue arabe. Cet article présente une nouvelle approche de résolution d'anaphores pronominales dans les textes arabes en se basant sur une méthode d'Apprentissage par Renforcement AR qui utilise l'algorithme Q-learning. Le processus de résolution comporte une étape d'identification des pronoms et des antécédents candidats et une autre de résolution. L'algorithme Q-learning permet d'apprendre dans un environnement dynamique et incertain. Il cherche à optimiser pour chaque pronom anaphorique, une séquence de choix de critères pour évaluer les antécédents et sélectionner le meilleur. Le système de résolution est évalué sur des textes littéraires, des textes journalistiques et des manuels techniques. Le taux de précision atteint jusqu'à 77,14%.

ABSTRACT

Q-learning for pronominal anaphora resolution in Arabic texts

Anaphora resolution is a fundamental task for most NLP applications. This task remains a difficult problem that requires several sources of knowledge and effective learning techniques, especially for the Arabic language. This paper presents a novel approach to resolving pronominal anaphora in Arabic texts based on a Reinforcement Learning RL that uses the Q-learning algorithm. The resolution process includes two steps: pronoun and antecedent identification step and the resolution step. The Q-learning algorithm allows learning in a dynamic and uncertain environment. It seeks to optimize for each anaphoric pronoun, a sequence of criteria choice to evaluate the antecedents and look for the best. The resolution system is evaluated on literary texts, journalistic and technical manual texts. Precision rate reaches until 77.14%.

MOTS-CLÉS : résolution d'anaphores, apprentissage par renforcement, Q-learning, critères morphosyntaxiques, arabe.

KEYWORDS: anaphora resolution, reinforcement learning, Q-learning, morpho-syntactic criteria, Arabic.

1 Introduction

Dans les discours en langue naturelle, plusieurs moyens différents permettent la référence à des objets ou des entités. Dans certaines situations linguistiques, les répétitions des Groupes Nominaux (GNs), peuvent être réduites au pronom afin d'éviter la redondance et la lourdeur ; c'est le

phénomène d'anaphore. Ce phénomène linguistique joue un rôle important dans la construction du sens. Il met en œuvre les différentes possibilités de reprise d'un élément qui peut paraître et réapparaître dans un texte. Chaque expression anaphorique dépend d'une autre expression (appelée référence ou antécédent) qui doit être trouvée dans la partie antécédente (ou parfois suivante) du texte. Dans notre travail nous avons traité les pronoms personnels sujets et objets, les pronoms démonstratifs et les pronoms relatifs. En langue arabe, les anaphores pronominales sont variés et denses ; nos statistiques réalisés sur des textes littéraires (comme l'exemple 1) montrent que 18,2% des mots sont des pronoms. En outre, la langue arabe est une langue riche morphologiquement et présente plusieurs spécificités qui rendent la tâche de résolution plus ardue, comme expliqué dans (Mathlouthi et al., 2016).

(1) فكه عينيك بتلك البسط الخضراء التي نسجتها يد الطبيعة نفسها فتلك هي السعادة بعينها

Jouissez vos yeux de ces vallées verdoyantes qui ont été créées par la nature elle-même, c'est tout le bonheur

La tâche de résolution d'anaphores pronominales (RAP) comporte deux étapes principales : une étape préliminaire pour l'identification des pronoms et une étape de résolution. Pour l'étape de résolution, nous considérons un ensemble de critères morphosyntaxiques nécessaires pour choisir le meilleur antécédent de chaque pronom parmi la liste des antécédents possibles. A cet effet, nous proposons une approche d'apprentissage par renforcement utilisant ces critères morphosyntaxiques comme étant l'ensemble des actions à choisir pour juger le bon candidat. Le choix de l'apprentissage par renforcement est motivé par les raisons suivantes :

- En langue arabe, le manque des données de taille importante et étiquetées avec des liens anaphoriques rend parfois l'utilisation de l'apprentissage complètement supervisé assez difficile.
- L'environnement du système de résolution est dynamique, car d'une part la liste des antécédents est limitée à une fenêtre de mots, et d'autre part, les critères linguistiques et leurs pertinences peuvent changer selon le pronom et le style du texte traité.
- Le système de RAP cherche à optimiser une séquence de décisions (choix des critères) afin de trouver le meilleur antécédent candidat.

