

Une grammaire formelle du créole martiniquais pour la génération automatique

Pascal Vaillant

Université des Antilles-Guyane — UFR de Lettres et Sciences Humaines

B.P. 7207 — 97275 SCHOELCHER CEDEX — Martinique, France

Mél : `pascal.vaillant@martinique.univ-ag.fr`

Mots-clefs – Keywords

Créole, Martiniquais, Grammaire, TAG, Génération
Creole, Martiniquese, Grammar, TAG, Generation

Résumé - Abstract

Nous présenterons dans cette communication les premiers travaux de modélisation informatique d'une grammaire de la langue créole martiniquaise, en nous inspirant des descriptions fonctionnelles de Damoiseau (1984) ainsi que du manuel de Pinalie & Bernabé (1999). Prenant appui sur des travaux antérieurs en génération de texte (Vaillant, 1997), nous utilisons un formalisme de grammaires d'unification, les grammaires d'adjonction d'arbres (TAG d'après l'acronyme anglais), ainsi qu'une modélisation de catégories lexicales fonctionnelles à base syntaxico-sémantique, pour mettre en œuvre une grammaire du créole martiniquais utilisable dans une maquette de système de génération automatique. L'un des intérêts principaux de ce système pourrait être son utilisation comme logiciel outil pour l'aide à l'apprentissage du créole en tant que langue seconde.

In this article, some first elements of a computational modelling of the grammar of the Martiniquese French Creole dialect are presented. The sources of inspiration for the modelling is the functional description given by Damoiseau (1984), and Pinalie's & Bernabé's (1999) grammar manual. Based on earlier works in text generation (Vaillant, 1997), a unification grammar formalism, namely Tree Adjoining Grammars (TAG), and a modelling of lexical functional categories based on syntactic and semantic properties, are used to implement a grammar of Martiniquese Creole which is used in a prototype of text generation system. One of the main applications of the system could be its use as a tool software supporting the task of learning Creole as a second language.

1 Introduction

Le créole martiniquais est l'un des représentants de la famille des langues créoles à base lexicale française de la zone Amérique-Caraïbes (« CRELFACS »). Ces langues peuvent être décrites très généralement parmi celles qui se sont formées dans une situation de contact ; mais l'expression relève ici d'un euphémisme considérable, le « contact » consistant en l'occurrence en la déportation massive de peuples de langues différentes, obligés d'adopter en peu de temps un véhiculaire comme nouveau moyen d'expression. La situation historique évoquée est celle de la colonisation du Nouveau Monde par les puissances européennes entre le XVIIe et le XIXe siècle, et de l'importation massive et forcée de main d'œuvre africaine engendrée par le système économique esclavagiste.

Les créoles ont ainsi subi simultanément, en l'espace d'à peine quelques générations, plusieurs processus d'évolution diachronique rapides (Alleyne, 1996). Certains sont assez faciles à se représenter et sont l'objet d'une description relativement classique : ce sont par exemple les développements de tournures analytiques, du même type que ceux qui ont conduit du latin aux langues romanes modernes, et qui sont encore à l'œuvre dans le français actuel (plus développées dans les variétés de français populaire qui étaient parlées par les colons que dans la langue standard, ces tournures auraient ainsi pu selon Chaudenson (1995) contribuer directement à influencer le lexique et la grammaire créole). D'autres, beaucoup plus spécifiques à la situation et beaucoup moins à la portée de l'investigation linguistique historique, ont pu provoquer des amalgames de structures lexicales et syntaxiques françaises d'une part, et de structures provenant de plusieurs langues africaines d'autre part, la propagation de modèles linguistiques variant dans certains cas avec l'influence de certains groupes de peuplement, qui jouissaient à certaines époques de situations de domination démographique ou culturelle relative (Alleyne, 1996). Les créoles ont en fin de compte développé un système sémantique et un système syntaxique tout à fait original, tout en gardant incontestablement une base lexicale majoritairement française.

Ces considérations historiques ne sont pas l'objet du travail présenté ici, mais leur rappel permet de resituer dans leur perspective les caractères originaux des crelfacs.

Dans une perspective synchronique, quoi qu'il en soit, nous nous sommes attachés à mettre sur pied une modélisation adéquate et économique des descriptions linguistiques du système actuel de la langue. Nous nous sommes appuyés, pour le cœur de la description des énoncés, sur l'approche fonctionnelle de Damoiseau (1984), tout en ayant recours pour des descriptions plus fines à certains exemples de (Bernabé, 1983) et de (Pinalie & Bernabé, 1999).

