



**HAL**  
open science

## Structure syllabique et information lexicale en arabe

Jean-Pierre Angoujard

► **To cite this version:**

Jean-Pierre Angoujard. Structure syllabique et information lexicale en arabe. XXVèmes Journées d'Étude de la Parole, Apr 2004, Fès, Maroc. pp.20-23. halshs-00430429

**HAL Id: halshs-00430429**

**<https://shs.hal.science/halshs-00430429>**

Submitted on 6 Nov 2009

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# Structure syllabique et information lexicale en arabe

Jean-Pierre Angoujard

Equipe “Acoustique, Acquisition et Interprétation” (AAI)  
Université de Nantes - Faculté des Lettres et Sciences Humaines  
Chemin de la Censive du Tertre BP 81227 44312 Nantes Cedex 3, France  
Tél. : +33 (0)2 40 14 14 68 - Mél. : jean-pierre.angoujard@wanadoo.fr

## ABSTRACT

This paper examines certain aspects of syllabification from the view-point of Declarative Phonology. Constraints pertaining to syllabic structure are often set in the lexicon. We show that processes like affixation (section 2) and sandhi (section 3) are problematic for such a view of the grammar. A partial analysis of the so-called “defective verbs” in Arabic (section 4) leads to the conclusion that syllabic constraints (specifically a constraint that minimalizes the number of syllables) are descriptions of the type *phrase* (for “phonological phrase”). Getting away from a templatic approach allows concrete representations, strictly settled in a non derivational framework.

## 1. INTRODUCTION

Les premières analyses plurilinéaires de l’arabe ont durablement imposé, par la présence d’une mélodie CV, une lecture syllabique des représentations lexicales [8]. Cette approche, associée à la reconnaissance de sommets non associés, a ouvert la voie à une analyse non dérivationnelle des alternances du type [kɪɾb-na] ~ [kɪɾb-u] : les deux formes du radical sont interprétées comme “bisyllabiques”, *i.e.* (où \* représente une position de sommet vocalique) [kɪɾb-] ≡ <k\*ɪɾb> et [kɪɾb-] ≡ <ɪɾb\* > [1].

Le recours à des représentations lexicales syllabées a été remis en cause et opposé à des analyses “dynamiques” rapportant l’organisation en syllabes à un processus de surface, à l’occasion associé à la “performance”. La morphologie flexionnelle (section 2) et les phénomènes de *sandhi* (section 3) montrent effectivement les limites d’un lexicalisme strict.

La phonologie déclarative offre un cadre entièrement non dérivationnel, monotone et basé sur les contraintes [4, 6]. Dans la mesure où il est fait référence à un seul et unique niveau de représentation, tout débat sur le niveau (ou le moment) de la syllabation est sans objet. L’interrogation se trouve déplacée (section 4) : quelles informations doit contenir la représentation lexicale (une contrainte) pour autoriser tout à la fois la description des contraintes sur les schèmes et celle d’une structuration syllabique gouvernée par l’organisation en syntagmes ?

## 2. LA SUFFIXATION

La théorie syllabique qui se réfère à un “modèle rythmique” fait l’hypothèse que toute séquence de sons est associée à une grille rythmique, cette grille étant la répétition un nombre *n* de fois d’un modèle rythmique [2]. Ce

modèle est constitué de trois positions dont seule la dernière est facultative. Des contraintes limitent les associations entre segments (SEG) et positions rythmiques (POS). En particulier, la position 3 du modèle n’est accessible qu’à un segment de sonorité élevée, à la première moitié d’une géminée ou à la seconde moitié d’une voyelle longue. Ainsi, une obstruante ne sera jamais associée à une position 3 (à moins qu’il ne s’agisse d’une géminée), mais à une position 1, et donc toujours suivie d’une position 2 (d’un sommet). A chaque doublet <SEG, POS> est également associée une position de courbe (PC), dont la valeur (une sonorité relative) appartient à l’ensemble  $\{i(\text{nitiale}), s(\text{ommet}), f(\text{inale})\}$ .

