Cours sur le traitement automatique des langues (II)

Violaine Prince
Université de Montpellier 2
LIRMM-CNRS

L'analyse syntaxique

- Le but : fournir une structure interprétable d 'un texte.
  - si le langage est artificiel, il faut en plus vérifier la correction
- L 'outil principal de l 'analyse syntaxique
  - la grammaire
    - hors-contexte (langage artificiel)
    - ou dépendante du contexte

Grammaires hors contexte

- Rappel sur les grammaires
  - G = {Vn, Vt, S, P}
    - Vn : vocabulaire auxiliaire
    - Vt: vocabulaire terminal
    - S ∈ Vn : axiome
    - P ensemble fini de productions
      - p ∈ P si
      - p ∈ (Vn ∪ Vt) x (Vn ∪ Vt) et p=(w1, w2) .

- Le système défini par {Vt*, S, P} est un système formel
- Le langage L engendré par G est l 'ensemble des théorèmes du système formel
- En langage naturel :
  - V_n : ensemble des **catégories grammaticales** (étiquettes) et des catégories syntaxiques.
    - Ex : groupe verbal est une catégorie syntaxique. verbe est une catégorie grammaticale.

- V_t : ensemble des mots de la langue (dictionnaire)
- P : ensemble des règles de grammaire
- S : axiome unitaire (phrase)
- Structure syntaxique : arborescence mémorisant la démonstration permettant d 'obtenir un mot (dérivation).

correspond à A->w1w2

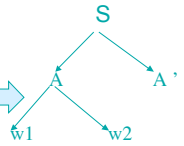

Hors contexte et dépendant du contexte

- G est dite hors contexte si, pour toute production du type
  - A->w, A ∈ V_n, et w ∈ V_n ou V_t.
- G est dite dépendante du contexte sinon.
- Exemples
  - une règle du type GN -> Nom préposition Nom est hors contexte
  - une règle du type GN-> Nom « de » Nom est dépendante du contexte

Les grammaires normées de Chomsky

- Une grammaire normée de Chomsky est un ensemble de règles de réécriture (ou production) de la forme :
- S—> S1 S2
  - avec S ∈ V_n, S1 ∈ V_n, S2 ∈ V_n
- Ou S —> A
  - Avec S ∈ V_n, A ∈ V_t.

Les grammaires normées de Chomsky

- S, S1 et S2 sont des symboles non terminaux (dans l'ensemble V_n des étiquettes grammaticales et syntaxiques)
- A est un symbole terminal (dans l'ensemble V_t des lexèmes)
- Exemple :
  - PH —> GN GV
  - GV—> V GN I V GNPREP
  - GN —> DET SN
  - GNPREP —> PREP GN
  - Sont des règles valides sur des symboles non terminaux

Les grammaires normées de Chomsky

- Les règles suivantes permettent d'inclure des symboles terminaux :
- DET —> Le
- SN —> chat
- SN —> souris
- SN —> sourire
- V—> manger
- V—> bondir
- V—> sourire
- PREP—> sur
- PREP —> à

On supposera que l'analyse morphologique est capable de reconnaître les flexions et les conjugaisons.

Les grammaires normées de Chomsky

- La grammaire ainsi définie, est capable de générer (ou de reconnaître) les phrases suivantes :
  - Le chat mange la souris.
  - Le chat bondit sur la souris.
  - Le chat sourit à la souris.

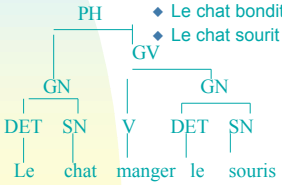

Génération et analyse

- Les grammaires de Chomsky sont des grammaires génératives (puissance en génération)
- L'analyse est vue comme un cas particulier d'appariement entre :
  - Une phrase fournie
  - Une phrase que l'on peut engendrer par la grammaire
- En raison de l'ambiguïté des étiquettes, la combinatoire en analyse est élevée, et l'élimination des combinaisons « fausses » est une tâche importante.

Combinatoire en analyse

- Exemple :
  - Le chat mange la souris.

