

2nd MEDAR International Conference on Arabic Language Ressources & Tools,
Cairo, 22-23 April 2009

Minimal Resources for Arabic Parsing: an Interactive Method for the Construction of Evolutive Automata

Claude Audebert (MMSH)

Christian Gaubert (IFAO)

André Jaccarini (MMSH)



Maison Méditerranéenne des Sciences de l'Homme – Aix-en-Provence, France

Institut français d'archéologie orientale au Caire, Egypt



Information retrieval and reported discourse

- Information retrieval IR
- Minimal resources
- Illustrate our approach with a few grammars
 - Reported speech and citation extraction
 - Judgment (min al-)
 - Some morphology

Reported discourse

- Marks and external signs can help detect
- Proper names with titles/position
- These names are a source of difficulty
- Root based names or silences (non derivative)
- Titles can be put in a lexicon
- Punctuation is not dependable

A minimal approach

- We chose a surface approach
- 1 – based on the morphology of the Arabic noun, without lexicon
- 2 – minimal set of rules
- 3 – rules represented by automata : conciseness and reflect the very nature of Arabic (Audebert, Jaccarini 1985)

Reported discourse : syntactic features

- Specific verbs : declarative verbs
- Government : *inna* إِنْ or *anna* أَنْ
- Only *qāla* قال (should) takes *inna*
- Different preposition are used by those verbs:
'abbara *'an*, *aḥbara-hu* *bi*, *'ašara* *ilā*
عَرَّبَ عَنْ ، أَخْبَرَهُ بِـ ، أَشَارَ إِلَى

Points of view

- Different implementations are possible :
- - an automaton for each preposition
- - a single automaton branching for the conjunctions
- These different choices reflect some *points of view* on the language ...
- To consider their adequacy to a given aim

Patterns to detect (1)

- We limit ourselves to the most probable conjugation
- We have to take into account the ambiguity of the *alif nūn* script, which may be also: *in* introducing negative sentence or *an* introducing a subordinate conjunctive clause

Patterns to detect (2)

- Removal of *anna* -> *Masdar*
'ašāra ilā anna-hā waṣalet 'amsi
'ašāra ilā wuṣūlihā
- Not a real quotation or reported discourse : will be a noise
yū'akkidu dalika anna ...

Sarfiyya, a tool for automata interactive designing

- Sarfiyya contains a specially designed parser for FST (using trees, chained lists and stacks), evolving to ATN
- Parse categorized FST
- Uses deterministic computation and pre-parsing (acceptor)
- Implements processes for morphological analysis

Sarfiyya

- Automata are regex and/or graphically specified with the support of a specific automata toolbox
- Allows piping between processes or automata
- Has a debugger mode

Sarfiyya

- Contains Arabic linguistic resources besides automata
- Now completely written in Java / XML / SVG with design patterns under Eclipse and open-source technologies
- ... on-going optimization !

srf.Sarfiyya Fichier Édition Morphologie Recherche Grammaires Utilitaires

Sarfiyya dev 0.5

ah07 nv N V T ↷ ۰.۹۳۳ s.

انخاف العائد الذى يحصل عليه العاملون فـ ، هذه المجالات بل قد يترتب على ذلك تخفيف فى حجم العمالة الفعلية، وبالطبع فإن كل ذلك سيت反映 بصورة سلبية على مدى السيولة المتاحة للعاملين فى هذه القطاعات حيث سيترتب على نقص السيولة حدوث نوع من الكساد.