L'apprentissage par renforcement est une technique utilisée pour permettre à un agent de connaître son environnement et de savoir quand explorer et quand exploiter pour prendre une bonne décision. L'algorithme Q-learning est l'une des techniques d'apprentissage par renforcement les plus utilisées. Il réalise l'équilibre entre les processus d'exploration et d'exploitation. L'environnement de notre système de RAP est modélisé par un processus de décision de Markov (PDM) qui permet de représenter, pour chaque pronom et ses antécédents candidats, le choix des combinaisons de critères possibles.

Le présent article est composé de quatre sections. Dans la section 2, nous menons une étude comparative de l'état de l'art entre les différents travaux existants. Nous détaillons les étapes de notre approche de RAP, dans la section 3, et nous expliquons l'utilité de la méthode d'apprentissage par renforcement AR dans la tâche de résolution. Enfin, nous présentons notre corpus de test, les résultats des expérimentations réalisées et leurs comparaisons aux résultats d'un travail similaire.

2 Les travaux antérieurs

La tâche de résolution d'anaphore a été le sujet de recherche de plusieurs travaux en TALN. Les travaux peuvent être classés en quatre types d'approche : les approches à base de règles, les

approches statistiques, les approches à base d'apprentissage et les approches hybrides. Les approches à base de règles linguistiques exploitent plusieurs sources de connaissances telles que les travaux Lappin & Leass (1994), Mitkov (1998) et Schmolz et al. (2012) pour l'anglais. Le travail Mitkov (1998) a été adapté à la langue arabe dans Mitkov et al. (1998). Néanmoins, les sources de connaissances linguistiques restent insuffisantes pour résoudre la complexité de la tâche surtout pour certaines langues naturelles ayant une structure linguistique très variée comme l'arabe. En fait, les règles linguistiques sont incapables à elles seules de résoudre des ambiguïtés sémantiques voire même pragmatiques. Certains travaux se sont reposés sur des méthodes à base de calcul statistiques comme le travail de Seminck & Amsili (2017). D'autres travaux ont utilisé des méthodes d'apprentissage afin de couvrir les insuffisances des règles linguistiques. La plupart des travaux dans cette classe ont considéré la résolution comme un problème de classification et ils ont exploité les vecteurs caractéristiques des paires pronoms-antécédents. Plusieurs d'entre eux ont utilisé l'apprentissage supervisé en exploitant l'entraînement des données étiquetées comme le travail d'Aone & Bennett (1996) pour le japonais, Li et al. (2011) pour l'anglais et Aktas et al. (2018) pour la langue allemande. Toutefois, l'apprentissage supervisé nécessite des sources de données étiquetées avec des liens anaphoriques de taille importante, ce qui est parfois coûteux et difficile à réaliser pour certaines langues. Les approches basées sur l'apprentissage non-supervisé, comme le travail de Charniak & Elsnar (2009), sont moins nombreux. Ainsi, l'apprentissage permet de couvrir l'incertitude du domaine linguistique et les divers niveaux d'ambiguïtés dans les langues naturelles. Pour les approches hybrides, les auteurs ont combiné les règles linguistiques et les techniques d'apprentissage dans une seule représentation pour tirer profit de leurs avantages respectifs et pour que l'une couvre les insuffisances de l'autre. Parmi les travaux qui ont opté pour ce type d'approche sont : Weissenbacher & Nazarenko (2007), Kamune & Agrawal (2015) pour l'anglais, Abolohom & Omar (2015) et Hammami (2016) pour l'arabe. Nous déduisons que les résultats des performances pour ce dernier type d'approches, particulièrement pour certaines langues comme la langue arabe, restent toujours insuffisants et nécessitent beaucoup plus d'efforts.

3 Approche d'apprentissage par renforcement basée sur Q-learning

L'objectif de la RAP consiste à chercher le meilleur antécédent du pronom anaphorique parmi la liste des antécédents candidats. Le système de résolution comporte deux étapes principales, à savoir: l'identification et la résolution. Les pronoms sont identifiés par leurs valeurs grammaticales puis ils sont filtrés en utilisant une approche à base de règles afin d'éliminer les pronoms non-référentiels. Nous nous limitons dans ce qui suit à la présentation de l'étape de résolution, l'étape d'identification des pronoms qui inclus le filtrage des pronoms non-référentiels est décrite en détail dans (Mathlouthi et al., 2016).