Le créole martiniquais est l'un des représentants de la famille des crelfacs, avec le guyanais, le trinitadien (en voie d'extinction, au profit de l'anglais), le saint-lucien, les dialectes dominicains, les dialectes guadeloupéens, les dialectes haïtiens, et le louisianais. Il a la particularité d'être l'un des plus unifiés, et partage par ailleurs avec le créole de Port-au-Prince (devenu langue nationale d'Haïti) une richesse en termes de production culturelle qui ne se retrouve qu'à un degré moindre dans d'autres pays créolophones. L'approche présentée ici est cependant aisément transposable à d'autres langues du même groupe, notamment le guadeloupéen et le guyanais.

2 Description

Nous exposons ici quelques faits grammaticaux succincts ; des descriptions plus complètes des faits de grammaire du créole martiniquais se trouvent dans les ouvrages déjà cités (Damoiseau, 1984; Bernabé, 1983; Pinalie & Bernabé, 1999).

Le créole est une langue isolante, dans laquelle les éléments lexicaux sont invariables. Les fonctions syntaxiques sont toutes manifestées par l'ordre des éléments dans la phrase.

Groupes verbaux

L'absence de flexion nominale est déjà familière à un lecteur francophone. Comme le français, et contrairement aux langues à flexion nominale comme le latin ou le russe, le créole ne détermine la fonction des actants et des circonstants des verbes que par deux procédés : (a) leur position dans la chaîne syntaxique, et (b) des prépositions introduisant des cas sémantiques spécifiques. L'ordre des actants et des circonstants a tendance à être plus rigide encore qu'en français, le procédé (a) ayant un périmètre d'emploi plus étendu encore. Ainsi, en créole, les verbes trivaux de type « attributif » (correspondant à des verbes français comme *donner*, *prêter*, *montrer*, etc.) forment des phrases à l'aide d'un cadre de distribution syntaxique des actants qui comporte trois groupes nominaux directs, là où en français seuls le sujet et l'objet sont des groupes directs (le complément d'attribution étant introduit par la préposition *à*). Ceci impose un ordre strict, en l'occurrence S V A O, pour déterminer les actants. Ainsi, en français les phrases (1a) et (1b) sont toutes deux recevables, alors qu'en créole seule la phrase (2b) est recevable.

(1a) *Pierre a donné un beau livre à Robert*

(1b) *Pierre a donné à Robert un beau livre*

(2a) **Pyè ba an bel liv Wobè*

(2b) *Pyè ba Wobè an bel liv*

La flexion verbale est ici remplacée par un système d'expression des variations d'aspect et de temps qui est purement analytique, comme celui que l'on observe en chinois. Les différents degrés sont exprimés par des particules temporelles ou aspectuelles qui sont préposées au verbe (contrairement au chinois, où elles sont postposées).

Le nombre de marques possibles du temps et de l'aspect est limité ; la gamme d'emplois de chacune de ces marques est donc vaste. Cet état de choses fait de leur description sémasiologique une tâche considérable, et il est difficile de caractériser le système de manière simple. Un panorama complet de cette question, ainsi qu'une description plus particulière des différences entre créole guyanais et martiniquais, est présenté par (Pfänder, 2000).

Plusieurs descriptions systémiques ont été proposées ; nous retiendrons pour l'état actuel de notre modélisation celle de Damoiseau (1984, p. 26). Si l'on peut questionner la pertinence de la frontière stricte qu'il trace entre marques temporelles et marques aspectuelles, notamment au sujet de la classification de *ké* comme marque strictement aspectuelle, son système présente l'avantage de recouper en assez grande partie la combinatoire syntagmatique de ces marques :

TEMPS :	ASPECT :		
	perfectif	imperfectif (duratif, général, itératif)	imperfectif (prospectif)
(pas d'indication)	∅	ka	ké
passé	té	té ka	té ké

Les combinaisons \emptyset , *ka*, *ké*, *té*, *té ka* et *té ké* sont en effet les plus fréquemment attestées¹.

Pour donner une idée des valeurs de ces combinaisons de marques, on peut mentionner certaines de leurs traductions les plus fréquentes en français : *mwen dòmi* : j'ai dormi ; *mwen ka dòmi* : je dors ; *mwen ké dòmi* : je vais dormir ; *mwen té dòmi* : j'avais dormi ; *mwen té ka dòmi* : je dormais ; *mwen té ké dòmi* : j'aurais dormi. Il faut cependant bien entendu garder à l'esprit qu'il ne s'agit pas d'équivalences systématiques, puisque les systèmes aspecto-temporels ne se recoupent pas, et que la notion de « mode » est étrangère au créole.

