

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement supérieur et de la Recherche Scientifique

Université d'Alger 2

Faculté des Lettres et des Langues - Département de Linguistique

MEMOIRE DE MAGISTER

INFORMATIQUE LINGUISTIQUE-

SCIENCES DU LANGAGE ET DE LA COMMUNICATION LINGUISTIQUE

OPTION : TRAITEMENT AUTOMATIQUE DU LANGAGE

*Résolution d'anaphores pronominales de la langue
arabe par apprentissage automatique*

Présenté par : **Leïla NOURI**

Jury

M ^r	A. SALMI	Docteur à l'université d'Alger	Président
M ^r	A. GUESSOUM	Professeur à l'USTHB	Encadreur
M ^{me}	H. ALIANE	Chargée de Recherche au CERIST	Examinateuse
M ^{me}	L. MAHDAOUI	Maitre de conférences à l'USTHB	Examinateuse

Année universitaire 2011/2012

Remerciements

الحمد والشكر لله تعالى

Je tiens à exprimer ma profonde gratitude et mes sincères remerciements au Professeur Ahmed GUESSOUM pour m'avoir proposée ce sujet, pour sa disponibilité et pour ses précieux conseils.

Mes remerciements s'adressent aussi au président du jury Dr Abdelmadjid SALMI et aux membres du jury Dr Hassina ALIANE et Dr Latifa MAHDAOUI, pour leur disponibilité à évaluer le présent mémoire et leur participation au jury de soutenance.

Mes vifs remerciements vont aussi à ma famille, mes amis, et mes collègues du CERIST, qui m'ont toujours soutenue et encouragée au cours de la réalisation de ce mémoire.

ملخص البحث

العائد هو كلمة لها سابقة أو عدة سوابق في النص. حل العائد في اللغة العربية بواسطة التعلم الآلي هو إيجاداً بطريقة آلية سابقة العائد باستعمال كم هائل من الأمثلة النصية للعملية.

في الواقع، تواتر تواجد العوائد في نصوص اللغة العربية كبير جداً، الأمر الذي يشكل إشكالية حقيقة للعلاج الآلي للمعطيات النصية، مثل التخخيص الآلي أو استرجاع المعلومات، أو الرد على استعلام في نظم حوار بين الإنسان والآلة، الخ.

ويعتبر التعلم التلقائي للشبكات العصبية واحدة من الحلول المثيرة للاهتمام لحل العائد.

في هذا العمل قمنا بدراسة مسألة حل العائد في اللغة العربية وقدمنا حلًا لمعالجته حاسوبياً عن طريق تحشية مدونة وشفيرها ألياً، ثم استعمالها داخل الشبكات العصبية باستخدام الشبكة ذات طبقات متعددة بطريقة التغذية الأمامية واستخدام خوارزمية الانتشار الخلفي (للتصحيف داخل الشبكة).

الكلمات الدالة : العائد، حل العائد، اللغة العربية، تحشية المدونة، وسم، الشبكات العصبية، الشبكة ذات الطبقات المتعددة الأمامية

Résumé

Une anaphore est un mot qui a obligatoirement un ou plusieurs antécédents qui lui réfèrent dans un énoncé. L'objectif de la résolution d'anaphores pronominales de la langue arabe par apprentissage automatique est de trouver de façon informatisée l'antécédent d'une anaphore et ce par apprentissage sur un maximum d'exemples de textes.

En effet, la fréquence d'apparition des anaphores dans un texte arabe est très grande, ce qui pose un problème pour un traitement automatique des données textuelles, tel que l'élaboration d'un résumé de texte ou d'une recherche d'information, ou pour répondre à une requête dans les systèmes de dialogue homme-machine, etc.

L'apprentissage automatique des réseaux de neurones est considéré comme une des solutions intéressantes pour la résolution d'anaphores.

Dans ce travail, nous nous intéressons à la résolution d'anaphores de la langue arabe sur un corpus annoté et codifié automatiquement, soumis à l'apprentissage des réseaux de neurones en utilisant le perceptron multi-couches selon l'algorithme de la rétro-propagation du gradient.

MOTS-CLÉS : *anaphores, résolution d'anaphores pronominales, langue arabe, annotation, étiquettes, corpus, réseaux de neurones, perceptron multi-couches.*

Abstract

An anaphora is a word that has one or more antecedents that refer to it in a sentence or paragraph. The objective of pronominal anaphora resolution is to find the antecedent of an anaphora in a computerized way based on the use of as large a corpus of examples of manual anaphora resolution as possible.

Indeed, the frequency of occurrence of anaphora in arabic text is very large, which turns out to be an issue that needs to be handled before automatic of textual data, so as to develop quality automatic text summaries information retrieval, or query answers in human-machine dialogue systems.

Automatic training of neural networks is considered as one of the interesting solutions for the resolution of anaphora.

In this work, we are interested in anaphora resolution of the arabic language on an automatically annotated and coded corpora, and a neural network which is trained as a feed-forward multilayer perceptron with backpropagation.

