

# Formalismes pour l'analyse syntaxique

Cours ENST – TALN

Vendredi 1er Mars 2002

Éric de la Clergerie

[Eric.De\\_La\\_Clergerie@inria.fr](mailto:Eric.De_La_Clergerie@inria.fr)

Transparents disponibles sur <http://atoll.inria.fr/~clerger> ► Enseignement

# La syntaxe existe-t-elle ?

A priori oui :

Un schtroumpf sachant schtroumpfer

"And hast thou slain the Jabberwock ?  
Come to my arms, my beamish boy !  
O frabjous day ! Callooh ! Callay !"   
He chortled in his joy.

'Twas brillig, and the slithy toves  
Did gyre and gimble in the wabe ;  
All mimsy were the borogoves,  
And the mome raths outgrabe.

« Jabberwocky » (Lewis Caroll)

Colorless green ideas sleep furiously [Noam Chomsky]

Mais débat sur

- la nature des constituants : Nom, Verbe, Determinant Syntagme Nominal, Syntagme Verbal
- les relations entre constituants : arborescentes, graphe, ...
- les fonctions linguistiques : sujet, objet, objet indirect, ...

# Théories linguistiques

Explication des phénomènes linguistiques

**ordre des mots** SOV VOS

**passif** le livre est donné à Paul par Anne

**extraction** Jean demande quel livre Paul est en train de lire

**Relatives** Jean connaît l'homme **que** Marie regarde **ε**.

**Interrogative** Jean demande **quel homme** Marie regarde **ε**.

**Clivées** C'est Jean **que** Marie regarde **ε**.

**Topicalisées** **Le chocolat amer**, Marie aime **ε**.

**coordination** Jean mange une pomme et Paul une poire

Existence d'une théorie « universelle » (couvrant tous les langages) ?

Liens avec la sémantique ?

# Formalismes

Cadre mathématique pour faire fonctionner les théories

Compromis entre expressivité et complexité (pour un traitement automatique)

Hiérarchie de Chomsky :

**Type 3** grammaires régulières (FSA)  $\Rightarrow$  linéaire

**Type 2** grammaires hors-contextes (PDA)  $\Rightarrow$  polynomiale

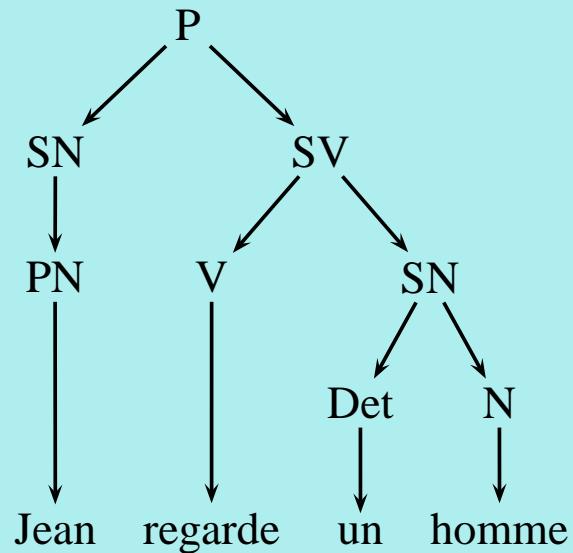
**Type 1** grammaires contextuelles (**Context-sensitive grammars**)

$uXv \rightarrow uyv$  y séquence non vide.  $\Rightarrow$  exponentielle

**Type 0** grammaires non contraintes (language récursivement énumérable)  $\Rightarrow$  indécidable

# CFG

P --> SN SV  
SN --> NP  
SN --> Det N  
SV --> V SN  
NP --> 'Jean'  
V --> 'regarde'  
Det --> 'un'  
N --> 'homme'

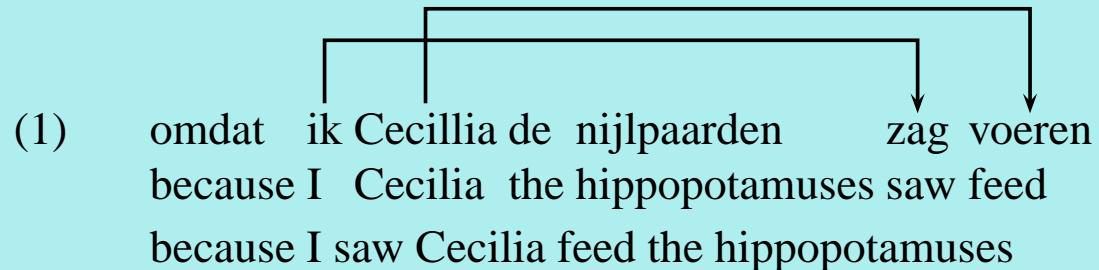


Difficultés de gestion des accords (nombre, genre, . . . ) : \*Jean mangent une homme  
Mais possible :

