



Natural Language Processing

Morphology

Mustafa Jarrar

Birzeit University



Watch this lecture and download the slides



Course Page: <http://www.jarrar.info/courses/NLP/>
More Online Courses at: <http://www.jarrar.info>


Acknowledgement:

This lecture is based on (but not limited to) to the lecture notes found in [.....]

Natural Language Processing

Morphology

In this lecture:

- 
- Part 1: **What is morphology**
 - Part 2: Lexeme and Lemma
 - Part 3: Stem and affixes
 - Part 4: Part-of-Speech

What is Morphology

التصريف

The study of how words are formed

Words are made up of smaller meaning-bearing units (morphemes).

Morpheme: smallest meaningful unit of a word. Morphemes can be: stems, suffixes, prefixes ...)

المدرسين
سيكتبها

Books
Unliked

Morphology is the identification, analysis, and description of the morphemes of a given word, including its root, part-of-speech, gender, number, etc.

Types of Morphology : **Inflectional Morphology** and **derivational morphology**

Inflectional Morphology (تصريف)

Modifying words to express **different grammatical categories** (gender, number, voice, mood, aspect, case, etc.)

forming new wordforms without changing its core meaning.

Verbs

كتب

كتبت، كتبها،
سأكتبها، يكتب،
أكتب، يكتبون،
سيكتبها، وسيكتبها

....

Write

writes, wrote,
writing

Nouns

عالم

عالمة، عالمين،
عالمتين، علماء،
عالمات
وعلمائنا
بعلمائكما

...

Scientist

Scientists

Inflectional Morphology will be the focus of this this lecture

Derivational Morphology (اشتقاق)

Modifying words to express **different meaning and/or part-of-speech** forming a new lemma (i.e., drive lemma from another lemma)

كتب	write
كتابة	writing
كاتب	writer
مكتوب	weakness
مكتبة	weaken
مكتب	reddish
كتيب	relational
كاتبة	relationally
	testify
	eatable
	guidance

English Derivational Morphology (الاشتقاق بالإنجليزية)

Examples of derivational patterns in English

verb-to-noun (agent):	er	write → writer
verb-to-adjective:	able	eat → eatable
verb-to-noun:	ance	guide → guidance
noun-to-adjective:	al	relation → relational
noun-to-verb:	fy	test → testify
adjective-to-noun:	ness	weak → weakness
adjective-to-verb:	en	weak → weaken
adjective-to-adjective:	ish	red → reddish
adjective-to-adverb:	ly	relation → relationally
....

Arabic Derivational Morphology (الاشتقاق بالعربية)