KEYWORDS : *anaphora, anaphora resolution, corpora, arabic language, annotation, tags, neural networks, multilayer perceptron.*

Sommaire

Liste des Figures

Liste des Tableaux

Introduction Générale.....	i
1. Introduction	ii
2. Objectif du mémoire	iii
3. Organisation du mémoire	iii

CHAPITRE 1 : Traitement Automatique du Langage Naturel 5

1. Introduction	5
2. Les domaines d'application du TALN	6
2.1 Recherche d'Information	6
2.2 Extraction d'Information	7
2.3 Systèmes Question-Réponse	7
2.4 Systèmes de résumé automatique de textes.....	8
2.5 Traduction automatique.....	8
2.6 Dialogue homme-machine	8
2.7 Génération automatique de textes	9
3. Difficultés et ambiguïtés du TALN	9
3.1 Ambiguité morphologique	9
3.2 Ambiguité Syntaxique	9
3.3 Ambiguité sémantique et pragmatique.....	10
4. Conclusion.....	10

CHAPITRE 2 : La Résolution d'anaphores pronominales 11

1. Introduction	11
2. L'anaphore	12
3. L'anaphore vs La coréférence	13
4. La typologie des anaphores dans la langue arabe	13

4.1 L'anaphore pronominale	13
4.1.1 Les pronoms personnels	13
4.1.2 Les pronoms relatifs	15
4.1.3 Les pronoms démonstratifs	16
4.2 L'anaphore lexicale	16
4.3 L'anaphore comparative	17
4.4 L'anaphore verbale	17
5. Le processus général de la résolution d'anaphores	17
5.1 Les connaissances morphologiques et lexicales	18
5.2 Les connaissances syntaxiques	18
5.3 Les connaissances sémantiques et pragmatiques	18
6. Les mesures d'évaluation dans les systèmes de résolution d'anaphores	19
7. Difficulté de la résolution des anaphores	21
8. Les différentes approches de la résolution d'anaphores pronominales	22
8.1 Présentation	22
8.2 L'approche basée sur la syntaxe	23
8.2.1 L'algorithme de Hobbs	23
8.2.2 Avantages et inconvénients de l'algorithme de Hobbs	24
8.3 L'approche basée sur le discours	24
8.3.1 La Théorie du Centrage	24
8.3.2 L'algorithme BFP	26
8.3.3 Avantages et inconvénients de la Théorie du Centrage	28
8.4 L'approche basée sur le facteur	28
8.4.1 Lappin et Leass	29
8.4.2 Kennedy et Boguraev	30
8.4.3 GogNIAC de Baldwin	30
8.4.4 L'approche de Mitkov	31
8.5 Les approches basées sur l'apprentissage automatique	35
8.5.1 Aone et Bennett, McCarthy et Lehnert	36
8.5.2 Connolly et al.	36
8.5.3 Cardie et Wagstaff	38
8.5.4 Soon et al.	38
8.5.5 Strube et al.	39
8.6 Les approches statistiques	40

8.7 Autres approches	40
9. Les domaines d'application de la résolution d'anaphores.....	42
9.1 La résolution d'anaphores dans l'extraction d'information	42
9.2 La résolution d'anaphores dans le résumé automatique du texte	43
9.3 La résolution d'anaphores dans la traduction automatique.....	44
9.4 La résolution d'anaphores dans les systèmes question-réponse.....	44
10. La résolution des anaphores pronominales dans la langue arabe	45
10.1 L'approche multilingue de Mitkov	45
10.2 La résolution d'anaphores dans l'Arabe utilisant le web comme corpus.....	46
11. Conclusion	46
 CHAPITRE 3 : Introduction aux réseaux de neurones.....	47
1. Introduction	47
2. Neurone Formel.....	47
3. Réseau de Neurones	49
4. Architecture des réseaux de neurones.....	49
4.1 Le perceptron monocouche	49
4.2 Le perceptron multi-couches	50
4.3 Les réseaux à fonction radiale de base	51
5. Apprentissage des réseaux de neurones	53
5.1 Apprentissage supervisé	53
5.2 Apprentissage non-supervisé.....	55
5.3 Apprentissage par renforcement.....	55
6. Styles d'apprentissage	55
6.1 Batch training	56
6.2 Incremental training	56
7. Avantages et inconvénients des réseaux de neurones	55
8. Conclusion.....	56
 CHAPITRE 4 : Annotation du corpus	58
1. Introduction	58
2. Caractéristiques morphologiques de l'Arabe	59
3. Etiquetage morphosyntaxique (POS Tagging).....	60
4. Outil d'étiquetage du corpus.....	60

4.1 SAIE POS-Tagger	61
4.2 Outil d'annotation et codification d'un corpus en langue Arabe (ANCARTool)	61
5. Conclusion.....	62
 CHAPITRE 5 : Approche pour la résolution d'anaphores de la langue arabe	64
1. Introduction	64
2. Codification du corpus.....	65
3. Description du Réseau de neurones	70
3.1 Le corpus d'apprentissage.....	71
3.2 Création du perceptron multi-couches	71
3.3 Apprentissage du perceptron multi-couches	72
3.3.1 Fonction d'apprentissage.....	73
4. Résultats d'apprentissage du perceptron multi-couches	73
5. Interprétation des résultats	75
5.1 Algorithme d'interprétation des résultats	76
5.2 Evaluation des résultats	79
6. Conclusion.....	80
 Conclusion & Perspectives	81
Références Bibliographiques	81
Annexe	92