En première approche, on peut schématiser les domaines d'application des systèmes aspectuel et temporel en disant que la caractérisation de l'aspect (\emptyset , *ka* ou *ké*) ne porte que sur des verbes exprimant un procès, alors que la caractérisation du temps (\emptyset ou *té*) s'applique aussi bien aux procès qu'aux états. On a donc deux séries de verbes, celle qui peut suivre les marques \emptyset , *ka*, *ké*, *té*, *té ka* et *té ké*, et celle qui ne peut suivre que \emptyset ou *té*. C'est en ces deux séries de verbes, par exemple, que (Saint-Quentin, 1989), l'une des premières grammaires créoles, voulait distinguer deux « conjugaisons » du créole guyanais.

Selon cette description, les phrases (3a) et (3b) sont donc possibles et leur différence traduit une nuance d'aspect, alors que seule la phrase (4a) est recevable.

(3a) *I dòmi tout lajounen* (il a dormi toute la journée)

(3b) *I ka dòmi tout lajounen* (il passe ses journées à dormir)

(4a) *I ni anpil lajan* (il a beaucoup d'argent)

(4b) **I ka ni anpil lajan*

Cette description est en réalité une simplification, puisqu'il existe bel et bien des contextes dans lesquels l'application de marques aspectuelles à des verbes « à signifié non-processif » (Damoiseau, 1984) est attestée : *ravèt pa ka ni rézon douvan poul* (le ravet n'a jamais raison devant la poule) ; ou même : *lè i ka sòti kazino i ka ni anpil lajan* : à chaque fois qu'il sort du casino, il a plein d'argent. Nous nous en tiendrons cependant à la première approche dans le cadre de ces premières tentatives de modélisation.

Groupes nominaux

Les groupes nominaux du créole ont un système de degrés de détermination qui comprend un degré générique, exprimé par \emptyset (ainsi *ravèt* et *poul* dans l'exemple ci-dessus), un degré indéterminé (*an timanmay* : un enfant), un degré défini exprimé par un déterminant postposé (*timanmay-la* : l'enfant), et un degré démonstratif également exprimé par un déterminant postposé (*timanmay-tala* : cet enfant). Les déterminants postposés, en martiniquais, peuvent se combiner avec une marque préposée *sé-* pour former un pluriel défini (*sé-timanmay-tala* : ces enfants) — le pluriel générique du français n'ayant pas d'équivalent : on utilise le degré générique du singulier.

Il n'existe pas de genre grammatical ; en revanche les noms déterminent une variation dans le choix de l'article défini, selon un principe d'harmonie consonantique et nasale : les mots se terminant par une voyelle ouverte prennent la marque *-a* comme déterminant défini, les mots se

¹Les choses sont plus complexes en réalité, puisque la combinaison *ké ka* est également attestée avec une valeur de futur duratif — cf. (Pinalie & Bernabé, 1999, p. 77) : *lè ou ké rivé, nou ké ka dòmi* : quand vous arriverez, nous serons en train de dormir. La combinaison *té ké ka* est même possible (comme dans la chanson de zouk : « *Kolé séré nou té ké ka dansé* » \simeq nous serions en train de danser l'un contre l'autre). Valdman (1978, p. 219) expose un système plus complet fondé sur deux catégories d'aspect (\pm continuatif, \pm prospectif), et une catégorie de temps (\pm passé).

terminant par une consonne ou par une semi-voyelle (y ou w) prennent la marque *-la*. Ceci ne s'applique qu'aux mots dont la dernière syllabe est non-nasalisée ; Pour les mots à terminaison nasale, les marques du défini sont respectivement *-an* et *-lan*.

Parties du discours

L'un des faits les plus frappants du créole, enfin, est l'absence de frontières nettes de catégories grammaticales. La tentation de rapprocher les mots d'origine française de leurs étymons et de leur attribuer la même catégorie (nom, verbe, adjectif ...) est souvent grande, et elle a même assez fréquemment une certaine pertinence, mais cette analogie est trompeuse. Dans beaucoup de cas en effet, si un mot peut être utilisé dans le même emploi grammatical que son étymon français, il possède également d'autres emplois, propres à des catégories syntaxiques différentes.

Les adjectifs, par exemple, ont en français besoin d'un verbe copule pour figurer en fonction d'attribut : *le gros arbre* vs. *l'arbre est gros*. En créole, l'adjectif seul peut jouer le rôle de prédicat : *gwo pyébwa-a* vs. *pyébwa-a gwo* (cf. chinois *dà shùmù* vs. *shùmù dà*). L'adjectif dans cette position de prédicat-attribut peut également recevoir les marques temporelles de la même manière que les verbes d'état : *pyébwa-tala té gwo* : cet arbre était gros ; voire des marques aspectuelles dans certains contextes, comme les verbes d'état également (exemple cité par Damoiseau (1984, p. 29) : *i ka las vit* : il se fatigue vite). Il est en fait très difficile de fournir une définition permettant de distinguer le verbe en tant que catégorie distincte de l'adjectif autrement que par des critères négatifs (blocage de la fonction épithète).