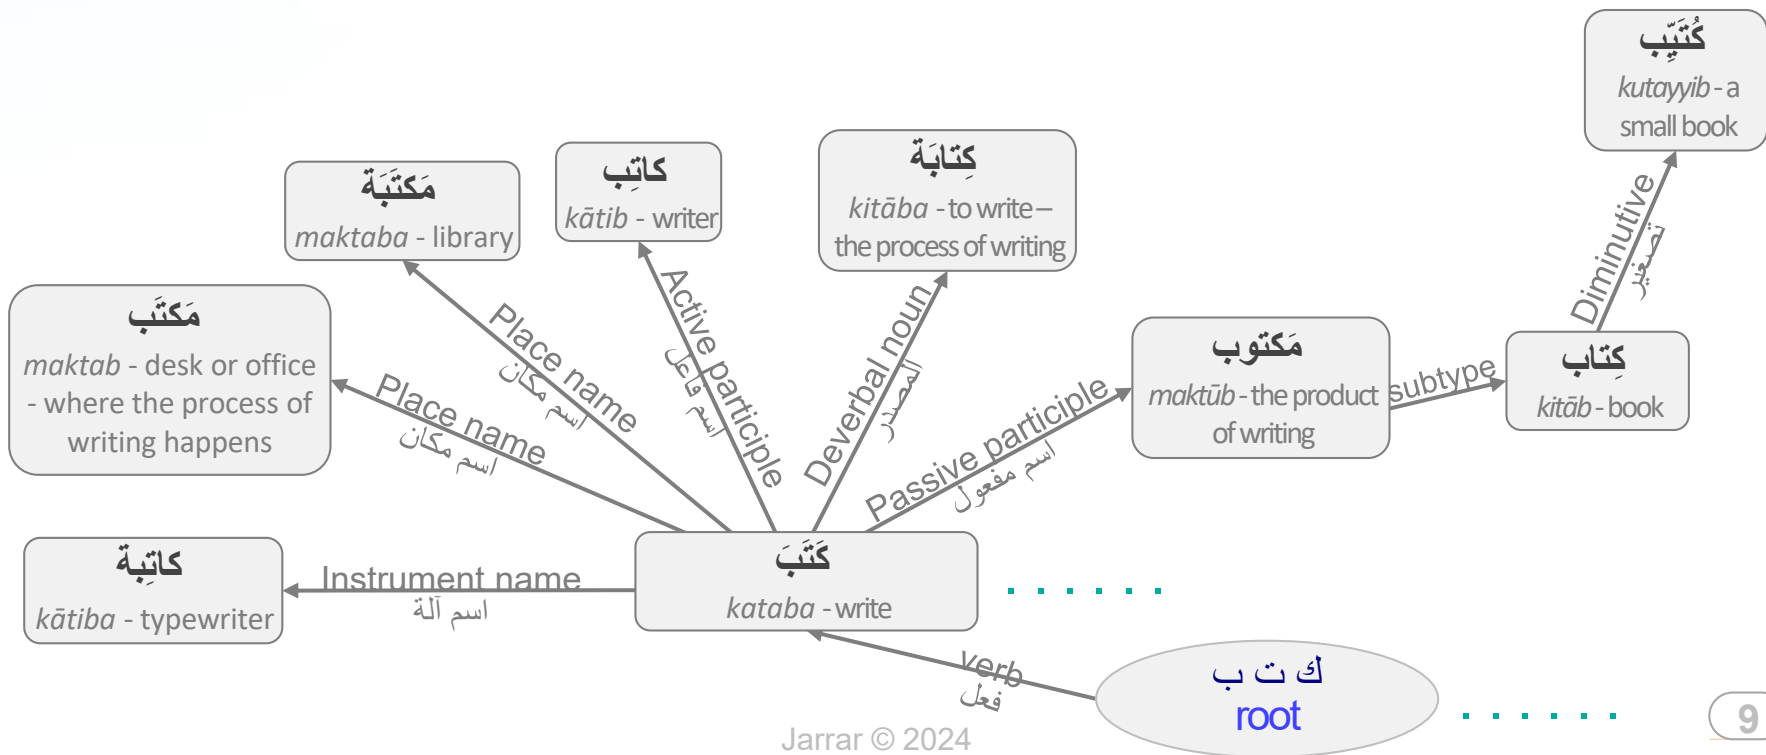
Derivational morphology in Arabic is

- mostly templatic and follows derivational patterns (أوزان اشتقاقية).
- changes the meaning (morpho-semantic category) rather than part-of-speech
- Examples:

فعل	كتب
مصدر أصلي	كتابة
اسم فاعل	كاتب
مبالغة اسم فاعل	كُتِّيب
اسم مفعول	مكتوب
اسم مكان	مكتبة
اسم مكان	مكتب
تصغير	كتَّيب
اسم آلة	كاتبه
...

Arabic Derivational Morphology (الاشتقاق بالعربية)

- Derivational morphology in Arabic can be seen as **morpho-semantic relationships** between lemmas (some are through a sense), as suggested in ([Jarrar, 2021](#)).
- A large graph of Arabic morpho-semantic relationships is available at ([Jarrar & Amayreh, 2019](#)).
- Example (simplified, some relations should be rough a sense):



Natural Language Processing

Morphology

In this lecture:

- ❑ Part 1: What is Morphology
- ❑ Part 2: **Lexeme and Lemma**
- ❑ Part 3: Stem and affixes
- ❑ Part 4: Part-of-Speech



Lexeme (الكسيم/وحدة صرفية)

Lexeme: lexical meaning for a **set of words** that related through inflections

Verb Lexemes:

{write, writes, wrote, writing}

{كتب، كتبت، يكتب، أكتب، كتبها، سأكتبها، يكتبون، وسيكتبها ...}

Noun Lexemes:

{scientist, scientists}

{عالم، عالمة، عالمين، عالمتين، علماء، عالمات، وعلمائنا، ...}

Lemma (مدخلة معجمية)

Lemma: is the dictionary form (also called canonical form and citation form) of a set of inflections (i.e., to represent a lexeme).