Nous définissons :

$$\begin{aligned} \text{init} &\equiv [\text{SEG} : \text{Seg}] \wedge [\text{POS} : 1] \wedge [\text{PC} : i] \\ \text{som} &\equiv [\text{SEG} : \text{Seg}] \wedge [\text{POS} : 2] \wedge [\text{PC} : s] \\ \text{fin} &\equiv [\text{SEG} : \text{Seg}] \wedge [\text{POS} : \text{Pos}] \wedge [\text{PC} : f] \\ \text{modèle} &\equiv \text{init} \wedge \text{som} \wedge (\text{fin} \vee \emptyset) \\ \text{mot} &\Rightarrow \text{mod}(\text{èle})^+ \end{aligned}$$

Ceci impose, par exemple, pour une forme [katab] (“il a écrit”, arabe de Damas), une grille rythmique composée de trois modèles successifs, le dernier sommet étant non associé (les courbes prosodiques ne seront pas représentées dans les figures 1, 3, 4 et 5) :

x	x	x	x	x	x
k	a	t	a	b	

FIG. 1: Forme [katab] (grille rythmique partielle)

La phonologie déclarative fait usage de représentations en structures de traits [attribut : valeur]. Dans ce cadre, l’absence de segment associé au dernier sommet (figure 1) (et, par voie de conséquence, l’absence de position de courbe) correspond à la non instanciation de la valeur du trait SEG (la valeur est alors une variable, notée *Seg*). Le dernier modèle rythmique de la séquence [katab] est représenté dans la figure 2 (la valeur <b> est une abréviation pour une liste d’éléments [7]).

Si la forme [katab] correspond à une 3ème personne du masculin singulier de l’accompli, elle apparaît également comme *radical* dans toutes les formes fléchies de l’accompli ([katabna], [katabu] etc.). Il a été proposé [3] que le radical verbal (*rad\_v*) soit un sous-type de *mot* :  
 $\text{mot} \sqsubseteq \text{rad}_v$ .

$$\text{mod} \left[ \begin{array}{l} \text{init} \\ \text{SEG} : < b > \\ \text{POS} : 1 \\ \text{PC} : i \end{array} \right] \text{som} \left[ \begin{array}{l} \text{SEG} : \text{Seg} \\ \text{POS} : 2 \\ \text{PC} : Pc \end{array} \right]$$

FIG. 2: Dernier modèle de [katab]

Une représentation lexicale du radical du verbe [katab] (incluant une information sur le vocalisme) serait :

$$\{ < k, t, b > \wedge \text{rad}_v \wedge (v_{acc} = A) \wedge (v_{inacc} = U) \}$$

Le type  $\text{rad}_v$  implique, *via* la contrainte  $\text{mot} \Rightarrow \text{mod}^+$  une structuration rythmique (une syllabation) de cette représentation lexicale. Si nous supposons que les affixes sont également des sous-types de  $\text{mot}$ , le suffixe de 3ème personne du pluriel [u] se verra doté d’un modèle rythmique autonome (avec une position 1 non associée) et la représentation de la forme suffixée [katabu] (“ils/elles ont écrit”) contiendra deux positions rythmiques adjacentes non associées (un sommet et un creux). Une analyse retenant l’unification de [u] et de la valeur de  $\text{som}|\text{SEG}$  du dernier modèle rythmique du radical est certainement préférable, ce qui suppose que ce suffixe et, plus généralement, les affixes, ne soient pas un sous-type de  $\text{mot}$ . Soit, pour représentation lexicale de ce suffixe :  $\{ < U > \wedge \text{uff} \}$  (l’information sur l’alternance régulière [u] ~ [u :] sera incluse dans la définition de  $\text{uff}$ ).