وأوضح أن هناك عدة أساليب مقترنة بها إخبار البنوك بالقطاعات الصناعية التي يوجد قائض كبير فى إنها مقارنة حجم الطلب وبالتالي، فإنه عند تقديم بطلبات لإقامة مشروعات جديدة فى هذه المجالات كمشروعات المطاحن مثلما فإن البنوك تضم ذلك فى اعتبارها وتوقف تحويل مثل هذه المشروعات باعتبار أنها لن تحقق عائدًا اقتصادياً مناسباً يتيح سداد أقساط القروض المصروف مثل هذه المشروعات، كما يمكن أيضاً وقف أي مزايا وحوافز تقدمها الدولة للمشروعات الجديدة التي قد يطلب بعض المستثمرين إقامتها، وذلك على أساس أن الهدف من هذه الحوافز الاستثمارية التشجيع على الاستثمار، ومادام يوجد قائض كبير فى القطاعات الصناعية للمطاحن فإن هذه النوعية من المشروعات بديلاً لإقامة تشجيع وبالتالي، لا يوجد سبب لنجها حواجز ومن ضمن المقترنات فى هذا المجال أيضاً أن يتم وقف إصدار أي موافقات جديدة.

ويقول السيد حسن دياب غانم رئيس غرفة صناعة الحبوب إن الطاقات الفائضة أصبحت ظاهرة لها تأثير سلبي كبير على صناعة الدقيق استخراج الذى يستخدم في إنتاج المكرونة والحلوى والخبز الفينو

DET calculée pour cit1: 78 états

يقول المهندس عادل الموزى وكيل اتحاد الصناعات المصرية ورئيس الشركة القابضة للصناعات الكيماوية إن

يقول المهندس عادل الموزى وكيل اتحاد الصناعات المصرية ورئيس الشركة القابضة للصناعات الكيماوية إن هناك بالفعل طاقات فائضة غير مستغلة في العديد من المجالات الصناعية ومنها مثلاً الأسمدة حيث تصل نسبة الطاقات غير المستغلة فيها إلى والأسدمة الأوتوماتيكية وبغاء الجلو، والأذنية وللح الطعام والغازات الصناعية وتحصل هذه النسبة في بعض الفارات إلى وبالطبع فإن هذه الطاقات الفائضة تعتبر أمر سلبياً وغير مناسب على الإطلاق خاصة في مصر

ويقول السيد حسن دياب غانم رئيس غرفة صناعة الحبوب إن

625 cit1

ويقول السيد حسن دياب غانم رئيس غرفة صناعة الحبوب إن الطاقات الفائضة أصبحت ظاهرة لها تأثير سلبي كبير على صناعة الدقيق استخراج الذى يستخدم في إنتاج المكرونة والحلوى والخبز الفينو

total1-6.xml

titre: cit1-6 doc: citation à 6 branches; DET 9814 états, 1

E: (0:0) A: l: cat:

qala-seul.xml

titre: cit1 doc: ; DET 63 états, 1.096 s.; DET: 78 états, 0.793 s.

E: (2:4) 24 A: 4 arc 4, l: g cat: cit-qala

regex mots expand 1 ligne

```
<pos e="8" dx="0.2" dy="0.0"/>
<pos e="9" dx="0.4" dy="0.0"/>
<pos e="10" dx="0.6" dy="0.0"/>
<pos e="11" dx="0.8" dy="0.0"/>
</graph>
</gram>
```

minel.xml

titre: minel doc: extrait entre et ou أن من الـ DET 29 états, 0.288 s.

E: (0:0) A: l: cat:

total1-6.xml

titre: cit1-6 doc: citation à 6 branches; DET 9814 états, 1

E: (0:0) A: l: cat:

regex mots expand 1 ligne

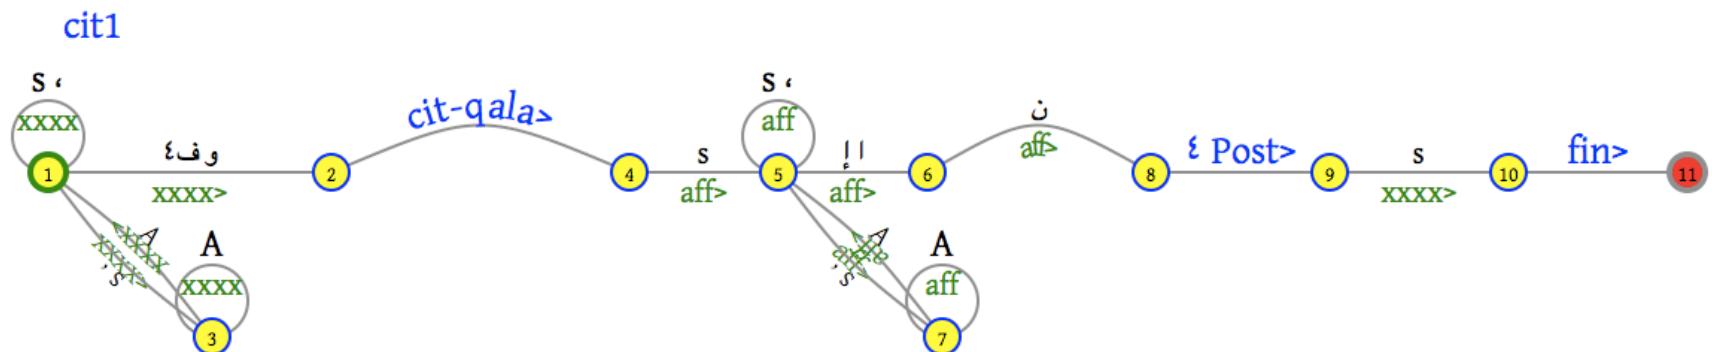
```
<pos e="12" dx="15.3" dy="3.0"/>
```