One of the words in the lexeme is selected **conventionally/اصطلاحا** to refer to a lexeme.

Verb lemmas: typically the past singular masculine 3rd form (الماضي المفرد المذكر الغائب)

{write, writes, wrote, writing}

{كتب، كتبت، يكتب، أكتب، كتبها، سأكتبها، يكتبون، وسيكتبها ...}

Noun Lemmas: typically the singular form (المفرد)

{scientist, scientists}

{عالم، عالمة، عالمين، عالمتين، علماء، عالمات، وعلمائنا، ...}

Lemma (مدخلة معجمية)

Issues about lemmas

Since lemmas are chosen (**conventionally/اصطلاحاً**) lexicons do not necessarily agree on them:

- Some lexicons split lemmas based on the common-use (شيوخ الاستخدام)
 - **include feminine and masculine forms** as separate lemmas, like (أشهب -) (شهباء - قاصر - قاصرة) ... if all are commonly used
 - **feminine forms if no masculine** like (تفاحة, جامعة)
 - **Plural or dual forms** (مُدْهَبَات، تسعينيات، تخوم) or (اثنان، أخبثان) if the singular forms is not common.
- Some lexicons **split lemmas if they are semantically very different**, like in SAMA (1-جامعة) and (2-جامعة) while Ghani consider it one.

Lemmatization Examples

Word	Lemma
وسيكتبها	كَتَبَ
إكتبلي	كَتَبَ
مكتباتهم	مَكْتَبَةٌ
مكاتبكم	مَكْتَبٌ
بمكتباتكن	مَكْتَبَةٌ
فكتابها	كِتَابٌ
كِتَابِي	كِتَابٌ
كُتِّبْنَا	كُتِّبَ
فكِتاباتنا	كِتَابَةٌ
بكتبة	كَاتِبٌ
وكتابهم	كَاتِبٌ
كُتِبَ	كِتَابٌ

Word	Lemma
أبيات	بَيْتٌ 2
بيوت	بَيْتٌ 2 بَيْتٌ 1
هذا	هَذَا
هذه	هَذَا
هؤلاء	هَذَا
بكم	بِ 2
لكم	لِ 2
على	عَلَى 2
عليكن	عَلَى 2

Lemmatization

Lemmatizer: a program that returns the lemma of a given word/sentence

<https://sina.birzeit.edu/alma>



SinaLab

[News](#) [Team](#) [Resources](#)

ALMA (الأمي)

Arabic Morphology Tagger

Lemmatizer, POS tagger, and root tagger.

Accuracy: POS (93.8%), lemmatization (90.48%), and speed (32K tokens/second). Outperformed all other tools (see [article](#)).

أسرع المحللات الصرفية العربية وأكثرها دقة، وهو محلل مفتوح المصدر. يتم تحديد المدخلة المعجمية وقسم الكلام والجذر لكل كلمة في النص.

Morph Tagger

Lemmatizer

POS Tagger

- Downloads

Download [SinaTools](#) (Morph Module), you can also access ALMA memory (morphological solution ordered by frequency) which is part of SinaTools.

Lemmatization

Lemmatizer: a program that returns the lemma of a given word/sentence

<https://sina.birzeit.edu/alma>



The screenshot displays the SinaLab website interface. At the top left is the SinaLab logo, a stylized atom with four colored spheres (orange, green, blue, red) around a central grey sphere. To its right is the text "SinaLab". Further right are navigation links for "News", "Team", and "Resources". Below the header, the main content area features the title "ALMA أَلْمَى" and the subtitle "Arabic Morphology Tagger". Underneath, it describes the tool as a "Lemmatizer, POS tagger, and root tagger." and provides accuracy statistics: "Accuracy: POS (93.8%), lemmatization (90.48%), and speed (32K tokens/second). Outperformed all other tools (see [article](#)).". A text input box contains the Arabic sentence: "أسرع المحللات الصرفية العربية وأكثرها دقة، وهو محلل مفتوح المصدر. يتم تحديد المنخلة المعجمية وقسم الكلام والجزر لكل كلمة في النص." Below the input box are three buttons: "Morph Tagger", "Lemmatizer", and "POS Tagger". At the bottom, there is a "Downloads" section with a link to "Download SinaTools (Morph Module)".

Qabas

Open-source Lexicographic Database

<https://sina.birzeit.edu/qabas>

عربي | English

About



Search for a term ...