### 3. LES SYLLABES EN SANDHI

L’article défini de l’arabe classique apparaît, après une pause (en début de syntagme phonologique) et devant tout mot dont le premier segment n’est pas coronal, sous la forme [ʔal], ainsi le nom [ʔal-madīna] (“la ville”). La suite initiale (les segments précédant le [I]) est dite “fragile” dans la mesure où, en position de *sandhi*, la séquence [ʔa] est absente. On rencontrera ainsi : [fi-l-madīna] (“dans la ville”) ou encore (avec réalisation minimale, [i] par défaut, du sommet) [katabat-i-l-bint] (“la petite fille a écrit”).

Ces deux dernières représentations s’expliquent très simplement si on suppose que l’article défini est constitué d’un unique segment [I] occupant une position 3 (type *fin*). Les positions 1 et 2 du dernier modèle rythmique (adjacent à gauche) constituent, avec l’article, un modèle rythmique à trois positions ; dans le cas où la position 2 adjacente est non associée (avec  $[\text{SEG} : \text{Seg}]$ ) cette variable est instanciée par défaut.

Cette analyse, certainement la meilleure, implique que l’article défini, pas plus que les affixes, ne soit associé lexicalement à un modèle rythmique. Une représentation lexicale très simplifiée (dans laquelle, notamment, l’assimilation devant les coronales n’est pas représentée) serait (FSP = “fin de syntagme phonologique” ;  $\wp$  est un opérateur de précedence immédiate) :

$$\{ < R, l > \wedge ( < A > \wedge (\text{FSP } \wp \text{ art\_def}) ) \}$$

La représentation lexicale de l’article défini présente une difficulté que nous n’avons pas rencontrée avec le suffixe [u]. Il ne fait guère de doute que le groupe [art\_def + nom] constitue un domaine clitique ; or tout objet intégré comme clitique à un objet de type  $\text{mot}$  est de type  $\text{mot}$  :  $\text{mot}[X \text{ mot}[ Y ]]$ .

Il s’ensuit que la séquence [art\_def + nom] doit être dotée d’une structure rythmique (comme cela est apparent après la pause, au travers de la réalisation [ʔal] de l’article) et que la concaténation [verbe + GN] doit être la concaténation de deux types  $\text{mot}$ . Nous nous trouverions alors devant une séquence incluant cette fois trois positions non associées : le sommet vide final du verbe et les positions 1 et 2 de l’article. Une contrainte générale ( $\text{dom\_plein}$ ) exclut la présence de positions non associées entre deux sous-domaines. Cette contrainte est notamment à l’oeuvre, de manière évidente, dans le processus de la “liaison obligatoire” en français).

La simplification souhaitable est obtenue si nous admettons, d’une part que la consonne finale du mot de gauche (comme [katabat] dans notre exemple) n’est pas suivie lexicalement d’un sommet et, d’autre part, que le groupe nominal ne contient pas de position 1 non associée. Ceci suppose que ni l’un ni l’autre ne soient associés, dans le lexique, à une grille rythmique. Ceci suppose que la contrainte  $\text{mot} \Rightarrow \text{mod}^+$  soit modifiée (*phrase* = syntagme phonologique) :

$$\text{phrase} \Rightarrow \text{mod}^+$$

Si nous nommons  $r\_phrase$  cette contrainte (et  $C_n$  les autres contraintes), nous aurons alors :

$$\text{phrase} \equiv \text{mot}^+ \wedge r\_phrase \wedge C_j \wedge \dots \wedge C_k$$

### 4. RYTHME ET MINIMALITÉ

Il n’est pas possible d’étendre la contrainte  $\text{dom\_plein}$  (section 3) au frontières entre syntagmes phonologiques. Un tel syntagme peut naturellement commencer par une voyelle (pas en arabe, mais dans une langue comme le français), auquel cas la première position rythmique (une position 1) sera non associée. Il peut également se terminer par une obstruante (tant en français qu’en arabe), et cette fois le syntagme se terminera sur une position 2 non associée (rappelons que le modèle rythmique [2] réserve la position 3 aux consonnes les plus sonores). Nous poserons toutefois que la structuration rythmique, au sein d’un type *phrase*, doit être “minimale” : elle devra comprendre le plus petit nombre acceptable de modèles rythmiques et/ou de positions non associées.