SN\_masc\_sing --> Det\_masc\_sing N\_masc\_sing  
SN\_masc\_plur --> Det\_masc\_plur N\_masc\_plur

## Autres limites

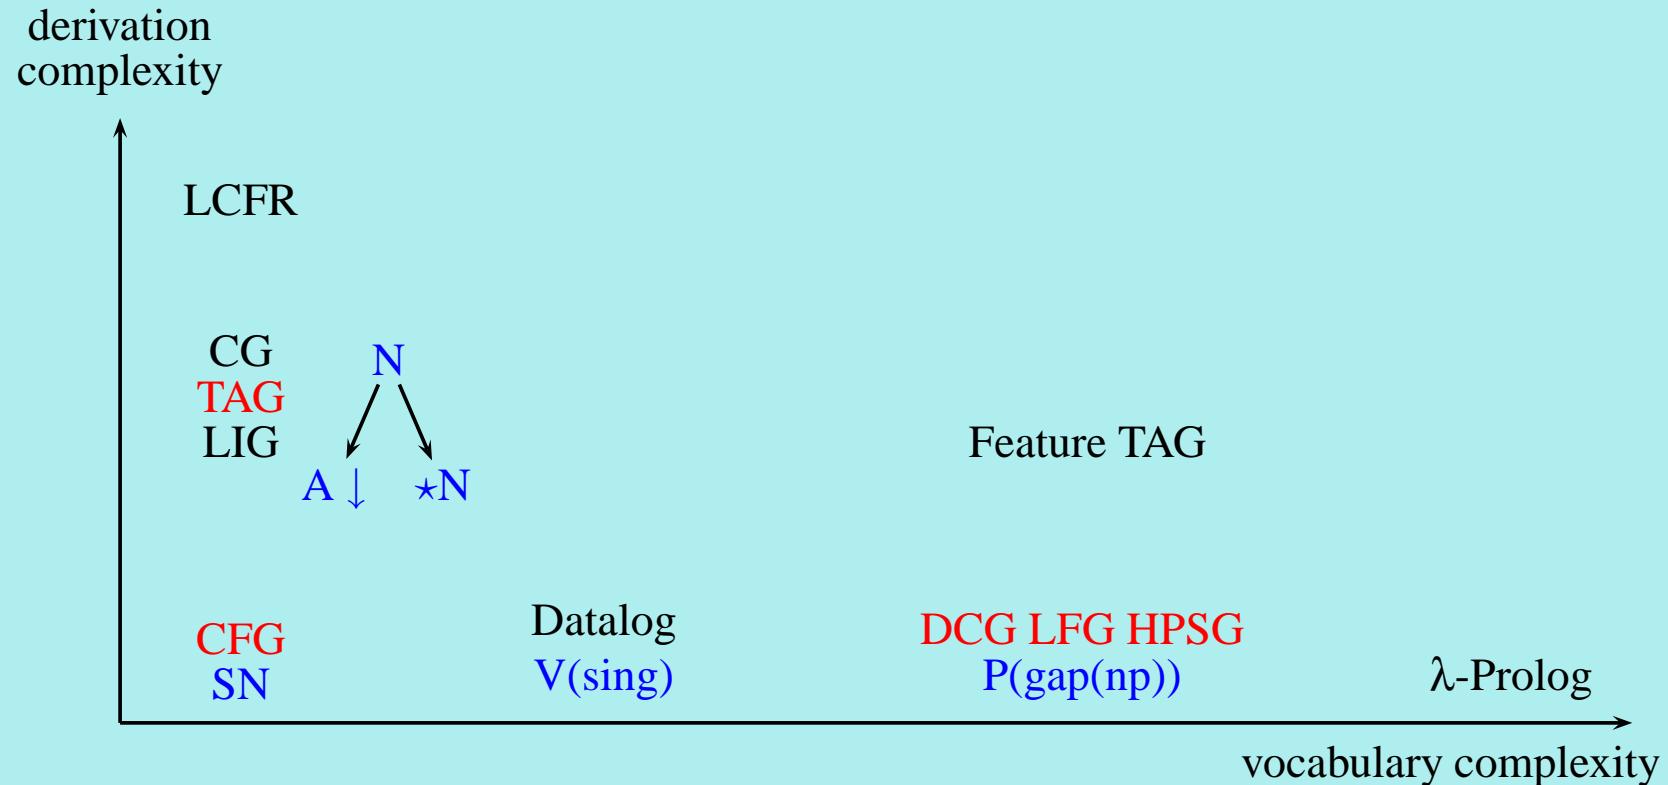
Les CFG manquent de puissance générative, par exemple pour les **croisements**



Autres difficultés :

- dépendances non bornées, extraction (topicalisation, relative, . . . )
- ordre « libre » des mots (**word scrambling**)