Most Commonly Used Words: [كلمة](#) . [معجم](#) . [قيس](#) .

Browse: [Ontology Tree](#)



Copyright © 2024 Birzeit University

Jan 2024

Qabas

Open-source Lexicographic Database

كلمات

ع | En

Translations Synonyms Definitions

Ontology Dictionaries Qabas lexicon About

(0.01 secs)

كَلِمَةٌ | كَلِمَةٌ

اللغة: فصحي حديثة

قسم الكلام: اسم

العدد: مفرد

الجذر: ك ل م

الجنس: مؤنث

معاني و مدخلات في المعاجم العربية

سياقات في مدونات نصية

+ كَلِمَةٌ | كَلِمَةٌ (معجم المعاصرة)

+ كَلِمَةٌ 1 (معجم سما)

- كلمة (المعجم الفلسفي)

○ في اللاهوت المسيحي ، الكلمة Le Verba هي الشخص الثاني في الثالوث المسيحي : الأب والابن والروح القدس.

مترادفات: كلمة word

○ عند مالبرانش : كلمة الله هي المبدأ الإلهي والعقل الكلي الذي تنطوي في جوهره الحقائق كلها .

مترادفات: كلمة word

○ عند المتصوفة: ما يكتفي به عن الماهيات والحقائق الأزلية الثابتة ، وكلمة 'الحضرة'هي صورة الإرادة الكلية ، وتشير إلى 'كن'في قوله تعالى 'إنما أمره إذا أراد شيئا أن يقول له كن فيكون'.

مترادفات: كلمة word

- كَلِمَةٌ (الأنطولوجيا العربية)

○ تعبير كتابي للإشارة أو الدلالة على معنى

مترادفات: كلمة word كلمة word form

- كَلِمَةٌ (الأنطولوجيا العربية)

<https://sina.birzeit.edu/qabas>



Search for a term ...



Translations Synonyms Definitions

Ontology Dictionaries **Qabas lexicon**

About

معجم قيس الحاسوبي

معجم قيس يتكون من 58,000 مدخلة و تم ربطه ب 110 معاجم و 10 مدونات نصية

ربط 10 مدونات نصية

تم ربط مدخلات 10 مدونات نصية بمدخلات قيس

مدخلات مقابلة في 110 معاجم

تم ربط مدخلات 110 معاجم بمدخلات قيس

أخبار



MoU with ALECSO to digitize 50 dictionaries



Digitize dictionaries of the Academy of the Arabic language-Cairo



Shoman Arab Researchers Award



Bin Rashid's Arabic Language Award

More News

إحصائيات

إحصائيات للمدونات التي تم ربطها مع قيس

إحصائيات للمعاجم التي تم ربطها مع قيس

إحصائيات حسب قسم الكلام

- عن المعجم
- أخبار
- إحصائيات
- مقدمة المعجم
- شمولية معجم قيس
- مميزات تطوير المعجم
- فلسفة المعجم
- المصادر اللغوية
- الدليل المعياري
- تصنيف المدخلات
- أسئلة شائعة
- حقوق الملكية
- تنزيل قيس

Natural Language Processing

Morphology

In this lecture:

- ❑ Part 1: What is Morphology
- ❑ Part 2: Lexeme and Lemma
- ❑ Part 3: **Stem and Affixes**
- ❑ Part 4: Part-of-Speech



Root and Stem

Root (جذر): is the primary lexical unit of word, and which carries aspects of semantic content.

- Roots in Arabic are **decided by linguists** (who sometimes disagree).
- Some words may have more than one root, سنة (س ن ي) (س ن و)

Stem (ساق): is the part that is common to all its inflected variants (no agreed definition), thus it **depends on the stemming algorithm**.

Roots and Stems in English are most likely the same, but in Arabic Roots and Stems are not the same.

Examples:

Word	Lemma	Root	Stem
سيكتبها	كَتَبَ	ك ت ب	كتب
مكتباتهم	مَكْتَبَةٌ	ك ت ب	مكتب
مكاتبكم	مَكْتَبُ	ك ت ب	مكاتب
كتابي	كِتَابٌ	ك ت ب	كتاب

Inflectional Affixes (زوائد صرفية)

Prefixes (سوابق): attached before the stem to form a word form.