Ce principe de minimalité rythmique (contrainte  $r\_min$ ) conduit, en français, à reconnaître l’association de l’article défini à une position 1 dans [tavylɔptiga] et à une position 3 dans [tavylptiga]. Ceci est évidemment rendu possible par la nature de l’article défini (une liquide). Si on imagine que “petit gars” est pris comme un nom propre, une éventuelle séquence “avec petit gars” ne pourra pas être réalisée \*[avɛkptiga] parce que le [k] (obstruante) doit être associé à une position 1 et donc, dans cet exemple, suivi d’un sommet non associé, la séquence ne respectant pas alors une contrainte ( $\text{som\_vide}$ ) proposée dans [2] et qui interdit la succession de deux sommets non associés (il est évidemment possible de réaliser [avɛk || ptiga]). On notera également avec intérêt que  $r\_min$  rend inutile (en l’intégrant à une contrainte beaucoup plus large) un principe comme celui de l’attaque maximale (*Maximal Onset Principle*).

La prise en compte des contraintes  $r\_phrase$  et  $r\_min$  a des conséquences très importantes pour l’analyse de l’arabe.

En effet, le concept de “schème”, le plus souvent assimilable à une structure syllabique, est omniprésent, depuis [8], dans les descriptions morpho-phonologiques de cette langue (sous ses diverses variétés). Nous prendrons l’exemple de l’analyse des verbes dits “défectueux” de l’arabe classique et nous verrons qu’une approche faisant usage de  $r\_phrase$  et  $r\_min$  conduit à une révision très profonde des processus impliqués.

Sont appelés “défectueux” les verbes dont la troisième consonne radicale est une semi-voyelle. Ainsi, il est régulièrement attribué, au radical du verbe signifiant “jeter”, la suite consonantique <r, m, y> (pour suivre une tradition constante en phonologie arabe, la semi-voyelle [j] est représentée comme [y]). Il se trouve que cette semi-voyelle est absente dans de nombreuses formes : si la 3ème personne du masculin singulier de l’accompli (suffixe [a]) du verbe signifiant “écrire” est [kataba], celle du verbe signifiant “jeter” est [ramā] (et non \*[ramaya]).

La phonologie générative a tout naturellement retenu la présence, dans la grammaire de l’arabe, d’une règle d’effacement des semi-voyelles : /ramaya/ → [ramā]. Cet effacement est dépendant de facteurs complexes (nature de la semi-voyelle, nature des voyelles adjacentes, structure morphémique). Dans la toute première analyse réalisée dans ce cadre théorique, Brame [5] établissait, entre autres, la règle suivante :

$G \rightarrow \emptyset / V_i \_ V_j$  [-vocalic]  
if  $V_j$  is [+low], then  $V_i$  is [+low]

Une interprétation déclarative, excluant toute règle de réécriture, a été proposée récemment [3]. Cette analyse s’appuyait sur une représentation lexicale incluant une disjonction : <r, m, (y ∨ Seg)>. Plusieurs contraintes rendaient compte de la présence ou de l’absence de la semi-voyelle. En particulier, une contrainte (appelée *sonorité*) se référait à la nature des voyelles adjacentes. Elle avait pour objectif de justifier, par exemple, les réalisations distinctes [ramā] vs [yarmiya] (inacc. subj.). Ce qui nous importe ici est le rôle essentiel joué alors par la structuration syllabique lexicale : dans tous les cas le radical était composé de trois modèles rythmiques binaires ; la distinction tenait à l’instanciation ou à la non instanciation de la valeur du trait SEG du troisième modèle rythmique. La figure 3 fournit une représentation, sous forme plurilinéaire, de la forme [ramā], telle qu’elle était analysée dans [3] (on notera, en particulier, la présence d’un creux non associé au sein de ce qui constitue la voyelle longue).

x	x̄	x	x̄	x	x̄
r	a	m	a		a

FIG. 3: Forme [ramā] (grille rythmique partielle)

De la même manière, la notion de “schème” (à tout verbe comprenant trois consonnes radicales sont associés, à la forme I, trois modèles rythmiques binaires) et l’application de la contrainte  $mot \rightarrow mod^+$  imposaient la présence, cette fois, d’un sommet non associé dans [ramaytu] (1ère personne du masc. sing. de l’accompli, suffixe [tu]), cf. figure 4.