3.1 Approche de résolution des anaphores pronominales à base d'apprentissage par renforcement

Notre système de résolution cherche le meilleur antécédent de chaque pronom, en utilisant des critères linguistiques qui favorisent certains candidats par rapport à d'autres. La combinaison de critères qui permet de juger le meilleur candidat de chaque pronom est inconnue au préalable et elle varie surtout avec le contexte du pronom. Nous avons ainsi opté pour une approche à base d'apprentissage par renforcement car ce dernier constitue une méthode efficace pour apprendre dans un environnement incertain et dynamique. L'environnement de notre système comporte le pronom,

ses informations morphosyntaxiques et la liste des critères linguistiques. L'agent système de résolution d'anaphores se charge d'apprendre par lui-même tout en interagissant avec son environnement. Il renforce les actions qui s'avèrent être les meilleures, et ce, dans le but de maximiser les récompenses obtenues à l'issue de chaque action. Dans l'apprentissage automatique, l'environnement est modélisé comme un PDM. Le Q-learning est introduit pour affecter la décision d'un agent afin d'explorer plus et d'améliorer sa décision. Il réalise l'équilibre entre les processus d'exploration et d'exploitation. La figure 1 décrit le processus de RAP. Le processus de résolution permet de parcourir le texte traité et d'identifier chaque fois le pronom et la liste d'antécédents correspondante. L'algorithme Q-learning utilise une matrice de récompense R et interagit avec son environnement contenant le contexte du pronom et une liste de critères. Cette matrice R est initialisée lors d'une phase de pré-apprentissage qui utilise quelques textes étiquetés. Cependant, l'algorithme Q-learning permet de trouver la combinaison de critères optimale, utilisée pour évaluer les antécédents et choisir le meilleur d'entre eux (Figure 1).

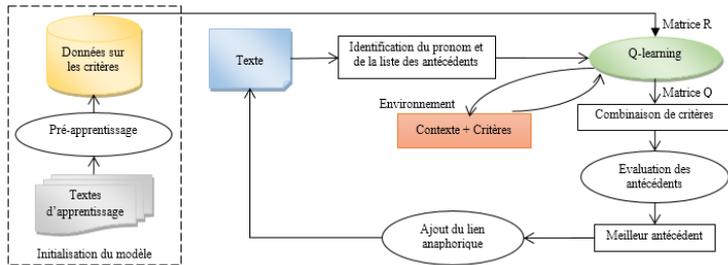


FIGURE 1 : Processus de résolution des pronoms basé sur Q-learning

3.1.1 Critères de résolution

Les critères d'évaluation des antécédents sont plus ou moins efficaces. Ils représentent des préférences et pas des facteurs absolus. Leurs pertinences dépendent du contexte du pronom anaphorique et même du style du texte et se sont des estimations de comptages réalisés sur quelques textes étiquetés anaphoriquement. Les critères « Définition », « Thème », « Distance », « Tête de paragraphe », « Nom propre » et « Répétition » sont décrites dans le travail Mathlouthi et al. (2017). Le critère « Définition » favorise les GNs définis à ceux non définis. Le critère « Thème » considère que les sujets des phrases sont préférés par rapport aux autres candidats. Le critère « Distance » considère que les candidats les plus proches sont les plus saillants. Le critère « Tête de paragraphe » favorise le candidat sujet de la première phrase du paragraphe qui reste souvent le centre d'intérêt dans un paragraphe. « Nom propre » est un critère qui favorise des éléments de discours importants. Le critère « Répétition » favorise les candidats dont les lemmes se répètent plusieurs fois dans le texte. En plus, nous avons ajouté un nouveau critère « Antécédent pronom précédent », ce critère privilégie le candidat qui a été déjà choisi comme antécédent pour le pronom précédent. En fait, dans les textes arabes littéraires, ce type de critère est bien vérifié (environ 35% des antécédents vérifient ce critère). Dans l'exemple (2) l'anaphore vérifie les critères « Définition » et « Thème ». Dans certains cas le critère peut pénaliser un antécédent correct, mais cette erreur peut être propagée ou corrigée par un autre critère. De ce fait, les critères ne participent pas nécessairement ensemble dans la résolution d'un pronom particulier. Toutefois, les critères proposés ne sont pas définitifs, ils dépendent des textes traités et peuvent être augmentés par d'autres.

(2) خرج الملك من اليمن غازيا في جيش (...). وعت سلطته مصر وافريقية

Le roi a quitté le Yémen pour la guerre avec une armée (...). L'Egypte et l'Afrique ont été soumis à son autorité

3.1.2 Approche Q-learning

Notre système de résolution est modélisé par un PDM (état, action, transition, récompense). L'ensemble des états comportent l'état initial, les états intermédiaires représentant toutes les combinaisons de critères possibles et l'état final. L'état initial S_1 du PDM contient des informations sur le pronom Pr, mais la combinaison des critères (CC) est encore inconnue. Les actions possibles sont les choix de critères. Chaque transition d'un état S_i à un autre S_j a une valeur de récompense associée r_{ij} . L'état final S_F contient la séquence d'actions optimale qui revient à la meilleure combinaison de critères. Chaque état S_i peut passer directement à l'état final S_F avec une récompense r_{iF} .