يكتب، سيكتب، وسيكتب، الكتاب، فكتب، أكتب، كالكتاب،

Suffixes (لواحق): attached after the stem to form a word form.

books, book**ed**, happ**iness**, usual**ly**, help**ful**, ...
كتبت، كتبها، كتبك، كتبكم، كتبكما، كتبهن،

Infixes (أواسط): inserted inside the stem to form a word form.

اجتهد، ابتاع، ...

Stemmer: a program that returns the stem of a given word, after removing affixes.

Prefixes (سوابق)

attached after the stem to form a word form
يكتب، سيكتب، وسيكتب، الكتاب، فكتب، أكتب، كالكتاب

In English:

- There are **no inflectional prefixes**;
- English uses suffixes to generate inflectional forms.
- Prefixes are derivational prefixes thus these words are new lemmas, not-inflections, such as (unhappy, asymmetric, demotivate, bilingual, cooperation, disappear, illegal...)

In Arabic:

Very complex and rich - 174 prefix types (115 un diacritized) in SAMA, such as:

أ، ال، ب، بال، ف، فأ، فاء، فال، فب، فبال، فك، فكال، فل، فلا، فلاأ، فلاا، فلان، فلات، فلاي، فلاأ، فلال، فلن، فلت، فلي، فلاأ، فمأ، فماء، فمان، فمات، فمائي، فمأ، فن، فسأ، فساء، فسن، فست، فسي، فسأ، فت، في، فأ، ك، كال، ل، لأ، لا، لاأ، لاا، لان، لات، لاي، لاأ، لل، لن، لت، لي، لأ، ماء، مان، مات، ماي، مأ، ن، سأ، ساء، سن، ست، سي، سأ، ت، و، وأ، وا، وال، وب، وبال، وف، وك، وكال، ول، ولأ، ولا، ولاأ، ولاا، ولان، ولات، ولاي، ولاأ، ولل، ولن، ولت، ولي، ولأ، وماأ، وماا، ومان، ومات، ومائي، وماأ، ون، وسأ، وساء، وسن، وست، وسي، وسأ، وت، وي، وآ، ي، آ،

Natural Language Processing

Morphology

In this lecture:

- ❑ Part 1: What is Morphology
- ❑ Part 2: Lexeme and Lemma
- ❑ Part 3: Stem and affixes
- ❑ Part 4: **Part-of-Speech (Short Overview)**



Part-of-Speech (اقسام الكلام)

Also called **word class**, **lexical class**, and **lexical category**

a category of words that have similar grammatical properties.
Words have the same POS have similar syntactic behavior, and sometimes similar morphology

In **English**:

noun (e.g., book)
verb (e.g., booked)
adjective (e.g.,)
adverb (e.g., very, quite)
pronoun (e.g., he, them)
preposition (e.g., in, of)
conjunction (e.g., and, but)
interjection (e.g., ops, alas)
numeral (e.g., one, two)
article (e.g., the, a , an)

In **Arabic**:

noun
verb (PV, IV, CV)
Letter/Functional words
words that are not nouns or verbs)

Next Lecture

→ **Part-of-Speech Tagging**

References

Mustafa Jarrar, Tymaa Hammouda: Qabas: An Open-Source Arabic Lexicographic Database. In Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024), pages 13363–13370, Torino, Italia. ELRA and ICCL.

Mustafa Jarrar, Diyam Akra, Tymaa Hammouda: **ALMA: Fast Lemmatizer and POS Tagger for Arabic**. In Proceedings of the 2024 AI in Computational Linguistics (ACLING 2024), Procedia Computer Science, Dubai. ELSEVIER.

Tymaa Hammouda, Mustafa Jarrar, Mohammed Khalilia: **SinaTools: Open Source Toolkit for Arabic Natural Language Understanding**. In Proceedings of the 2024 AI in Computational Linguistics (ACLING 2024), Procedia Computer Science, Dubai. ELSEVIER.

Jarrar, M. (2021). **The Arabic Ontology - An Arabic Wordnet with Ontologically Clean Content**. Applied Ontology Journal, 16:1, 1-26. IOS Press.

Jarrar, M., & Amayreh, H. (2019). **An Arabic-Multilingual Database with a Lexicographic Search Engine**. In Proceedings – 24th International Conference on Applications of Natural Language to Information Systems (NLDB 2019). Lecture Notes in Computer Science (vol. 11608, pp. 234-246). Springer. Doi:10.1007/978-3-030-23281-8_19