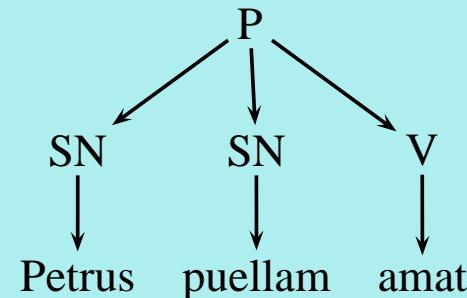
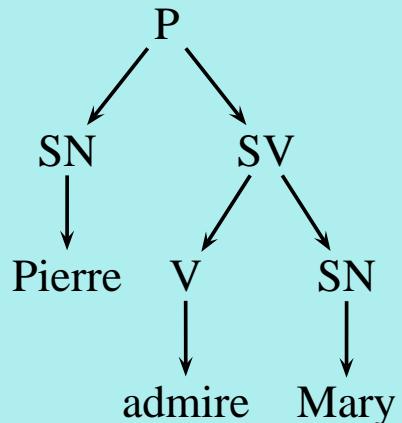
# Nature des formalismes grammaticaux



# Lexical Functional Grammars [LFG]

Bresnام et Kaplan (1982) The mental representation of grammatical representation

Théorie : Associer structures de constituants (**c-structures**) et structures fonctionnelles (**f-structure**) :



Suj	[Pred pierre]
Pred	admirer
Obj	[Pred mary]

Suj	[Pred pierre]
Pred	admirer
Obj	[Pred mary]

# Formalisme : Structures de traits

$$\left[ \begin{array}{c} \text{Det} \left[ \begin{array}{c} \text{Accord } \boxed{1} \left[ \begin{array}{c} \text{Num sing} \\ \text{Genr masc} \end{array} \right] \\ \text{Cat Det} \end{array} \right] \\ \\ \text{Nom} \left[ \begin{array}{c} \text{Accord } \boxed{1} \\ \text{Cat N} \end{array} \right] \end{array} \right]$$

# Unification de structures de traits

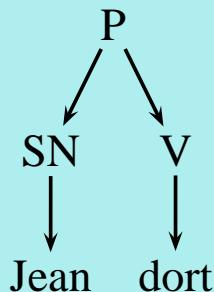
$$\left[ \begin{array}{l} \text{Det} \left[ \text{Accord} \left[ \text{Num sing} \right] \right] \\ \text{Nom} \left[ \text{Accord} \left[ \text{Num sing} \right] \right] \\ \text{Cat N} \end{array} \right] \sqcup \left[ \text{Det} \left[ \text{Accord} \left[ \text{Genre Masc} \right] \right] \right] = \left[ \begin{array}{l} \text{Det} \left[ \text{Accord} \left[ \begin{array}{l} \text{Num sing} \\ \text{Genre masc} \end{array} \right] \right] \\ \text{Nom} \left[ \text{Accord} \left[ \text{Num sing} \right] \right] \\ \text{Cat N} \end{array} \right]$$

$$\left[ \begin{array}{l} \text{Det} \left[ \text{Accord } \boxed{1} \left[ \text{Num sing} \right] \right] \\ \text{Nom} \left[ \text{Accord } \boxed{1} \right] \\ \text{Cat N} \end{array} \right] \sqcup \left[ \text{Det} \left[ \text{Accord} \left[ \text{Genre Masc} \right] \right] \right] = \left[ \begin{array}{l} \text{Det} \left[ \text{Accord } \boxed{1} \left[ \begin{array}{l} \text{Num sing} \\ \text{Genre masc} \end{array} \right] \right] \\ \text{Nom} \left[ \text{Accord } \boxed{1} \right] \\ \text{Cat N} \end{array} \right]$$

# Productions et équations fonctionnelles

Une grammaire est donnée par des productions CFG décorées par des équations fonctionnelles.

$$\begin{array}{lll} P \longrightarrow SN & V & SN \longrightarrow Jean \\ (\uparrow Suj) = \downarrow & \uparrow = \downarrow & (\uparrow Num) = sing \\ & & (\uparrow Genre) = masc \\ & & (\uparrow Pred) = 'Jean' \\ V \longrightarrow dort & & (\uparrow Suj Num) = sing \\ & & (\uparrow Suj Pers) = 3 \\ & & (\uparrow Mode) = indicatif \\ & & (\uparrow Pred) = 'dormir < Suj >' \end{array}$$



$$\left[ \begin{array}{l} \text{Suj} \begin{bmatrix} \text{Pred } 'Jean' \\ \text{Genre masc} \\ \text{Num sing} \end{bmatrix} \\ \text{Pred } 'dormir \langle \text{Suj} \rangle' \\ \text{Mode indicatif} \end{array} \right]$$

# Variations sur les équations

Contraintes existentielles :

$$\begin{array}{ll} \text{SN} \longrightarrow (\text{Det}) & \text{N} \\ \uparrow = \downarrow & \uparrow = \downarrow \end{array} \quad \begin{array}{ll} \text{N} \longrightarrow \text{Jean} & \sim(\uparrow \text{Det}) \\ & \end{array} \quad \begin{array}{ll} \text{N} \longrightarrow \text{chien} & \text{Det} \longrightarrow \text{le} \\ & (\uparrow \text{Det}) \\ & (\uparrow \text{Det}) = \text{le} \end{array}$$