Au-delà du cas des verbo-adjectivaux, des « noms » peuvent apparaître en position de prédicat (*i yich mwen* : c'est mon enfant), et des « verbes » en fonction nominale (*mwen dòmi an bel dòmi* : j'ai sacrément dormi [litt. j'ai dormi un grand dormir] ; *vin pran an bwè* : viens prendre un verre [litt. viens prendre un boire]) ; et ces tournures sont loin d'être des exceptions ou des figures de style, mais font partie du fonctionnement le plus banal de la langue. Certains verbes, en outre, occupent des fonctions de préposition. Ainsi, le verbe *ba* (donner), qui construit généralement des phrases avec trois actants (*i ba mwen an pen* : il m'a donné un pain), peut, accompagné du seul actant *destinataire*, construire un syntagme qui joue le rôle de circonstant pour les verbes n'ayant pas le destinataire dans leur cadre valenciel de base. Ainsi dans *i pòté an boutèy wonm ba mwen* : il m'a apporté une bouteille de rhum, ou *mwen ka palé ba'w* : je suis en train de te parler (cf. chinois *tā gěi wǒ yī píng jiǔ* : il me donne une bouteille d'alcool, vs. *tā dàilái le yī píng jiǔ gēi wǒ*, il m'a apporté une bouteille d'alcool). Certains verbes enfin peuvent être employés comme particules aspectuelles, enrichissant le système fondé sur { \emptyset , *ka*, *ké* et *té*} ; ainsi *sòti* (sortir) ou *fini* (finir) dans des tournures comme : *es ou kompwann sa yo sòti di'w la ?* : est-ce que tu comprends ce qu'ils viennent de te dire ? (Bernabé, 1983, p. 1057), ou *pwan* (prendre) dans : *i pwan kouri* : il s'est mis à courir (Bernabé, 1983, p. 1043).

3 Modélisation

On pourrait donner encore d'innombrables exemples de cette plasticité grammaticale ; la leçon qu'il convient d'en tirer dans le cadre de ce travail (modélisation informatique), est qu'il faut développer un mécanisme pour la prendre en compte, car elle est tout sauf marginale.

Il serait peu pratique de multiplier les catégories grammaticales *ad hoc* en faisant un produit cartésien sur les catégories de la grammaire française pour obtenir des parties du discours sur-spécialisées (adjectif-verbe-qui-ne-peut-jamais-être-un-nom, ou nom-pouvant-servir-

parfois-de-verbe-d'état ...). Il nous paraît également qu'il serait assez artificiel de prévoir un grand nombre de règles de conversion ; il semble en définitive que la catégorie grammaticale soit une notion moins essentielle en créole martiniquais qu'en français, ou autrement dit — car il faut bien tout de même des fonctions dans l'énoncé — qu'elle soit plus qu'ailleurs contextualisable. Le fait qu'un mot ait la possibilité de remplir une fonction de sujet (comme un groupe nominal), d'épithète (comme un adjectif), de prédicat (comme un verbe) ... semble pouvoir être déterminé de manière afférente aussi bien qu'inhérente, pour reprendre ici le vocabulaire de Rastier (1987). Un mot peut avoir un emploi central de verbe, mais, placé dans un contexte de groupe nominal (avec un article, par exemple), pouvoir être interprété sans difficulté comme un nom. De même, un nom, placé directement après le sujet, et éventuellement temporalisé par une particule comme *té*, peut jouer le rôle d'un verbe si son sens s'y prête. Ces réflexions sont d'ailleurs probablement valides *en principe* pour toutes les langues², quoiqu'à des degrés variables.

Il a donc été choisi de ne retenir que deux grandes catégories grammaticales (**N** et **Pred** : nom et prédicat), lesquelles peuvent être déterminées plus spécifiquement par des ensembles de traits caractérisant leurs emplois possibles :

Pred possède les attributs $\langle \text{type} \rangle = T$, $\langle \text{cadre} \rangle = C$, $\langle \pm \text{epithete} \rangle$. Le *type* T classe le mot soit parmi les verbes exprimant un procès (*dòm* : dormir, *manjé* : manger, *ba* : donner, *pòté* : porter, etc.), soit parmi les verbes ou les verbo-adjectivaux exprimant un état (*ni* : avoir, *sav* : savoir, *gwo* : gros/être gros, *las* : fatigué/être fatigué, etc.). Le *cadre* C correspond au cadre d'attribution de positions syntaxiques aux actants du verbe (sous-catégorisation verbale) : intransitif pour *dòm* ou *las*, transitif pour *manjé*, attributif pour *ba*, etc. Le trait *épithète*, à valeur binaire, détermine si le mot peut oui ou non apparaître en position épithète, comme un adjectif : il est positif pour *gwo* et négatif pour *manjé*, par exemple.