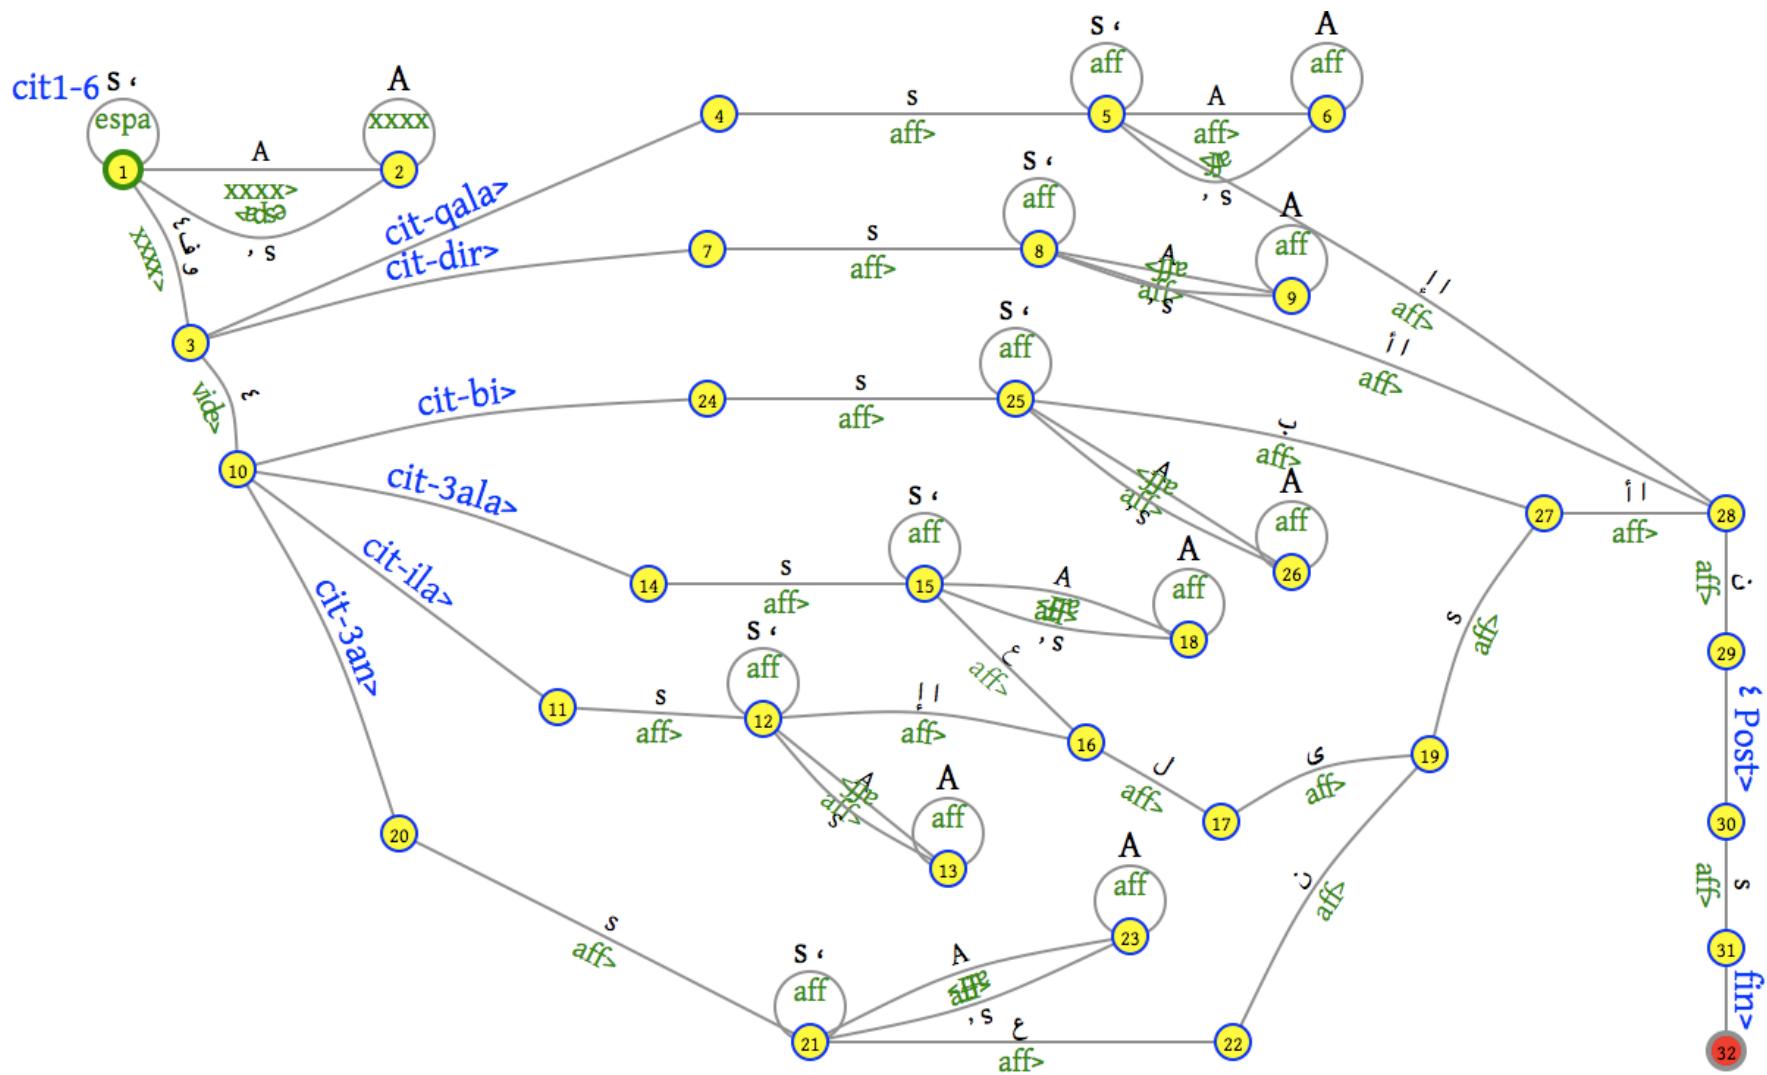
Building the *cit* grammar

- Phrase-qala = words ($\epsilon + \text{ف} + \omega$) cit-qala words إِن (Post+ ϵ) words end
- + for disjunction; s for space; * Kleen star
- Words = $(A\ A^* (s+\cdot)\ (s+\cdot)\ ^*)^*$
- cit-qala = قال+قالت+قالوا+يقول+تقول etc.