Equations « contraintes »

$$\begin{array}{ll} \text{P}' \longrightarrow \text{SN} & \text{P} \\ & (\downarrow \text{Qu}) =_c + \quad (\uparrow \text{Qu}) = + \\ & \uparrow = \downarrow \end{array}$$

Equations ensemblistes

$$\begin{array}{ll} \text{SV} \longrightarrow \text{V} & (\text{SN}) \quad (\text{SP})^* \\ \uparrow = \downarrow & \uparrow \text{Obj} = \downarrow \text{ ou } \uparrow \text{Ajout} \ni \downarrow \quad \uparrow \text{Ajout} \ni \downarrow \end{array}$$

(Jean dort le matin.

Jean mange le gateau

Jean mange ce gateau avec Anne)

# Fonctions grammaticales

Fonctions catégorisables : Sujet, Objet, Comp(létive), XComp (infinitives et participiales), Prep-Obj (compléments prépositionnels, obliques)

Fonctions non-catégorisables : XAjout, X étant la catégorie

**Vcomp** Jean veut **partir à Rio**.

**Acomp** Jean devient **fou**.

**Ncomp** Ils ont élu Jean **président**

**Vajout** **Partant en voyage**, Marie se prépare

**Aajout** Paul est parti **content**

**Prep-Obj** Paul ressemble **à Jean**

# Sous-catégorisation

Le champ Pred indique les fonctions attendues par un mot.

**manger** ( $\uparrow$ Pred)=’manger<Suj,Obj>’

**donner** ( $\uparrow$ Pred)=’donner<Suj,Obj,A-Obj>’

**falloir** ( $\uparrow$ Pred)=’falloir<Obj>Suj’ et ( $\uparrow$ Suj Form) =<sub>c</sub> il

**vouloir** ( $\uparrow$ Pred)=’vouloir<Suj,Vcomp>’ et ( $\uparrow$ Suj)=( $\uparrow$ Vcomp Suj) Jean veut venir

**proposer** ( $\uparrow$ Pred)=’proposer<Suj,A-Obj,Vcomp>’ et ( $\uparrow$ Vcomp Suj)=( $\uparrow$ Suj)/( $\uparrow$ A-Obj)

Jean propose à Jean de venir

**destruction** ( $\uparrow$ Pred)=’destruction<De-Obj,Par-Obj>’ Destruction de la maison par les promoteurs

## Sous-catégorisation (2)

SP → Prep SN  
↑=↓ ( $\uparrow$ Obj)=↓

SP → Prep SV  
↑=↓ ( $\uparrow$ Vcomp)=↓  
(↓Mode=inf)

Prep → à  
( $\uparrow$ Pcas)=A

SV → V (SN) (SP)\*  
↑=↓ ( $\uparrow$ Obj)=↓ ( $\uparrow$ ( $\downarrow$ PCas)-Obj)=↓  
(↓Obj) ( $\uparrow$ ( $\downarrow$ PCas)-Vcomp)=↓  
(↓Vcomp)

# Dérivations lexicales : Analyse du passif

Certaines « transformations » syntaxiques analysables par des entrées lexicales dérivées  
(approche **lexicale**, alternative aux approches **transformationnelles**)

$$\begin{array}{l} Suj \Rightarrow \emptyset / Par - Obj \\ \textbf{Passif : } Obj \Rightarrow Suj \\ Vinf \Rightarrow Vppart \end{array}$$

donner, V :  $\uparrow \text{Pred} = \text{'donner<Suj,Obj,A-Obj>'}$

$\uparrow \text{Mode} = \text{inf}$

donné, V :  $\uparrow \text{Pred} = \text{'donner<\emptyset/Par-Obj,Suj,A-Obj>'}$