N possède l'attribut $\langle \text{harm} \rangle = A$, qui détermine le type de marque de détermination définie qui doit apparaître selon la syllabe finale (A peut valoir *a*, *la*, *an* ou *lan*). Les noms propres et les pronoms personnels possèdent également le trait $\langle \text{det} \rangle = \text{def}$, qui exprime le fait qu'ils sont déjà définis (et ne se combinent donc plus avec un déterminant) — le trait $\langle \text{det} \rangle$ n'apparaissant dans les autres cas qu'au niveau de barre 2, c'est-à-dire au niveau du groupe nominal. Le fait qu'un **N** puisse oui ou non apparaître également en fonction verbale est déterminé par la présence, à côté de ces traits spécifiquement nominaux, du trait $\langle \text{cadre} \rangle = C$ signalant l'existence d'une valence interne.

Cette conception des catégories comme faisceaux de traits évoque celle qui guide le formalisme des grammaires syntagmatiques généralisées (GPSG) (Abeillé, 1993, p. 101–105). Nous avons toutefois préféré utiliser pour ce travail le formalisme des grammaires d'arbres adjoints à unification de structures de traits (FS-TAG) (Vijay-Shanker & Joshi, 1988), (Abeillé, 1993, ch. 4), qui se prête tout à fait bien à la génération (bien qu'il ait d'abord été conçu pour l'analyse) grâce à sa capacité à représenter les tours de phrase sous la forme d'arbres élémentaires s'étendant sur plus d'un seul niveau. L'utilisation de modèles d'arbres adjoints pour la génération a été pour cette raison adoptée dans différents travaux de recherche, d'autant qu'elle a pu être étendue au-delà du niveau de la phrase, comme dans le modèle G-TAG (Danlos, 1998).

Nous n'avons en revanche pas, pour cette application de génération, une grammaire TAG entièrement lexicalisée ; les arbres sans ancre lexicale nous permettent en effet de donner une

²Ainsi, un énoncé comme *je mère-poule mes enfants* est tout à fait compréhensible — sinon recevable — en français (exemple emprunté à Jacques Coursil).

description formelle homogène à des structures parallèles, dont les unes s'expriment avec une marque lexicale et les autres avec une marque zéro (ex. imperfectif en *ka* vs. perfectif en \emptyset). En outre, les arbres sans ancre lexicale permettent (a) de faire l'économie de quelques kilo-octets de fichier, et de nombreuses opérations de copie-collé, en regroupant sous un même « arbre schéma » toutes les structures verbales ayant le même cadre de sous-catégorisation ; (b) de rendre compte des phénomènes linguistiques de degré de complexité supérieur à la phrase nucléaire (comme les subordonnées relatives) (Abeillé, 1993, p. 230).

Construction du GN

Le **N** non encore défini, mais qui peut avoir déjà reçu des compléments (en termes de théorie de X-barre, le \bar{N}), se substitue à la position adéquate dans l'arbre élémentaire du déterminant pour former le **GN** (niveau de barre 2). Le cas du déterminant indéfini est illustré fig. 1a (la valeur du trait *harm*, A, est une variable), et un exemple de déterminant défini est illustré fig. 1b³.

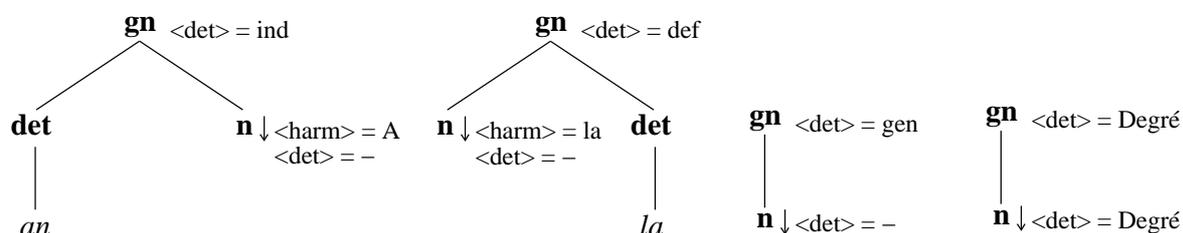


FIG. 1 – Arbres élémentaires : (a) du déterminant indéfini ; (b) d'un déterminant défini ; (c) du degré de détermination générique ; (d) du nom déjà défini.