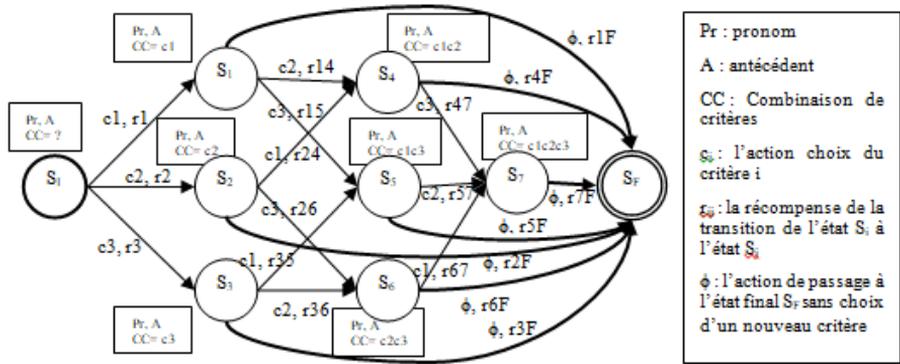


FIGURE 2 : Modélisation PDM pour la résolution des pronoms

La figure 2 montre un exemple de représentation PDM pour le cas de 3 critères. La récompense du choix de l'action c_x sur l'état S_i est calculée par la probabilité P de S_i sachant Pr et c_x . Le calcul de la probabilité se base sur la fréquence de la participation de la combinaison de critères dans la résolution des liens anaphoriques sachant le contexte de Pr. Pour le cas du passage direct d'un état S_i de contexte $\{c_y\}$ à l'état final, la récompense r_{iF} est la probabilité pour que l'ensemble de critères $\{c_y\}$ participent seuls dans la bonne résolution.

L'algorithme Q-learning utilise deux matrices Q et R. La matrice R est une matrice à deux dimensions ; les lignes représentent l'ensemble des états et les colonnes sont les actions. Les actions sont les critères c_x et l'action finale ϕ qui permet de passer directement à l'état final. Les contextes des états contiennent toutes les combinaisons de critères possibles. Pour chaque état, il y a des actions possibles (leurs récompenses sont les probabilités P décrites précédemment) et d'autres interdites (leurs récompenses valent -1). La matrice Q est initialisée à 0 et elle est mis à jour aux cours des expériences réalisées par l'agent en utilisant la matrice de récompense R. Grâce à cette matrice Q, l'agent met à jour les traces de ses décisions prises dans le passé. Il apprend par expérience et explore d'un état à l'autre jusqu'à atteindre l'objectif. Au niveau de la matrice Q finale, l'ensemble des actions optimales correspond à la meilleure combinaison de critères capable d'évaluer les antécédents du pronom en question. L'algorithme Q-learning procède comme suit :

Début

1. Initialiser les paramètres alpha α , gamma γ et le nombre d'épisode maximale E_{max} ,
2. Définir les récompenses de l'environnement dans la matrice R.
3. Initialiser la matrice Q à 0.

4. Pour chaque épisode :

Sélectionner un état initial aléatoire S_i .

Tant que l'état final est non atteint.

a. Sélectionner l'une des actions possibles c pour l'état actuel.

b. Obtenir, à partir de la matrice Q , la valeur Q maximale pour l'état suivant S_{i+1} en fonction de toutes les actions possibles.

c. Mettre à jour la matrice Q :

$$Q(S_i, c) \leftarrow Q(S_i, c) + \alpha * [R(S_i, c) + \gamma * \text{Max}_{c \text{ dans } C}(Q(S_{i+1}, c))]$$

d. Définir l'état suivant comme état actuel.

Fin Tant que

Fin Pour

5. Parcourir la matrice Q finale ; à partir de l'état initial, trouver les actions avec les valeurs de Q les plus élevées jusqu'à atteindre l'état final.

Fin

Le cœur de l'algorithme est une mise à jour de la fonction de valeur (action-état) représentée par $Q(S_i, c)$. A chaque choix d'un critère c , l'agent observe la récompense $R(S_i, c)$ et le nouvel état S_{i+1} et met à jour la matrice Q . Les paramètres α et γ ont une plage de 0 à 1 ; α est un facteur d'apprentissage, il contrôle le taux de mise à jour, γ est un facteur d'actualisation pour modérer l'effet des récompenses futures.