On cherchera à construire deux arbres

(arborescence précédente)

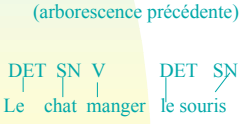

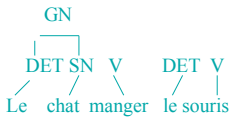

Combinatoire en analyse

- On dit que l'analyse a réussi si et seulement si, à partir d'une phrase donnée, on construit par les règles de grammaire une arborescence de nœud PH (racine).
- Dans l'exemple précédent, avec la valeur V pour « souris » la phrase ne mène pas à une arborescence de nœud PH. Elle doit donc être éliminée.

Difficultés et « backtracking »

- Plus la grammaire est importante, plus la combinatoire est élevée.
- Exemple :
  - Supposons que l'on rajoute la règle terminale :
    - GN —> Le
  - Pour rendre compte des pronoms personnels compléments d'objet.

Exemple de construction d'arborescences

Le	chat	mange	la	souris.
DET	SN	V	DET	SN
GN			GN	V

6 arborescences seront construites avec comme base

DET SN V DET SN (c'est la bonne)
GN SN V DET SN |= GN SN V GN |= GN SN GV
DET SN V GN SN |= GN V GN SN |= GN GV SN |= PH SN
DET SN V GN V |= GN V GN V |= GN GV V |= PH V
GN SN V GN SN |= GN SN GV SN
GN SN V GN V |= GN SN GV V
GN SN V DET V

Algorithme d'analyse

- Il existe un algorithme, nommé algorithme de Cock qui permet de savoir si une phrase est analysable par une grammaire normée de Chomsky, avec une complexité en $O(n^3)$. Fourni en TD.
- Une phrase peut ne pas être analysable par une grammaire de Chomsky parce que:
  - La grammaire est non couvrante
  - La phrase n'est pas grammaticale (mal formée).
  - Il y a des mots inconnus.

Théorème d'équivalence

- Toute grammaire de type réécriture, hors contexte, peut être réécrite sous forme de grammaire normée de Chomsky.
- Exemple :
  - S —> S1 S2 S3
  - S3 —> S5
  - S2 —> k
- Peut se réécrire sous forme :
  - S —> S1 S4
  - S4 —> S2 S3
  - S2 —> k

Intégrité de la grammaire

- Une grammaire est intègre en génération si tout symbole non terminal peut se réduire, par une série de réécritures, en un (ou plusieurs) symbole(s) terminal(ux).
- Pas de symboles « vides ».
  - Ex: GV —> V GNPREP
  - GNPREP —> PREP GN
  - Il faut qu'il existe une règle terminale avec PREP —> xxx

Les grammaires normées de Chomsky

- Pour le langage naturel :
  - Analyse en constituants
- Des défauts :
  - Rechercher une grammaire couvrante, intègre.
  - Ne traite pas les phrases agrammaticales
  - Multiplication des règles de génération pour les phrases particulières (nominales, subordonnées, relatives, etc…).

Les grammaires normées de Chomsky

- Pour une première approche des problèmes peut servir d'accroche « pédagogique » :
  - Implémentation de l'algorithme de Cock
  - Recherche de la couverture grammaticale d'un ensemble de phrases données (bien formées).
- Marche mal sur du tout venant, et sur des grandes masses de données.

Exemple d 'un analyseur syntaxique théorique : SYGMART

- Analyse morphosyntaxique
- Moteur de réécriture sur des objets cibles : structures syntaxiques
- Extension des algorithmes de Markov
- Puissance de la machine de Turing

Eléments de base

- Arborescences
  - Structures neutres.
  - Représentation :
    - chaîne de caractères sur le vocabulaire V = {(,)}
- Propriétés
  - transformation d 'arborescence : transformation de chaîne
  - Elément structuré : ensemble d 'arborescences.
  - Identification d 'arborescence : numéro (dimension)

- Etiquettes
  - Définies par une valeur
  - Variables typées : arithmétique (entière), flottant, chaîne, à valeur définie exclusive et non exclusive, potentielle (valeur définie mais non explicitée), référence (pointeur sur une autre étiquette).
- Fonction d 'étiquetage :
  - application d 'un noeud d 'une arborescence à une étiquette associée.
    - étiquetage morphologique : catégories grammaticales, nombre, genre

- VARIABLES UTILISEES
- DEFINIT Analyse
  - DECLARE variables_lexicales
    - CHAINE : frm.
    - POT: unite-lexicale.
  - FIN variables_lexicales.
  - DECLARE variables_grammaticales
    - EXC : categorie (PH,GN,GV,ART,ADJ,NM,PONCT)
    - NEX:nombre(sing,plur); genre(mas,fem).
  - FIN variables_grammaticales
- FIN analyse.