$\uparrow \text{Mode} = \text{ppart}$

$\uparrow \text{Passif} = +$

Non passivable : coûter :  $\uparrow \text{Pred} = \text{'couter<Suj,Ncomp>'}$

# Extractions

$P' \longrightarrow SN$

$P$

$(\downarrow Qu) =_c +$

$\uparrow = \downarrow$

$(\uparrow Focus) = \uparrow$

$(\downarrow Qu) = +$

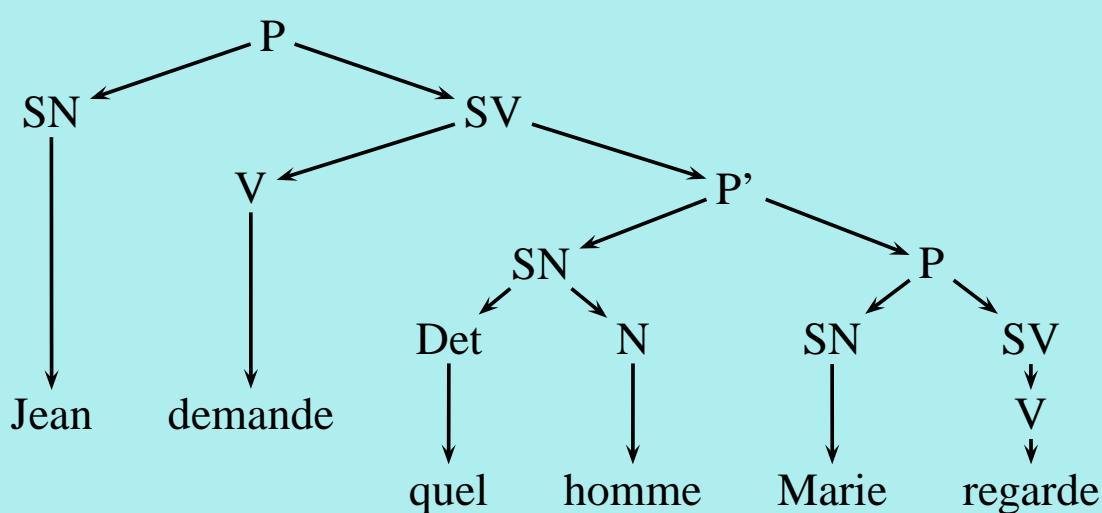
$(\uparrow Focus) = (\uparrow Obj)$

demande, V :  $(\uparrow Pred) = 'demander < Suj, Comp >'$

$(\uparrow Comp Qu) =_c +$

quel, Det :  $(\uparrow Det) = 'quel'$

$(\uparrow Qu) = +$

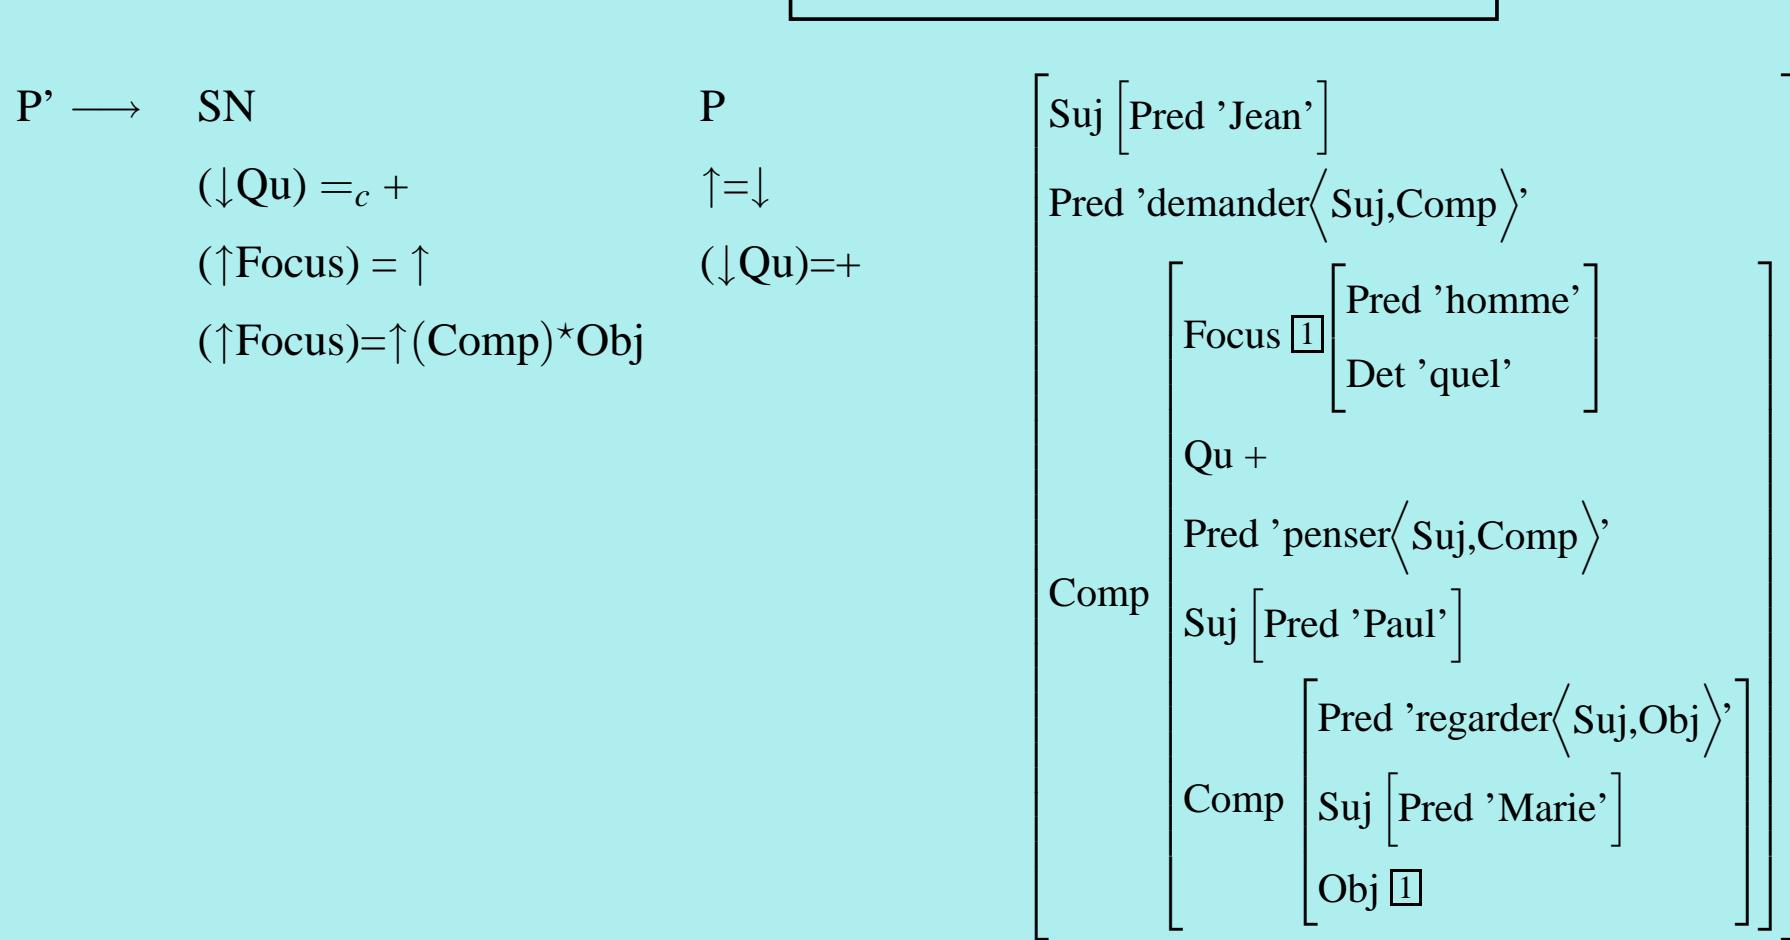


$Suj [Pred 'Jean']$   
 $Pred 'demander \langle Suj, Comp \rangle'$   
 $Comp$   
 $Focus [1] [Pred 'homme']$   
 $Det 'quel'$   
 $Suj [Pred 'Marie']$   