Cette modélisation place le déterminant défini postposé *après* les éventuels compléments, comme les compléments de nom, ou les subordonnées relatives. Ceci est conforme avec l'usage du créole martiniquais, qui dit : *kay-la* (la maison) ; *kay papa mwen an* (la maison de mon père) ; *kay mwen ja palé ba'w la* (la maison dont je t'ai parlé).

Le **GN** déterminé au degré générique se construit à partir du nom non encore déterminé grâce à l'arbre représenté en fig. 1c ; tandis que le **GN** peut également se constituer directement sur la base d'un **N** pré-déterminé au niveau lexical, comme un pronom personnel ou un nom propre, comme illustré fig. 1d.

Construction du GPred

Le prédicat connaît trois niveaux d'expansion, conformément au choix que nous avons fait de nous conformer au modèle simplifié du temps et de l'aspect présenté par Damoiseau (1984) (cf. plus haut).

Au niveau lexical, le **Pred** n'est marqué ni en temps ni en aspect. Au niveau 1, il est marqué en aspect : soit avec une valeur d'aspect *zéro*, dans le cas où il s'agit d'un état ; soit avec une valeur d'aspect *perfectif*, *imperfectif* ou *prospectif*, s'il s'agit d'un procès. Les arbres correspondant à l'aspect zéro (pour un état), et à l'aspect perfectif (pour un procès), sont montrés respectivement en fig. 2a et fig. 2b. Les aspects imperfectif et prospectif sont formés à l'aide des marques *ka* et *ké*. L'arbre correspondant au cas de l'aspect imperfectif est montré en fig. 2c. L'aspect prospectif se construit de la même manière.

³N.B. Dans ces figures, comme dans les suivantes, conformément à la tradition héritée du langage Prolog et du formalisme des grammaires à clauses définies (DCG), les termes commençant par une majuscule correspondent à des variables, alors que les termes commençant par des minuscules correspondent à des valeursinstanciées.

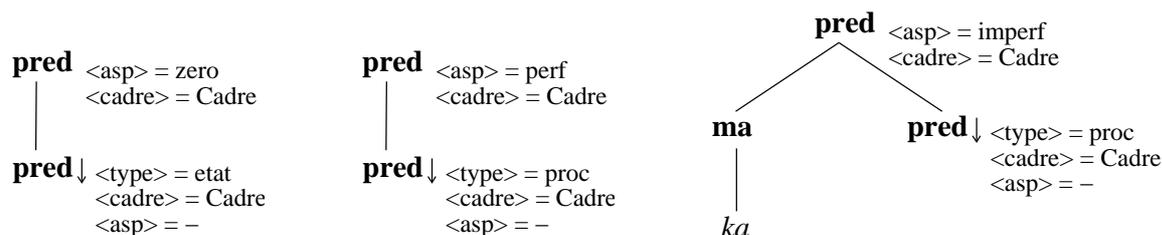


FIG. 2 – Arbres de construction du prédicat : (a) aspect zéro ; (b) aspect perfectif ; (c) aspect imperfectif.

Au niveau 2, le prédicat est marqué en temps, soit avec la marque zéro (\emptyset), soit avec la marque du passé (*té*) ; les mécanismes utilisés correspondent respectivement, à un niveau d'expansion au-dessus, à ceux utilisés pour marquer respectivement l'aspect perfectif ou l'aspect imperfectif sur les prédicats-procès. La marque de temps s'applique à un terme de niveau 1 ($\overline{\text{Pred}}$) qui peut donc être soit un état (automatiquement à l'aspect zéro), soit un procès (déjà marqué en aspect). Dans l'arbre élémentaire servant à passer du prédicat marqué en aspect ($\overline{\text{Pred}}$) au prédicat marqué en temps et en aspect ($\overline{\overline{\text{Pred}}}$), le nœud inférieur (nœud de substitution) doit donc spécifier la présence du trait *aspect* et l'absence du trait *temps*, puis reporter le trait *aspect* au niveau supérieur, et y ajouter le trait *temps* — le nœud supérieur comportant donc en tout les traits *temps*, *aspect* et *cadre*.

Enfin, au niveau supérieur, $\overline{\overline{\text{GPred}}}$, le prédicat marqué en temps et en aspect ($\overline{\overline{\text{Pred}}}$) est entouré de ses actants, dans la disposition spécifique du cadre de sous-catégorisation concerné. Le trait *cadre* est supprimé, et un trait *saturé* est ajouté. La phrase nucléaire (**Ph**) est constituée d'un sujet et d'un $\overline{\overline{\text{GPred}}}$ saturé.

Les différents cadres de sous-catégorisation sont représentés par des arbres-schéma (fig. 3), qui engendrent des familles d'arbre lorsque l'on y greffe les arbres des différents prédicats marqués en temps et en aspect.