- Exemple :
  - « un court exemple montre les transformations.»

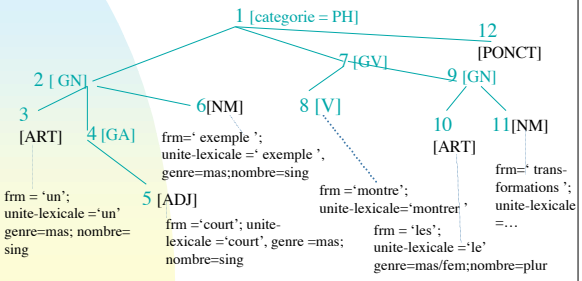

Transformations d 'élements structurés

- Schéma
  - ensemble d 'éléments structuré recherché dans l 'élément traité. Chaque élément a globalement la même structure, les variations portent sur l 'étiquetage, la présence (ou non) de certaines parties, l 'ordre entre les éléments.
- schéma d 'arborescence
  - soient deux arborescences A et B. A est une sous-arborescence de B s 'il existe une projection de A dans B.

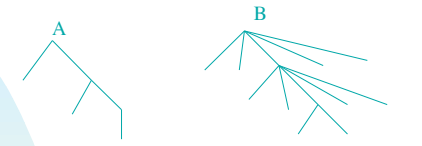

A est une sous-arborescence de B. La décomposition correspond à un traitement d'un ensemble d 'infixes (un infixe est un mot contenu dans un autre).

Contraintes sur la décomposition

- Dépendance : immédiate ou généralisée
  - dans la reconnaissance d 'une sous-arborescence, chaque point différent de la racine, dépend directement d 'un autre point.

- Contrainte de continuité

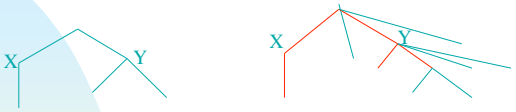

S 'il y a une contrainte de continuité entre X et Y, l 'arborescence de gauche ne peut pas être une sous-arborescence de l 'arborescence de droite.

- Contrainte d 'ordre

- Contrainte de présence
  - un noeud (et ses descendants) peut être déclaré optionnel
    - Le schéma A sera reconnu dans l 'arborescence B si le noeud X peut être déclaré optionnel.

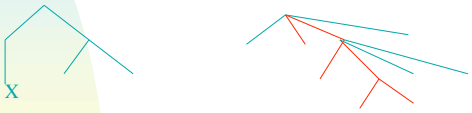

schéma A schéma B

- Schéma d 'élément structuré
  - Il est avant tout défini par des conditions sur les étiquettes associées aux noeuds par la fonction d 'étiquetage.
  - Conditions :
    - expressions booléennes portant sur les valeurs des variables.
    - deux types
      - conditions propres : l 'expression booléenne ne peut faire référence qu 'à une seule étiquette du schéma
      - conditions inter-sommets : elle peut faire référence à tout ou partie de l 'ensemble des noeuds du schéma.

- Exemple de schéma
- (0(1(2)3(4)))

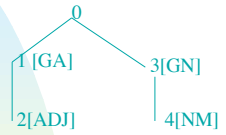

genre(2)&genre(4) != 0
Le nom et l'adjectif doivent être du même genre

- Identification d 'un schéma
  - lorsqu'un schéma est reconnu dans une arborescence, il identifie un ensemble de noeuds. Cette identification sépare les différents éléments de l 'arborescence en listes.

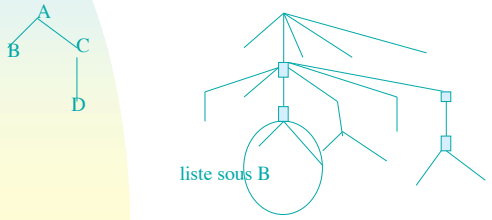

- liste d 'arborescence
  - A <B,C> : ensemble des éléments qui se trouvent sous le point associé à A, à droite du point associé à B et à gauche du point associé à C. A est obligatoire, B et C sont facultatifs.

