

جامعة نيويورك أبوظبي



WIDH@NYCDH 2021



Introduction to Arabic Text Processing with Python and CAMEL Tools

Starting soon!

جامعة نيويورك أبوظبي



WIDH@NYCDH 2021



Introduction to Arabic Text Processing with Python and CAMEL Tools

Salam Khalifa and Ossama Obeid

Computational Approaches to Modeling Language (CAMEL) Lab
New York University Abu Dhabi

Roadmap

- Arabic NLP Challenges
- CAMeL Lab Solutions:
CAMeL Tools
- Questions

خارطة الطريق

- تحديات اللغة العربية
- حلول من مختبر كامل:
أدوات كامل
- أسئلة

The Arabic Language

اللغة العربية

- فصحي التراث
 - لغة القرآن الكريم
 - نصوص تاريخية
- فصحي العصر
 - اللغة الرسمية في البلدان العربية
 - لغة الصحف والإعلام
 - لها إملاء قياسي وقواعد قياسية
 - لغة الأمة
- اللهجات العربية
 - لغة التحدث الرئيسية
 - بدون إملاء أو قواعد قياسية رسمية
 - لغة الأم
 - وجود متزايد على وسائل التواصل الاجتماعية
- Classical Arabic
 - Quranic Arabic
 - Historical texts
- Modern Standard Arabic
 - Official language
 - Language of news & media
 - Standard writing & grammar
 - The National Language
- Dialectal Arabic
 - Predominantly spoken
 - No official standardization
 - The Mother Tongue
 - Increasing use on social media

The Main Challenges for Arabic Language Processing

التحديات الرئيسية
للمعالجة الآلية
للغة العربية

- Orthographic ambiguity
 - Morphological richness
 - Dialectal variation
 - Orthographic inconsistency
 - Resource poverty (data & tools)
 - Limited research
- الإبهام الإملائي
 - الغنى الصرفي
 - تعدد اللهجات
 - الأخطاء الإملائية
 - فقر موارد البيانات والأدوات
 - البحث العلمي المحدود

Arabic Script

الخط العربي

العربية


العربیة

- Written right-to-left
- Letters have contextual variants
- Used to write many languages besides Arabic: Persian, Kurdish, Urdu, Pashto, etc.

- مكتوب من اليمين إلى اليسار
- حروف أشكالها متغيرة سياقيا
- يستخدم لكتابة العديد من اللغات إلى جانب العربية: الفارسية والكردية والأردية والباشتو ، إلخ.

Arabic Script

الخط العربي



- Written right-to-left
 - Letters have contextual variants
 - Used to write many languages besides Arabic: Persian, Kurdish, Urdu, Pashto, etc.

- مكتوب من اليمين إلى اليسار
 - حروف أشكالها متغيرة سياقيا
 - يستخدم لكتابة العديد من اللغات إلى جانب العربية: الفارسية والكردية والأردية والباشتو ، إلخ.

Orthographic Ambiguity

الإبهام الإملائي

- Arabic script uses optional diacritical marks
 - 1.5% of newspaper words have some diacritical marks
 - Standard Arabic has 6.8 diacritizations and 2.7 lemmas per word
- الإملاء بالخط العربي يستخدم التشكيل الاختياري
 - ١،٥٪ من كلمات نصوص الصحف تحتوي على علامات تشكيل الكلمات العربية الفصحى
 - تشكيلات و٢،٧ مداخل معجمية بالمتوسط

وَعَدْنَا

وَبِعَقْدِنَا وَبِعَقْدِنَا وَبِعَقْدِنَا

and with our (contract, necklace, psychoses) / and he stresses us out

الغنى الصرفی

Morphological Richness

- Arabic has a very rich inflectional system
 - For example, Arabic verbs have 5,400 inflected forms
 - Whereas English verbs have 6 and Chinese verbs have 1!

- لللغة العربية نظام صرفي غني جداً ينتج عنه تراكيب كثيرة
 - فمثلاً، للفعل العربي حوالي ٥،٤٠٠ تصريف
 - بينما للفعل الإنجليزي ٦ تصارييف، وللفعل الصيني تصريف واحد!