 $Qu +$   
 $Pred 'regarder \langle Suj, Obj \rangle'$   
 $Obj [1]$

# dépendances non bornées

Nombre arbitraire d'enchâssements entre un constituant extrait et le prédicat dont il dépend :

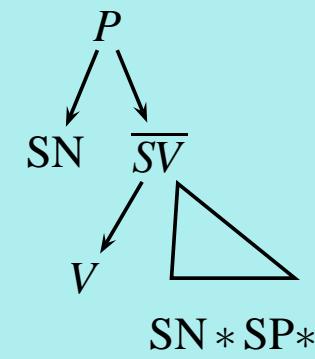
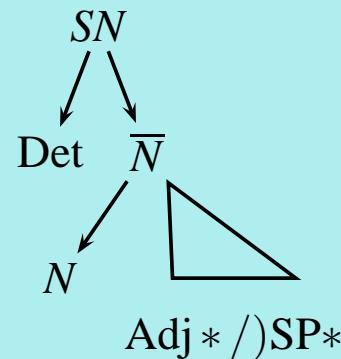
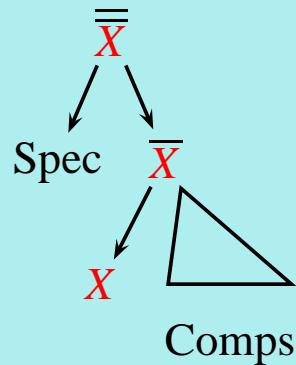
Jean demande [quel homme Paul pense [que Marie regarde  $\varepsilon$ ]]



# Head-driven Phrase Structure Grammars [HPSG]

Pollard et Sag (1987) *Information-based syntax and semantic*

- Théorie linguistique complète : phonologie, lexical, syntaxe, sémantique et pragmatique
- Approche lexicale, avec importance de la sous-catégorisation
- Notion de tête linguistique (Théorie X-Bar)