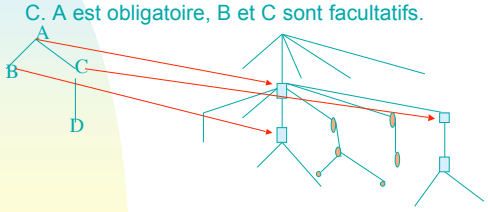

Réalisation des transformations

- Transformation d 'arborescence
  - on remplace la sous-arborescence, reconnue par le schéma de reconnaissance, par l 'arborescence de transformation.
- Transformation d 'élément structuré.
  - Une transformation est définie par un quadruplet (A, B, f, O)
    - A est un schéma de reconnaissance
    - B est un schéma de transformation
    - f est une fonction de l 'ensemble des listes de A dans l 'ensemble des listes de B.
    - O est une relation d 'ordre partielle telle que :
      - x et y deux listes de A telles que f(x)=f(y), alors 0(x,y) est défini.

Exemple

- On définit la transformation suivante :
  - schéma de reconnaissance

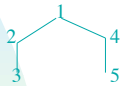

  - Schéma de transformation

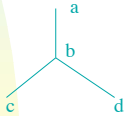

- Des applications permettant de définir f et O:
  - 1<,2> —> a<,b>
  - 1<2,3> —> a<,b>
  - 1<3,> —>a<b,>
  - 2<,> —>b<c,d>
  - 3<,> —>b <c,d>
  - 4 <,> —>c <,>
  - 5 <,> —> d <,>
  - soit :
  - (1(2(3) 4(5))) —>(a[* 1<,2> *,* 1<2,3>*](b ([*1<3,>*]c [*2<,>*, *3<,>*, *4 <,>*] d [2<,>*, *3<,>*, *5 <,>*])))

- Cette transformation peut s 'appliquer sur la structure suivante :

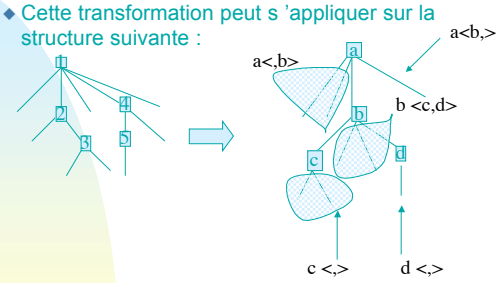

Grammaire

- Algorithme de Markov étendu aux éléments structurés.
  - un ensemble ordonné de règles de transformation.
  - modes de fonctionnement :
    - itératif (mode des algorithmes de Markov)
    - exhaustif (lorsqu 'une règle est appliquée elle est éliminée de la grammaire)
    - unitaire (mode itératif borné par une valeur numérique)

Exemples de règles « à la sygmart »

- La racine d 'un arbre d 'un texte à analyser est à 0.

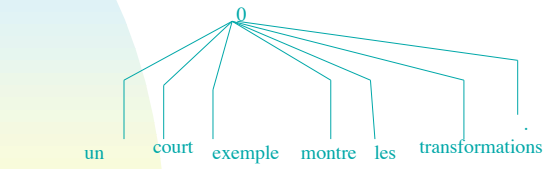

noeuds de niveau 1

- Eléments de la règle (transformation)
  - forme de la structure à transformer :
    - noeud1 (noeud2)

    - noeud1, noeud 2

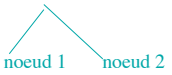

    - les noeuds doivent être contigus (contrainte de continuité)

- noeud1, *, noeud2

- conditions sur la structure à transformer :/ condition noeud1;condition noeud2;…;condition noeud n
- schéma de transformation:
  - insertion de noeud,
  - transformation de hiérarchie.