La présence dans notre grammaire des deux contraintes

x	x̄	x	x̄	x	x̄	x	x̄
r	a	m	a	y		t	u

FIG. 4: Forme [ramaytu] (grille rythmique partielle)

$r\_phrase$  et  $r\_min$  nous permet maintenant de retenir une analyse infiniment plus simple (pour ne pas encombrer les représentations, les segments ne sont pas représentés comme des listes d’éléments ; la semi-voyelle est toutefois notée I (réalisation [y] ou [i]) :

$$lex\_rama \equiv \left\{ \begin{array}{l} \langle R, M, (I \vee Seg) \rangle \wedge rad\_v \wedge (v\_acc = A) \\ \wedge (v\_inacc = I) \end{array} \right\}$$

$$lex\_suff\_3pl \equiv \{ \langle u \rangle \wedge suff \}$$

$$lex\_suff\_1sg\_m \equiv \{ \langle t, u \rangle \wedge suff \}$$

$$lex\_pref\_3\_inacc \equiv \{ \langle I, a \rangle \wedge pref \}$$

$$lex\_suff\_inac\_subj \equiv \{ \langle a \rangle \wedge suff \}$$

$$phrase \equiv mot^+ \wedge r\_phrase \wedge r\_min$$

Le choix au sein de la disjonction  $(I \vee Seg)$  sera guidée par la nécessité de construire une grille rythmique acceptable ( $r\_phrase$ ) comprenant le plus petit nombre possible de modèles ( $r\_min$ ).

Nous obtiendrons pour [ramaytu], et en l’absence de toute dérivation (*contra* [5, 8]), une représentation rythmique (figure 5, à comparer avec la figure 4) incluant un modèle à trois positions (I est suffisamment sonore pour être associé à une position 3 et l’arabe admet parfaitement les diptongues lourdes).

x	x̄	x	x̄	x	x	x̄
r	a	m	a	y	t	u

FIG. 5: Forme [ramaytu] (nouvelle version)

[On notera que le choix de la valeur *Seg*, au sein de la disjonction, ne conduirait pas à une forme d’égale simplicité (soit \*[ramatu]), mais retiendrait la présence d’une position non instanciée ; contrairement à [ramā] (cf. ci-dessous) où la variable *Seg* est unifiée avec la valeur [a] du suffixe.]

La structure rythmique retenue pour la forme [ramaytu] sera donc distincte de celle des formes comme [katabtu], construites à partir d’une séquence  $\langle C_1 C_2 C_3 \rangle$  et dans lesquelles  $C_2$  est une obstruante nécessairement associée à une position 1, suivie d’un sommet non instancié. Ces analyses différentes ne doivent pas surprendre : elles sont comparables, par exemple, aux analyses distinctes, pour le français, des deux participes [ābarke] “embarqué” (avec un [ʁ] en position 3) et [āpakte] “empaqueté” (avec un sommet non instancié après l’occlusive vélaire). Il reste que la notion de “schème”, traditionnelle au sein des études arabes, est ici malmenée —avec raison, nous semble-t-il<sup>1</sup>.

<sup>1</sup>Merci au lecteur anonyme qui nous a incité à développer ce point et

La forme [ramā] recevra directement son interprétation la plus simple et la plus communément admise, cf. l'orthographe رَمَى. Le suffixe [a] constitue (en position 3) la seconde partie d'une voyelle longue. La figure 6 présente la structure de traits correspondant au second (et dernier) modèle rythmique de cette forme (à comparer avec la grille présentée dans la figure 3). Le traitement de l'unification entre les deux valeurs de SEG pour les positions 1 et 2 (Principe du Contour Obligatoire) ne sera pas développé ici.