وسنقولها
/wasanaqūluhā/
و + س + ن + قول + ها
wa+sa+na+qūl+u+hā
and+will+we+say+it
And we will say it

قال، قالت، قالا، قالوا، قلت،
قلت، قلتما، قلتم، قلتن،
يقول، يقول، يقل، تقول، تقول،
تقل، تقولين، تقولي،
فقال، فقالت، فقالا...
وسأقولها، **وسنقولها** ... ،

Dialectal Variation

- Coarse Classification
 - Gulf Arabic
 - Levantine Arabic
 - Egyptian Arabic
 - Maghrebi Arabic
- Classification Problems
 - Countries with multiple varieties
 - Sub-dialectal varieties:
e.g., Urban, Rural, and Bedouin
- Diglossia and Multilingualism

تعدد اللهجات

- التصنيف العام
 - اللهجة الخليجية
 - اللهجة الشامية
 - اللهجة المصرية
 - اللهجة المغاربية
- مشاكل تصفيفية
 - تعدد اللهجات في نفس البلد
 - تعدد اللهجات الفرعية:
المدنية، والفلاحية والبدوية، مثلاً
- الازدواجية والتنوع اللغوي

Phonological Variation

الاختلافات الصوتية

- First noticed differences
 - Not the most important

- الاختلافات الصوتية تلاحظ فورياً
 - ليست الأكثر أهمية

الفصحي MSA	Dialects اللهجات
ق /q/	ق، ك، ء، گ، دج /q/, /k/, /ʔ/, /g/, /dʒ/
ث /θ/	ث، ت، س /θ/, /t/, /s/
ذ /ð/	ذ، د، ز /ð/, /d/, /z/
ج /dʒ/	ج، گ، دج /dʒ/, /g/, /ʒ/

قلب → /qalb/, /galb/, /ʔalb/ (*heart*)

/fagr/ → فجر ، فقر (*poverty, dawn*)

Morphological Variation

- Compared to Standard Arabic, dialectal morphology can be simpler or more complex
 - No case
 - New complex clitics

الاختلافات الصرفية

- مقارنة بصرف الفصحى، فإن صرف اللهجات أحياناً أبسط وأحياناً أكثر تعقيداً
 - اختفاء الحركات الإعرابية
 - تعدد التراكيب اللواصقية

كتاب → كتابُ، كتابٌ، كتابَ، كتاباً، كتابِ، كتابٍ

(book)

وما كتبتوهالوش → ولم تكتبوها له

(you all did not write it for him)

Morphological Variation

الاختلافات الصرفية

- Dialects vary systematically among themselves

- هناك العديد من الاختلافات المنهجية الصرفية بين اللهجات

	Past الماضي	Future المستقبل
فصحي Standard	كتب /kataba/	سيكتب /sajaktubu/
شامي Levantine	كتب /katab/	حٰيكتب /hajiktob/
مصري Egyptian	كتب /katab/	هيكتب /hajiktib/
مغربي Moroccan	كتب /kteb/	غيكتب /va jekteb/

Lexical Variation



You say **to-MAY-to**,
I say **to-MAH-to!**

الاختلافات المعجمية



براد؟



/b r aa d/


أنا أشهر بـBrad بـبيت!
I'm the most
famous "brad"

Common Spelling Errors and Inconsistency

كثرة الأخطاء الإملائية والتضارب الإملائي

- Unedited standard Arabic text on news commentaries has an error rate of ~30% (QALB project)

- نسبة الخطأ في التعليقات الغير محررة المكتوبة بالعربية الفصحى على صفحات بعض مواقع الأخبار تصل إلى ٣٠٪ (مشروع «قلب»)



كثرة الأخطاء الإملائية والتضارب الإملائي

Common Spelling Errors and Inconsistency

- But in the dialects, there is no official orthography! So, there are many free forms including Arabizi.

وجدنا على الإنترت ٢٧ تهجئة لهذه الكلمة باللهجة المصرية

We found 27 spellings online of the Egyptian Arabic word

ما بيقولهاش

/mabiʔulhāʃ/

“he does not say it”

(Habash et al., 2018)



- ولكن في اللهجات، لا يوجد معيار إملائي قياسي! لذا ، هناك تنوع في التهجئات بما في ذلك الإملاء المرومن (العربيزي).