The *cit* grammar

- cit (verbs, preposition, conjunction) =
Verbs words* preposition conjunction (Post+ε)
- cit1 = cit (cit-qala, ε, نِإِلَيْهِ)





$Cit_{1-6} = \text{words } (\epsilon + \dot{\text{ف}} + \dot{\text{و}}) (\sum \text{cit}_i) (\text{Post} + \epsilon) \text{ words}$

Computing DET(*cit*)

- Using the classical DET algorithm (Aho 86, etc.)
- Exponential complexity :
- cit1-4 : 1900 states; cit1-5 : 4200 states; cit1-6 near 10 000 states within hours!
- Requires optimized structures
- Using workarounds (each branch being separately determinized)

Testing *cit*

- Using a 20 000 words corpus of al-Ahram contained in a larger one
- Retrieves 48 quotations and reported speech, mainly from *qāla*, *'akada*, *awdaha*, *adāfa*, about 1000 words/s
- Also retrieves noise coming from long sentences with multiples *anna* / *inna*

Troubleshooting *cit*

- Introducing a complement capacity into the parser
- Split some sentences into overlapping sequences to be parsed and reassembled
- Develop a non greedy branch of the parser
- A hard limit to limiting some cycles into automata

من الـ أن

- من الممكن، من الواضح...
- ومن غير المنطقى أن
 - words (غير+ع) الـ s من (و+ف) A* s words
- Fighting some noise with a small lexicon

Revisiting morphology

- From the very simple automata of 6 states to 13 states for the determinist version : Cohen then Jaccarini 94
- We define general morphology as a *transduction* of a basic system (Jaccarini 98)
- To associate micro-lexicon data and morphological categories can help to cover 98% of the needs, with unavoidable but measurable noise (Gaubert 01)

كواكب برو * Kawâkib pro

<http://localhost:8080/kawakib/pro.html?lg=en>

Kawâkib bêta كواكب

Arabic Text : [enlarge](#) [hide](#) [erase](#)

Français English عربية

_shed الأسبوع الماضي الإعلان عن عدة ظواهر فلكية مهمة، وهي اكتشاف ١٠ كواكب جديدة خارج المجموعة الشمسية، وحدوث عدة انفجارات شمسية وصفها العلماء بعطلة الشمس أثرت بصورة مباشرة على الأقمار الصناعية والشبكات الكهربائية بالأرض، ومن المتوقع - كما يقول الدكتور محمد أحمد سليمان رئيس معمل أبحاث الشمس بالمعهد القومي للبحوث الفلكية - أن تحدث عدة انفجارات هائلة بالشمس نظراً لدورها بمرحلة النهاية العظمى لدورة نشاطها التي تكرر كل ١١ سنة وتنتهي عام ٢٠٠١.

Settings and Actions : [arabic keyboard help](#)

Schemes Root (to look at) ظ ن ر ٣ ٢ ١ Frequent roots
 Empty phrase Tokens suites Tokens Sequence رئيس
 Reported speech Frequencies Repetitions NVT

Result : [enlarge](#) [right to left](#)

Test me!

Copy a text of your choice in Arabic (taken for instance from the Arabic newspapers websites like [الصري اليوم, الأهرام](#), etc. or any other source of texts) or choose one of the proposed examples on the left-side list. You can enlarge this text, hide it to work in a blindly way or erase it to replace it.

Then achieve one of the following actions:

- Search for the 20 most frequently used roots
- Search for a trilitar root like ظ ن ر using for the input the right side (consonants) of the virtual [arabic keyboard](#) if you don't have a hardware keyboard; in R3, the letter ر must be used for ي (enter شفو for شفوي for instance)
If you erase one of the radical letters Kawakib will show a list of roots using the other letters
- Search a character string
- Read the text with its tokens (tool words)
- Click on settings and actions/help or on the Cygnus constellation (Deneb) (ذنب الدجاجة) to reload the initial page

Terminé

S3Fox commission * لجن

Conclusion

- Necessity of the feed-back method
- To evaluate grammars themselves not only results
- Ambiguity not necessarily due to the absence of lexicon and should be organized into a hierarchy
- Automats helps clarifying the transition from the declarative to the operational