FIG. 6: Dernier modèle de [ramā]

La forme 3 masc. sing. de l'inaccompli subjonctif est construite par préfixation de [ya] et suffixation de [a]. Il faut également ajouter la non instanciation du premier sommet du radical, non instanciation qui caractérise les formes à préfixe [CV] (cette dernière contrainte ne sera pas discutée ici). Le second sommet reçoit lexicalement la valeur [i] ( $v_{inacc} = I$ ). Le choix de la valeur *Seg* au sein de la disjonction ( $I \vee Seg$ ) conduirait cette fois à une séquence inacceptable en arabe : ya+rmi+a, qui ne pourrait être interprétée que comme \*[yarmiā] ou \*[yarmiya] (cette langue n'accepte ni les successions de voyelles, ni les diphtongues légères). La valeur I doit donc être retenue, avec pour résultat la forme attestée [yarmiya].

On aura remarqué que cette analyse nous dispense de recourir à une contrainte spécifique portant sur l'entourage vocalique de la semi-voyelle (contrainte *sonorité* dans [3]). Ce qui ne met nullement hors de cause, par ailleurs, la qualité des voyelles concernées, mais rapporte leur comportement à une contrainte générale sur les structures syllabiques acceptables.

## 5. CONCLUSION

La phonologie déclarative, monostratale, interprète toute représentation comme la somme de ses représentations partielles (ou contraintes). Les contraintes portant sur l'organisation syllabique (rythmique) font évidemment partie de la représentation. Il a été proposé dans cette communication que les contraintes rythmiques appartiennent au type *phrase* (le syntagme phonologique). Il s'ensuit que les représentations lexicales ne contiennent pas cette information rythmique : elles sont essentiellement constituées d'une suite ordonnée de segments (de listes d'éléments) et d'informations morphologiques (pour la partie de la grammaire qui nous préoccupe ici). Le type *phrase* inclut également une contrainte *min* imposant une structuration rythmique minimale.

Nous avons montré que ces choix ont des conséquences non triviales pour l'analyse des langues naturelles. En par-

à en signaler explicitement la conséquence.

ticulier, ils suggèrent que, contrairement à ce qu'un long et persistant usage de la notion de "schème" laissait croire, la structuration rythmique de l'arabe n'est sans doute pas aussi spécifique qu'on voulait bien l'imaginer. Un examen (très simplifié) de quelques caractéristiques des verbes "défectueux" nous a appris qu'il était possible de retenir des représentations syllabiques "concrètes", et ceci sans recourir à quelque dérivation que ce soit (et donc à quelque représentation lexicale abstraite que ce soit).

## RÉFÉRENCES

- [1] Jean-Pierre Angoujard. Sur la représentation du verbe [ktib] (parler de Tunis). *Analyses, Théorie*, 1982/2-3 :1-17, 1982.
- [2] Jean-Pierre Angoujard. *Théorie de la Syllabe. Rythme et Qualité*. CNRS Editions, Paris, 1997. 224 p.
- [3] Jean-Pierre Angoujard. Vers une morphologie déclarative de l'arabe. *Langues et Littératures du Monde Arabe*, 2 :9-31, 2001.
- [4] Steven Bird. *Computational Phonology. A constraint-based approach*. Cambridge University Press, Cambridge, 1995. 203 p.
- [5] M. Brame. *Arabic Phonology : Implications for Phonological Theory and Historical Semitic*. PhD thesis, M.I.T., 1970.
- [6] John Coleman. *Phonological representations. Their names, forms and powers*. Cambridge University Press, Cambridge, 1998. 345 p.
- [7] Jonathan Kaye, Jean Lowenstamm, and Jean-Roger Vergnaud. The internal structure of phonological elements : a theory of charm and government. *Phonology*, 2 :303-326, 1985.
- [8] John J. McCarthy. *Formal Problems in Semitic Phonology and Morphology*. PhD thesis, M.I.T., 1979.