- insertion :
  - noeud-père:noeud-père (propriétés noeud-fils)

- modification de hiérarchie

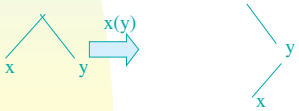

- R1 :0 (1),0:categorie = 0, 1: categorie = ADJ => 0:0: categorie = GA (insertion d 'un noeud sous 0)
- R2 : 0 (1), /0 :categorie = 0, 1: categorie = NM=>0:0: categorie = GN
- R3: 0 (1), 0 :categorie = 0, 1: categorie = V=> 0:0 : categorie = GV

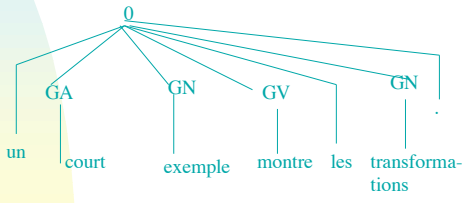

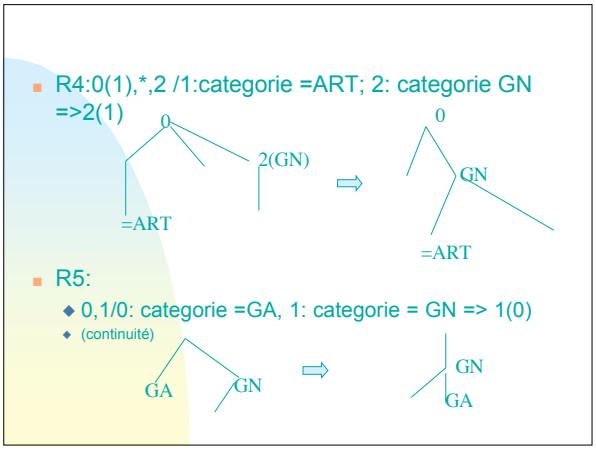
R4:0(1),*,2 /1:categorie =ART; 2: categorie GN =>2(1)
0
2(GN)
=ART
0
GN
=ART
R5:
0,1/0: categorie =GA, 1: categorie = GN => 1(0)
(continuité)
GA
GN
GN
GA

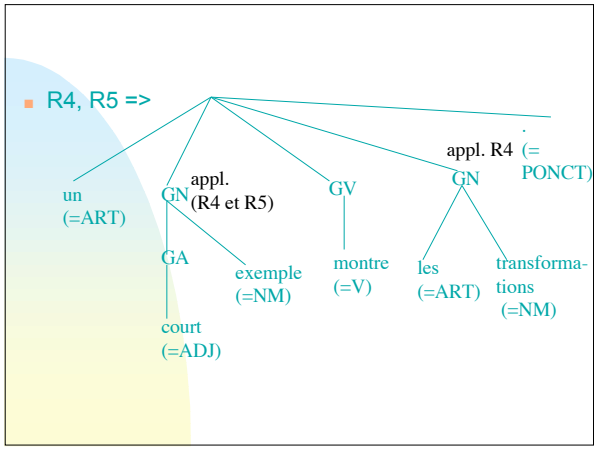
R4, R5 =>
un (=ART)
GN
appl. (R4 et R5)
GV
appl. R4
GN
. (= PONCT)
GA
exemple (=NM)
montre (=V)
les (=ART)
transforma-tions (=NM)
court (=ADJ)

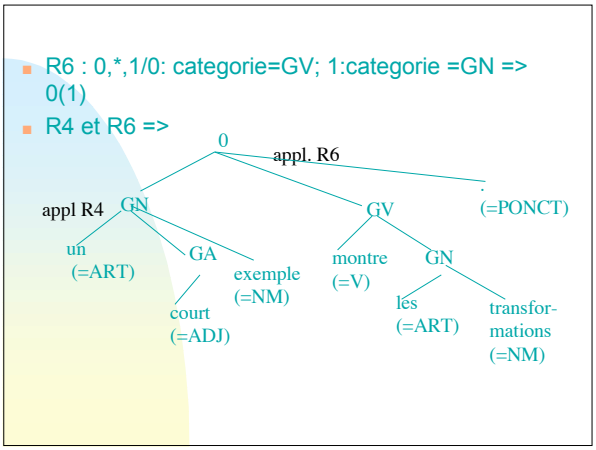
R6 : 0,*,1/0: categorie=GV; 1:categorie =GN => 0(1)
R4 et R6 =>
0
appl. R6
appl R4
GN
GV
. (=PONCT)
un (=ART)
GA
exemple (=NM)
montre (=V)
GN
court (=ADJ)
les (=ART)
transfor-mations (=NM)