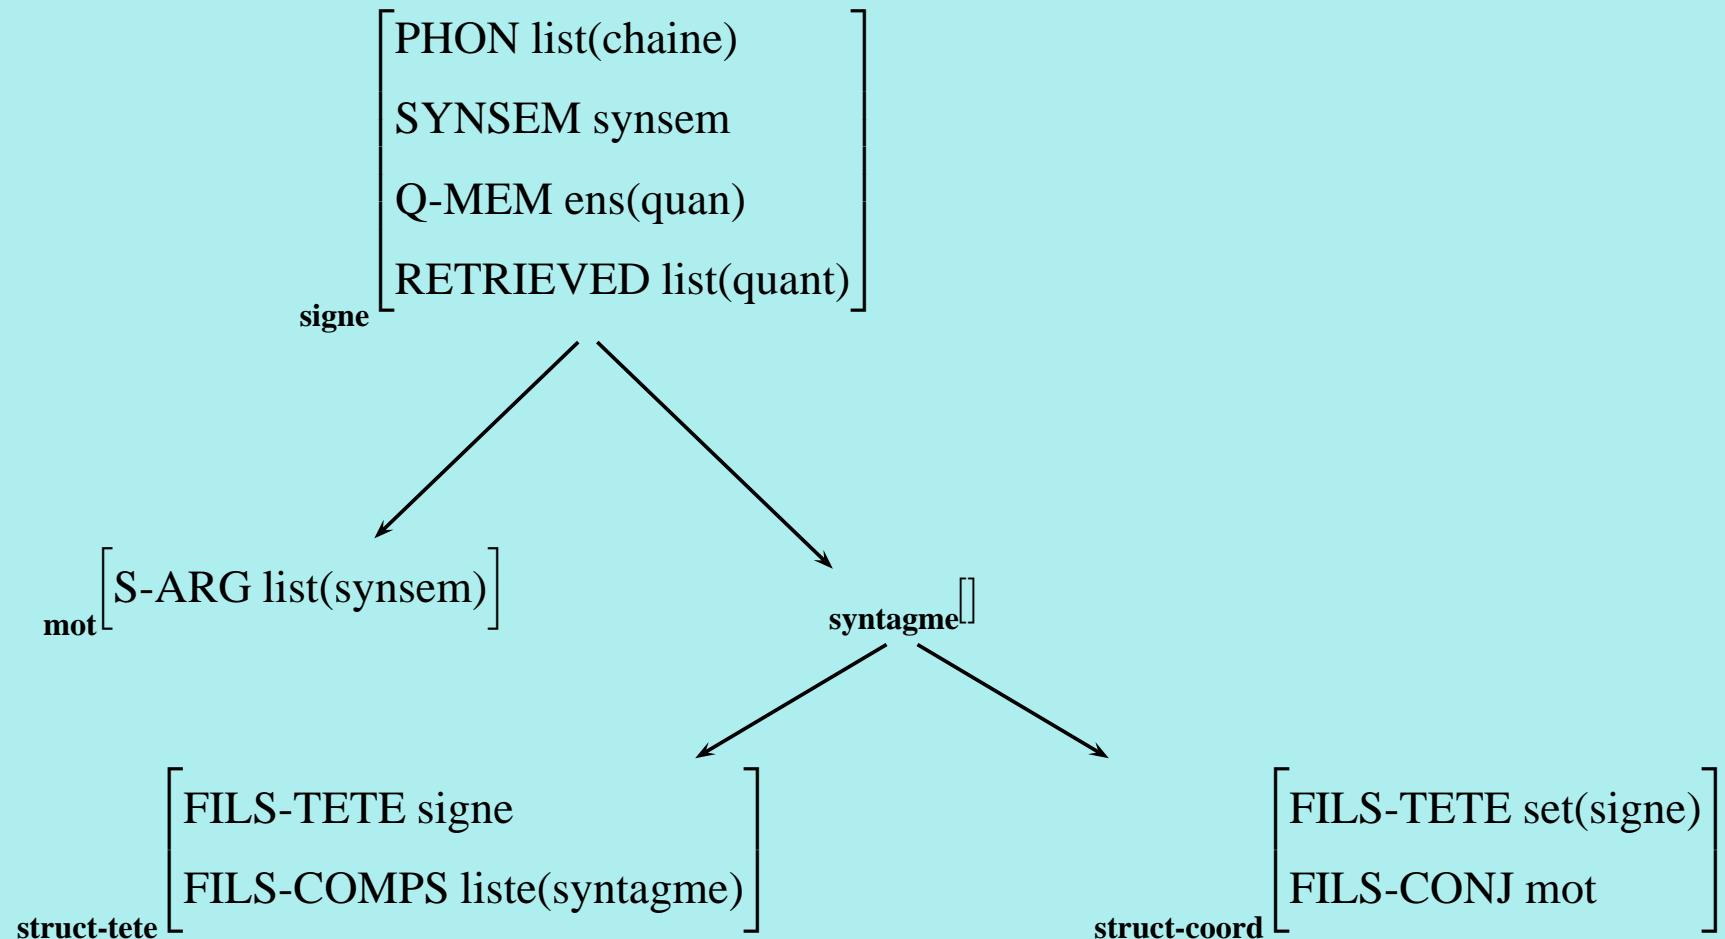


- Théorie en évolution (HPSG III)
- S'appuie sur un formalisme puissant et homogène : structures de traits typées [TFS]

Bob Carpenter (1992) *The logic of typed feature structures*

Structures de traits possédant un type défini dans une hiérarchie

# Hiérarchie de type



# Hiérarchie de type

Notation à la Prolog, utilisée dans ALE et DyALog.