3.2.3. Evaluation des antécédents

L'algorithme Q-learning permet de sélectionner la meilleure combinaison de critères CC pour chaque pronom Pr . D'autre part, chaque antécédent candidat A vérifie un ensemble de critères. En fait, notre but est de donner un score à chaque antécédent pour pouvoir l'évaluer. Le score d'un antécédent dépend de la pertinence des critères CC vérifiés. Si l'antécédent A_i vérifie le critère c ($Verif(A_i, c)=1$) alors son score augmente en ajoutant la pertinence sinon son score diminue ($Verif(A_i, c)=-1$). Les scores d'évaluations permettent de juger le meilleur antécédent. Le score d'évaluation calculé pour chaque antécédent est décrit par la formule (3).

$$score_{Eval} = \sum_{\forall c \in CC} (Verif(A, c) * Pertinence(c)) \quad (3)$$

4 Expérimentations et résultats

Afin d'évaluer la performance de l'approche, nous avons réalisé plusieurs expérimentations sur un corpus de textes variés. Le corpus est composé de textes littéraires présentés dans le livre scolaire de la 8^{ème} année de base de l'enseignement tunisien, et aussi des textes journalistiques et des manuels techniques extraits du web. Ce corpus contient 4201 mots et 436 pronoms dont 409 sont référentiels. La phase de pré-apprentissage utilise des textes d'entraînement contenant 5196 mots et 638 pronoms. En fait, le simulateur implémenté prend comme paramètre d'entrée des textes d'entraînement de même type que le texte traité. Notons que le corpus d'entraînement est utilisé juste pour initialiser le modèle mais n'intervient pas lors de la phase d'apprentissage par renforcement. Notre système a réussi à détecter tous les pronoms anaphoriques et à les identifier selon leurs types. Il couvre toutes les anaphores considérées dans la résolution et génère une liste de candidats non vide pour la plupart des pronoms. Afin de mieux apprécier l'approche proposée, nous avons implémenté et adapté l'approche robuste de Mitkov et al. (1998) (qui a pu atteindre des bons résultats) et nous l'avons évaluée sur nos textes de test afin de comparer les résultats. Nous avons choisi l'ensemble des critères de préférences proposés par Mitkov qui s'adaptent à la langue arabe à savoir , « Définition », « Thème », « Distance » et « Tête de paragraphe » et nous l'avons augmenté

par nos critères « Nom propre », « Répétition » et « Antécédent pronom précédent ». Nous avons utilisé les pertinences (-1, 0, 1, 2) que Mitkov a attribué à ces critères. La Table 1 présente les résultats d'évaluation de notre approche sur des textes littéraires, des manuels techniques et des textes journalistiques. L'approche de Mitkov a été testée également sur les mêmes textes.

Textes		Textes littéraires	Textes manuels techniques	Textes journalistiques
Taille	Nombre mots	1615	1714	872
	Nombre pronoms	218	136	82
Approche Q-learning		70,11%	72,8%	77,14%
Approche Mitkov		64,67%	53,04%	50%

TABLE 1 : Précisions de l'approche Q-learning et celle de Mitkov

En comparant les résultats de notre approche à ceux de Mitkov, nous avons déduit l'efficacité de l'approche Q-learning. Cette dernière donne des résultats meilleurs que celle de Mitkov pour tous les types de textes traités. La précision pour que l'antécédent ait la position n°1 atteint un taux de 77,14%, nous considérons que ces résultats sont encourageants. Pour mettre en évidence une amélioration possible des résultats, nous avons présenté dans la figure 3 la précision selon la position de l'antécédent correct. Si l'antécédent figure parmi les deux premiers candidats (respectivement les trois premiers candidats), alors la précision peut atteindre 84,29% pour les textes journalistiques (respectivement 87,7% pour les textes manuels techniques).