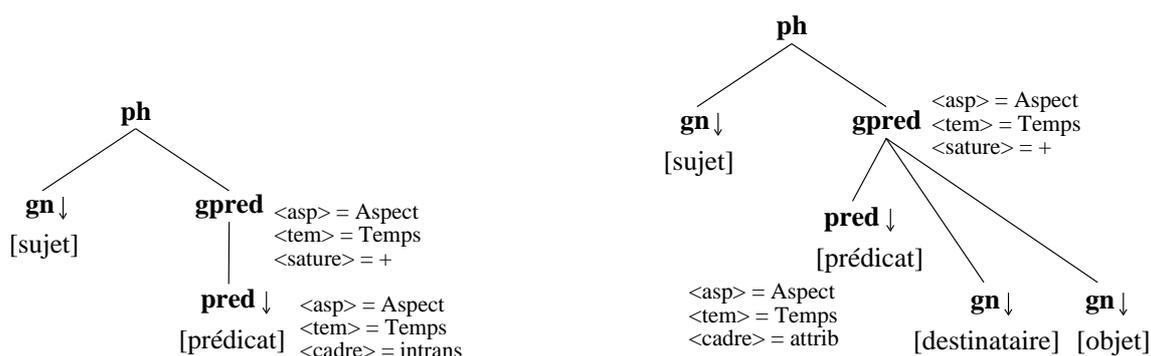


FIG. 3 – Arbres schéma : (a) des verbes intransitifs ; (b) des verbes attributifs.

Les circonstants, c'est-à-dire les rôles sémantiques qui n'ont pas pu être exprimés par les actants du cadre valenciens de base du verbe, sont exprimés par l'adjonction de syntagmes prépositionnels. Comme dans le cas déjà évoqué des compléments d'attribution introduits par *ba*, le rôle des prépositions peut parfois être joué par des verbes accompagnés d'un jeu « restreint » d'actants. Ces types de syntagmes sont modélisés comme des $\overline{\overline{\text{GPred}}}$, à la différence que le verbe y est utilisé avec un autre cadre de sous-catégorisation ; le cas est donc traité comme une alter-

nance verbale. Ainsi, le verbe *ba* possède, à côté de son cadre « complet » (*attributif*), un cadre « restreint » (*prep_datif*) qui est utilisé pour former les arbres auxiliaires pour l'adjonction de compléments d'attribution, grâce à l'arbre-schéma représenté fig. 4. Un trait *saturé*, contraignant l'adjonction sur le nœud pied de ce type d'arbres, garantit que les circonstants ne peuvent commencer à s'adjoindre au **GPrep** qu'après tous les actants (sujet excepté).

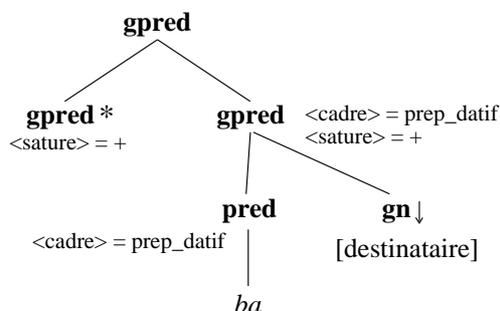


FIG. 4 – Arbre auxiliaire pour exprimer les compléments d'attribution.

4 Mécanisme de génération

Le programme réalisé implante informatiquement les arbres décrits par des structures PROLOG. Toutes les opérations élémentaires sur les structures de traits (unification, écrasement) ont été également implantées sous la forme de buts PROLOG, ainsi que les opérations sur les arbres spécifiques au modèle TAG (substitution et adjonction).

La structure de départ du processus de génération est un graphe conceptuel contenant des nœuds liés entre eux par des rôles sémantiques. Les nœuds peuvent porter des attributs sémantiques qui servent à en préciser la valeur (temps, aspect, degré de détermination ...) Le programme effectue la génération en parcourant le graphe conceptuel en un parcours direct (arbre de couverture du graphe), et en engendrant, pour chaque prédicat, un arbre correspondant à la verbalisation de ce prédicat et de ses actants fondamentaux sous la forme d'une phrase nucléaire. Les rôles sémantiques non-verbalisés dans la phrase nucléaire sont ensuite générés sous forme d'arbres auxiliaires à tête **GPred**, et adjoints à la phrase nucléaire. Enfin, les relations sémantiques incidentes à l'un des concepts de l'arbre de couverture direct, mais non encore exprimées dans la phrase principale, sont soit adjointes lorsque c'est possible par un procédé syntaxique commun (épithète, subordonnée relative), soit générées dans de nouvelles phrases juxtaposées à celles déjà engendrées. Ce mécanisme a été exposé plus en détail dans (Vaillant, 1997; Vaillant, 1998), et reste fondamentalement le même, indépendamment de la langue à laquelle il est appliqué.