Arabic Orthography	Arabic Transliteration	Frequency
مبقولهاش	<i>mbyqwlhAš</i>	≈ 26,000
ما بيقولهاش	<i>mA byqwlhAš</i>	≈ 13,000
ما بقلهاش، مبقولهاش، مبقلهاش، ما بقلهاش، ما بيقولهاش	<i>mAbqlhAš, mbqwlhAš,</i> <i>mbqlhAš, mA bqlhAš,</i> <i>mAbyqwlhAš</i>	≤ 10,000
ما بقولهاش، ما بقولهاش، مبقولهاش، ما بيقولهاش ما بقلهاش	<i>mAbqwlhAš, mA bqwlhAš,</i> <i>mbyqlhAš, mA byqlhAš</i> <i>mAbyqlhAš</i>	≤ 1,000
مبئلهاش، مابيؤلهاش، ما بيؤلهاش، مابيؤلهاش	<i>mbŷlhAš, mAbŷwlhAš,</i> <i>mA byŷwlhAš, mAbŷwlhAš</i>	≤ 100
ما بيؤلهاش، مابئلهاش، مبئلهاش، ما بيئلهاش، ما بؤلهاش، مبئلهاش، ما بؤلهاش، مابيؤلهاش، مبئلهاش، مبؤلهاش	<i>mA byûlhAš, mAbŷjhAš,</i> <i>mbyŷwlhAš, mA byŷlhAš,</i> <i>mAbŷwlhAš, mA bŷlhAš,</i> <i>mA bŵlhAš, mbŷwlhAš,</i> <i>mbyûlhAš, mAbûlhAš,</i> <i>mbûlhAš</i>	≤ 10

بعض تهجئات عربiziّة: mabi2ulhash, mabiqulhash, mabi'ulhash,...

The Main Challenges for Arabic Language Processing

التحديات الرئيسية
للمعالجة الآلية
للغة العربية

- Orthographic ambiguity
 - Morphological richness
 - Dialectal variation
 - Orthographic inconsistency
 - **Resource poverty (data & tools)**
 - Limited research
- الإبهام الإملائي
 - الغنى الصرفي
 - تعدد اللهجات
 - الأخطاء الإملائية
 - فقر موارد البيانات والأدوات
 - البحث العلمي المحدود

Roadmap

- Arabic NLP Challenges
- CAMEL Lab Solutions:
CAMEL Tools
- Questions

خارطة الطريق

- تحديات اللغة العربية
- حلول من مختبر كامل:
أدوات كامل
- أسئلة

Computational Approaches to Modeling Language Lab

[Researchers](#)
[Research](#)
[Teaching](#)
[Publications](#)
[Resources](#)
[News](#)
[Work With Us](#)
[Home](#) / [Research](#) / [Centers, Labs and Projects](#) / Computational Approaches to Modeling Language Lab

Computational Approaches to Modeling Language Lab

The Computational Approaches to Modeling Language (CAMEL) Lab is a research lab at New York University Abu Dhabi established in September 2014. CAMEL's mission is research and education in artificial intelligence, specifically focusing on natural language processing, computational linguistics, and data science. The main lab research areas are Arabic natural language processing, machine translation, text analytics and dialogue systems.



مختبر كامل
CAMEL Lab

Featured Projects

TOIA

TOIA (time-offset interaction application) is a bilingual (Arabic-English) conversational agent, similar to a chat bot, except that the avatar is based on pre-recorded videos of an actual human being.



MADAR

Parallel Dialectal Corpus and Lexicon for 25+ cities



Gumar

A browsable 100-million word data set of Gulf Arabic



MADAMIRA

Arabic Artificial Intelligence

www.camel-lab.com

موارد كامل
CAMEL Resources

أدوات كامل
CAMEL Tools



Corpora

[+] [Expand all](#)

- + ANERcorp - CAMeL Lab Train/Test Splits
- + Arab-Acquis: A parallel corpus of Arabic with all the languages of the European Parliament
- + The Arabic Parallel Gender Corpus
- + Gumar: The Gulf Arabic Corpus
- + Margarita Dialogue Corpus
- + Multi-Arabic Dialect Corpus (MADAR Corpus)
- + NYUAD Universal Dependency of Arabic (NUDAR) Treebank
- + Palm Treebank: A Multi-genre Arabic Dependency Treebank
- + Qatar Arabic Language Bank (QALB Corpus)

Lexicons

[+] [Expand all](#)

- + Arabic Multidialectal Word Embeddings
- + ArabScribe
- + Multi-Arabic Dialect Lexicon (MADAR Lexicon)
- + SAMER Readability Lexicon

Tools

[+] [Expand all](#)

- + ADIDA: Arabic Dialect Identification
- + BOTTA: An Arabic Dialect Chatbot
- + CALIMA-STAR
- + CAMeLParser
- + CAMeL Tools
- + DALILA: The Dialectal Arabic Linguistic Learning Assistant
- + Gulf Arabic Morphological Analyzer
- + MADAMIRA: Morphological Analyzer and Disambiguator for Arabic
- + MADARI: Web-base Morphological Annotation Tool
- + Palmyra
- + SIMMR
- + YAMAMA: Arabic Morphological Analyzer and Disambiguator

Guidelines

[+] [Expand all](#)