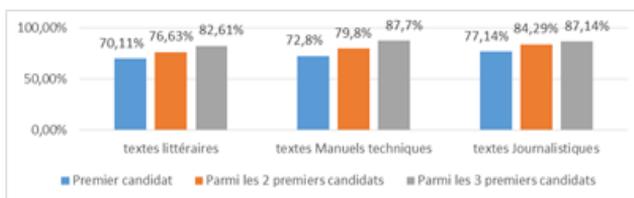


FIGURE 3 : Position de l'antécédent correct parmi la liste des antécédents candidats

5 Conclusion

Cet article présente une nouvelle approche de résolution des anaphores pronominales en langue arabe. L'approche basée sur l'apprentissage par renforcement utilise la méthode Q-learning et exploite un ensemble de critères linguistiques. En effet, notre système est modélisé par un PDM qui représente la séquence des critères possibles. L'algorithme Q-learning cherche la combinaison de critères avec les valeurs de récompense les plus élevées. Cette combinaison de critères est utilisée pour évaluer les antécédents et en sélectionner le meilleur. Comme futurs travaux, nous visons agrandir notre corpus de textes journalistiques et de manuels technique afin de réaliser plus d'expérimentations. Nous projetons également d'ajouter des critères sémantiques capables d'améliorer les résultats.

Références

Mitkov R. (1998). Robust pronoun resolution with limited knowledge. Montreal, Canada: Proceedings of the 18.th International Conference on Computational Linguistics (COLING' 98)/ACL' 98.

- Mitkov R., Belguith L., Stys M. (1998). Multilingual robust anaphora resolution, Granada, Spain.
- Schmolz H., Coquil D., Döllner M. (2012). In-Depth Analysis of Anaphora Resolution Requirements. 2012 23rd International Workshop on Database and Expert Systems Applications. Vienna, Austria.
- Seminck O., Amsili P. (2017). A Computational Model of Human Preferences for Pronoun Resolution. Proceedings of the Student Research Workshop at the 15th Conference of the European Chapter of the Association for Computational Linguistics, pages 53–63, Valencia, Spain.
- Ashima A., Mohana B. (2016). Improving Anaphora Resolution by Resolving Gender and Number Agreement in Hindi Language using Rule based Approach. Indian Journal of Science and Technology, Vol 9(32), august 2016.
- Aone C., Bennet S. (1995). Applying machine learning to anaphora resolution. International Joint Conference on Artificial Intelligence IJCAI 1995: Connectionist, Statistical and Symbolic Approaches to Learning for Natural Language Processing pp 302-314, 1995.
- Elghamry K., Al-Sabbagh R., El-Zeiny N. Arabic Anaphora Resolution Using Web as Corpus. Proceedings of the seventh conference on language engineering, pp. 1-18. Cairo, Egypt, 2007.
- Weissenbacher D., Nazarenko A. (2007). A bayesian classifier for the recognition of the impersonal occurrences of the it pronoun. In Proceedings of DAARC'07, 2007. 29, 32, 43, 72, 120.
- Hammami S. (2016). La résolution automatique des anaphores pronominales pour la langue arabe, thèse de doctorat, Université de Sfax, Faculté des Sciences Economiques et de Gestion, Sfax, Tunisie.
- Mathlouthi S., Ben Fraj Trabelsi F., Ben Othmane Zribi C. (2016). A Novel Approach Based on Reinforcement Learning for Anaphora Resolution. 28th IBIMA Conference, November 2016.
- Mathlouthi S., Ben Fraj F., Ben Othmane C. (2017). How to combine salience factors for Arabic Pronoun Anaphora Resolution. 2017 IEEE/ACS 14th International Conference on Computer Systems and Applications.
- Lappin S., Leass H. J. (1994). An Algorithm for Pronominal Anaphora Resolution. London, Computational Linguistics, 20(4), 535-561.
- Li D., Miller T., Schuler W. (2011). A pronoun anaphora resolution system based on factorial hidden markov models. In *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics, Portland, Oregon, June 19-24*, page 1169–1178, 2011. 42, 115.
- Aktas B., Scheffler T., Stede M. (2018). Anaphora Resolution for Twitter Conversations: An Exploratory Study. Proceedings of the Workshop on Computational Models of Reference, Anaphora and Coreference, pages 1–10. New Orleans, Louisiana, June 6, 2018.
- Charniak E., Elsnar M. (2009). EM works for pronoun anaphora resolution. In Proceedings of EACL, pp. 48-156.
- Kamune K., Agrawal A. (2015). Hybrid Approach to Pronominal Anaphora Resolution in English Newspaper Text. International Journal of Intelligent Systems and Applications, 02: pp. 56-64. Published Online January 2015 in MECS. DOI: 10.5815/ijisa.2015.02.08.
- Abolohom A., Omar N. (2015). A Hybrid Approach to Pronominal Anaphora Resolution in Arabic, Journal of Computer Sciences 11(5): 764-71 DOI: 10.3844/jcssp.2015.764.771.