5 Conclusion

Dans ce travail, une grammaire à adjonction d'arbres a été utilisée pour passer d'une structure sémantique limitée au niveau phrastique à une lexicalisation en langue créole. Nous n'avons pas eu l'ambition en revanche d'essayer de partir d'une structure sémantique « interlangue » ou « indépendante de la langue ». Le système des paramètres sémantiques utilisés pour le temps et l'aspect, par exemple, est ni plus ni moins celui de la langue créole martiniquaise (ou tout ou

moins du sous-ensemble que nous prétendons en modéliser). La question de l'existence d'une étape encore antérieure à la représentation liée à la structure sémantique de la langue-cible n'est pas abordée dans le cadre de cette étude, qui se borne à réaliser la génération de la chaîne syntagmatique à partir d'un modèle du sens dans la même langue, représenté sous forme de graphe. Tout au plus peut-on noter que le même système peut servir, à quelques modifications de la grammaire près, pour des dialectes proches, qui ont à peu près le même système sémantique (ainsi le guadeloupéen, ou le guyanais de la côte).

La question de l'étape antérieure se pose en réalité dans deux contextes : soit dans les tentatives de modélisation des processus cognitifs fondamentaux, qui postulent l'existence d'une hypothétique représentation sémantique profonde, ou universelle ; soit dans les applications de transfert d'un système sémiotique à un autre, donc de génération de phrases créoles, par exemple, à partir d'une entrée qui pourrait aussi bien être formulée en français, en allemand, en chinois, ou en idéogrammes Bliss. Nous viendrons à l'avenir à nous pencher sur le second problème, qui pourra être le noyau d'un futur système d'aide à l'apprentissage, destiné par exemple à des apprenants n'ayant pas le créole pour langue maternelle. Quant au premier problème, il nous semble hors de notre portée. On pourra se consoler en évoquant l'hypothèse du créoliste innéiste Bickerton (1981), selon lequel ressurgissent dans les langues créoles les structures innées du langage faisant partie du « bioprogramme » de l'humanité. Selon cette hypothèse, donc, s'il existe une quelconque structure sémantique universelle, c'est précisément celle que nous avons sous la main avec le créole ...

Références

- ABEILLÉ A. (1993). *Les nouvelles syntaxes*. Paris: Armand Colin.
- ALLEYNE M. (1996). *Syntaxe historique créole*. Hommes et sociétés. Paris: Karthala.
- BERNABÉ J. (1983). *Fondal-natal*. Paris: L'Harmattan. 3 vols.
- BICKERTON D. (1981). *Roots of language*. Ann Arbor (É.U.A.): Karoma.
- CHAUDENSON R. (1995). *Les Créoles*. Que sais-je ? Paris: PUF.
- DAMOISEAU R. (1984). *Éléments de grammaire du créole martiniquais*. Fort-de-France: Hatier Antilles.
- DANLOS L. (1998). G-TAG : un formalisme lexicalisé pour la génération de textes inspiré de TAG. *Traitement Automatique des Langues — T.A.L.*, **39**(2), 4–32.
- PFÄNDER S. (2000). *Aspekt und Tempus im Frankokreol*. ScriptOralia. Tübingen (R.F.A.): Gunter Narr.
- PINALIE P. & BERNABÉ J. (1999). *Grammaire du créole martiniquais*. Paris: L'Harmattan.
- RASTIER F. (1987). *Sémantique Interprétative*. Formes Sémiotiques. Paris: PUF.
- SAINT-QUENTIN A. D. (1989). *Étude sur la grammaire créole*, In *Introduction à l'histoire de Cayenne, suivie d'un recueil de contes, fables et chansons en créole*. Comité de la Culture, de l'Éducation et de l'Environnement de Guyane: Cayenne. Première édition 1872.
- VAILLANT P. (1997). *Interaction entre modalités sémiotiques. De l'icône à la langue*. Orsay: Université Paris-Sud. Thèse de doctorat.
- VAILLANT P. (1998). Interpretation of iconic utterances based on contents representation: Semantic analysis in the PVI system. *Natural Language Engineering*, **4**(1), 17–40.
- VALDMAN A. (1978). *Le créole : structure, statut et origine*. Paris: Klincksieck.
- VIJAY-SHANKER K. & JOSHI A. K. (1988). Feature structure based tree adjoining grammars. In *Proceedings of the 12th International Conference on Computational Linguistics (COLING)*, Budapest (Hongrie).