- + CAMeL Arabic Phonetic Inventory (CAPHI)
- + CAMeL Part-of-speech tagset and guidelines (CAMEL POS)
- + CODA: Conventional Orthography for Dialectal Arabic


أدوات كامل CAMEL Tools

The Camel Tools Team

فريق أدوات كامل



أسامي عبيد
Ossama Obeid



ناصر زلموط
Nasser Zalmout



سلام خليفة
Salam Khalifa



ديما التاجي
Dima Taji



مي عودة
Mai Oudah



بشار الحفني
Bashar Alhafni



جو إينوي
Go Inoue



فضل الإرياني
Fadhl Eryani



اليكساندر إردمان
Alex Erdmann



نزار حبش
Nizar Habash



أدوات كامل

CAMeL Tools

- An Open-source Python Toolkit for Arabic Natural Language Processing
- Arabic Specific
- Flexibility in use and reuse
- Modularity
- High Performance
- Ease of use for beginner
- مجموعة أدوات مفتوحة المصدر بلغة بايثون لمعالجة اللغة العربية
- التركيز على اللغة العربية
- مرونة الاستخدام وإعادة الاستخدام
- وحدات مستقلة سهلة التجميع
- الأداء عالي الجودة
- سهولة الاستخدام للمبتدئين

Comparison with other toolkits المقارنة مع رزم أخرى

	CAMEL Tools	MADAMIRA	Stanford CoreNLP	Farasa	
Target Language	Arabic خاص بالعربية	Arabic خاص بالعربية	Multilingual متعدد اللغات	Arabic خاص بالعربية	نوع الحزمة
Programming Language	Python بايثون	Java جافا	Java/Python جافا/بايثون	Java جافا	لغة البرمجة
CLI	✓	✓	✓	✓	واجهة سطر الأوامر
API	✓	✓	✓	✓	واجهة برمجة التطبيقات
Exposed Pre-processing	✓				المعالجة المسبقة للنصوص
Morphological Modeling	✓	✓			نمذجة التصريف
Disambiguation	✓	✓	✓	✓	حل الالتباس
POS Tagging	✓	✓	✓	✓	توسيم قسم الكلام
Diacritization	✓	✓		✓	التشكيل
Tokenization	✓	✓	✓	✓	التقطيع
Lemmatization	✓	✓		✓	المدخل المعجمي
Named Entity Recognition	✓	✓	✓	✓	التعرف على الكيانات المسماة
Sentiment Analysis	✓				تحليل المشاعر
Dialect ID	✓				تحديد اللهجة

- Other new toolkits include Adwat (Zerrouki, 2020) and ASAD (Mubarak et al., 2020)

- من بين الرزم الأخرى الحديثة، رزمة «أدوات» (زروقي، ٢٠٢٠) ورزمة «أسد» (مبارك وآخرون، ٢٠٢٠)

Roadmap

- Arabic NLP Challenges
- CAMeL Lab Solutions:
CAMeL Tools
- Questions

خارطة الطريق

- تحديات اللغة العربية
- حلول من مختبر كامل:
أدوات كامل
- أسئلة

https://github.com/CAMeL-Lab/camel_tools

CAMeL-Lab / camel_tools

Unwatch

15

Unstar

113

Fork

27

Code

Issues 2

Pull requests

Actions

Projects

Wiki

Security

Insights

master

8 branches

11 tags

Go to file

Add file

Code



owo Merge pull request #35 from slkh/docs ...

524fd52 on Dec 16, 2020

315 commits

.github/ISSUE_TEMPLATE

Delete usage-and-support.md

5 months ago

camel_tools

Bumped version to 1.1.0.

2 months ago

docs

Added an example to dediac.

2 months ago

tests

Updated copyright date.

5 months ago

.gitignore

Finished CALIMA Star CLI plus extra documentation a...

2 years ago

.readthedocs.yml

Fixed issues with Read the Docs builds.

6 months ago

CONTRIBUTING.rst

Updated python version support mentions.

5 months ago

LICENSE

Updated copyright date.

5 months ago

MANIFEST.in

Remove Calima Star database from repo.

5 months ago

README.rst

Updated installation instructions.

2 months ago

camel_tools_logo.png

Updated CAMeL Tools Logo.

6 months ago

setup.py

Implemented camel_data CLI utility.

2 months ago

tox.ini

Updated python version support mentions.

5 months ago

About

A suite of Arabic natural language processing tools developed by the CAMeL Lab at New York University Abu Dhabi.

nlp

sentiment-analysis

named-entity-recognition

nlp-apis

arabic

nlp-library

morphological-analysis

dialect-identification

Readme

MIT License

Releases 11


camel-tools v1.1.0

Latest

on Nov 30, 2020

+ 10 releases

<https://camel-tools.readthedocs.io/>



The screenshot shows the CAMEL Tools Documentation page. At the top left is the logo "camel_tools" with "latest" underneath. A search bar says "Search docs". On the right is a "Docs" link and an "Edit on GitHub" button. The main title "CAMEL Tools Documentation" is centered above a large logo. The logo features a red circular icon with concentric arcs to the left of the text "أدوات كامل" (Arabic) and "CAMEL Tools" (English). Below the title is a section titled "Contents:" with a list of links: Overview, Getting Started, Command-line Tools, Python API Reference, Reference, and License. There is also a "Read the Docs" button at the bottom left and a "v: latest ▾" dropdown at the bottom right.

CAMEL Tools Documentation



Contents:

- [Overview](#)
 - [About](#)
 - [License](#)
- [Getting Started](#)
 - [Installation](#)
 - [Datasets](#)
 - [Next Steps](#)
- [Command-line Tools](#)
 - [camel_transliterate](#)
 - [camel_arclean](#)
 - [camel_word_tokenize](#)
 - [camel_dediac](#)
 - [camel_diac](#)
 - [camel_morphology](#)
- [Python API Reference](#)

<https://bit.ly/3a40q3O>

File Edit View Insert Runtime Tools Help Last saved at 7:59 PM

Comment Share ⚙️ 🌐

Table of contents

- Introduction
- Arabic NLP Refresher
- Installation and Setup**
- Preprocessing
 - Simple Transliteration
 - Unicode Normalization
 - Orthographic Normalization
- Diacritization
- Word Tokenization
- Morphology
 - Analysis
 - Generation
 - Reinflection
- Disambiguation
- Tagging
- Tokenization
- Dialect Identification
- Sentiment Analysis
- Named Entity Recognition
- + Section

Introduction

This notebook provides a quick overview of the functionalities provided by CAMeL Tools. While it doesn't cover every component in detail, it does provide a starting point for learning CAMeL Tools and navigating its APIs. For more detailed information please refer to the [CAMeL Tools documentation](#).

Arabic NLP Refresher

Before diving into CAMeL Tools, we recommend a quick refresher on Arabic NLP and the challenges it presents. [This webinar](#) presented by Dr. Nizar Habash provides a short introduction on Arabic NLP as well as short examples of how CAMeL Tools can be used to solve various problems. A similar presentation of this webinar in Arabic is also available [here](#).

Note: The examples in this talk may not be compatible with current or newer versions of CAMeL Tools.

Installation and Setup

The following steps are needed if you want to run the examples in this notebook on Google Colaboratory. If you want to run this notebook on your own machine, please follow the [installation instructions](#) instead.

First, we install the CAMeL Tools Python package.

```
[ ] %pip install camel-tools
```



شكراً على المتابعة ! Thank You

www.camel-lab.com

{oobeid,salamkhalifa}@nyu.edu



diac	وَسِيَّكْتُبُونَهَا	التشكيل
lex	كَتَبٌ	المدخل المعجمي
root	ك.ت.ب	الجذر
pattern	وَسِيَّكْتُبُونَهَا	الوزن
caphi	w_a_s_a_y_a_k_t_u_b_uu_n_a_h_aa	اللفظ
gloss	and + will + they (people) + write+it; them; her	الترجمة
pos	verb	قسم الكلام
catib6	PRT+PRT+VRB+NOM	قسم الكلام / كاتب
ud	CONJ+AUX+VERB+PRON	قسم الكلام / يو دي
prc2	wa_conj	سابقة ٢
prc1	sa_fut	سابقة ١
per	3	الشخص
gen	m	الجنس
num	p	العدد
asp	i	الزمن
vox	a	البناء
mod	i	الصيغة
enc0	3fs_dobj	لاحقة ١
d1tok	وَسِيَّكْتُبُونَهَا	تطبيع ١٥
d2tok	وَسِيَّكْتُبُونَهَا	تطبيع ٢٥
atbtok	وَسِيَّكْتُبُونَهَا	تطبيع بنك بن الشجري
d3tok	وَسِيَّكْتُبُونَهَا	تطبيع ٣٥
bwtok	وَسِيَّكْتُبُونَهَا	تطبيع باكو التر
bw	وَسِيَّكْتُبُونَهَا	تحليل باكو التر
pos_logprob	-1.023208	احتمالية قسم الكلام
lex_logprob	-3.648503	احتمالية المدخل المعجمي