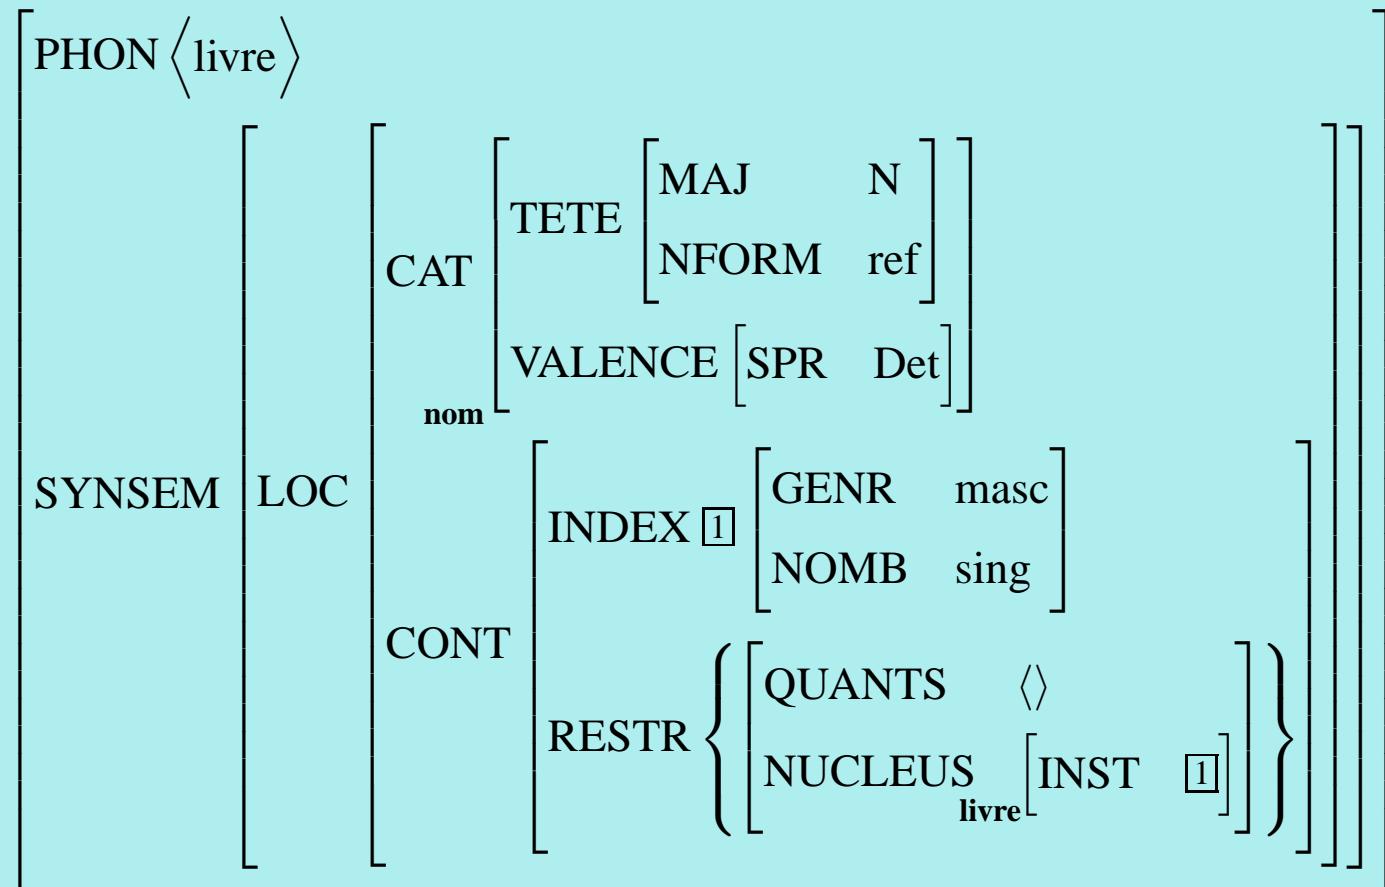
```
bot sub [ string , list , cat ,synsem].  
    string escape symbol.  
    cat sub [ s,np,vp,det,n ].  
        s sub []. np sub []. vp sub [].  
        det sub []. n sub [].  
    synsem sub [phrase,lexeme] intro [ cat : cat ].  
        phrase sub [ root ] intro [ args : list ].  
            root sub [] intro [ cat : s ].  
            lexeme sub [] intro [ orth : string ].  
        list sub [ ne_list , e_list ].  
            ne_list sub [] intro [ hd:bot, tl : list ].  
            e_list sub [].
```

- Un type peut introduire des sous-types
- Un type peut introduire ou préciser un trait et le type de sa valeur
- héritage multiple possible
- les types introduisant un trait  $f$  ont un type plus général

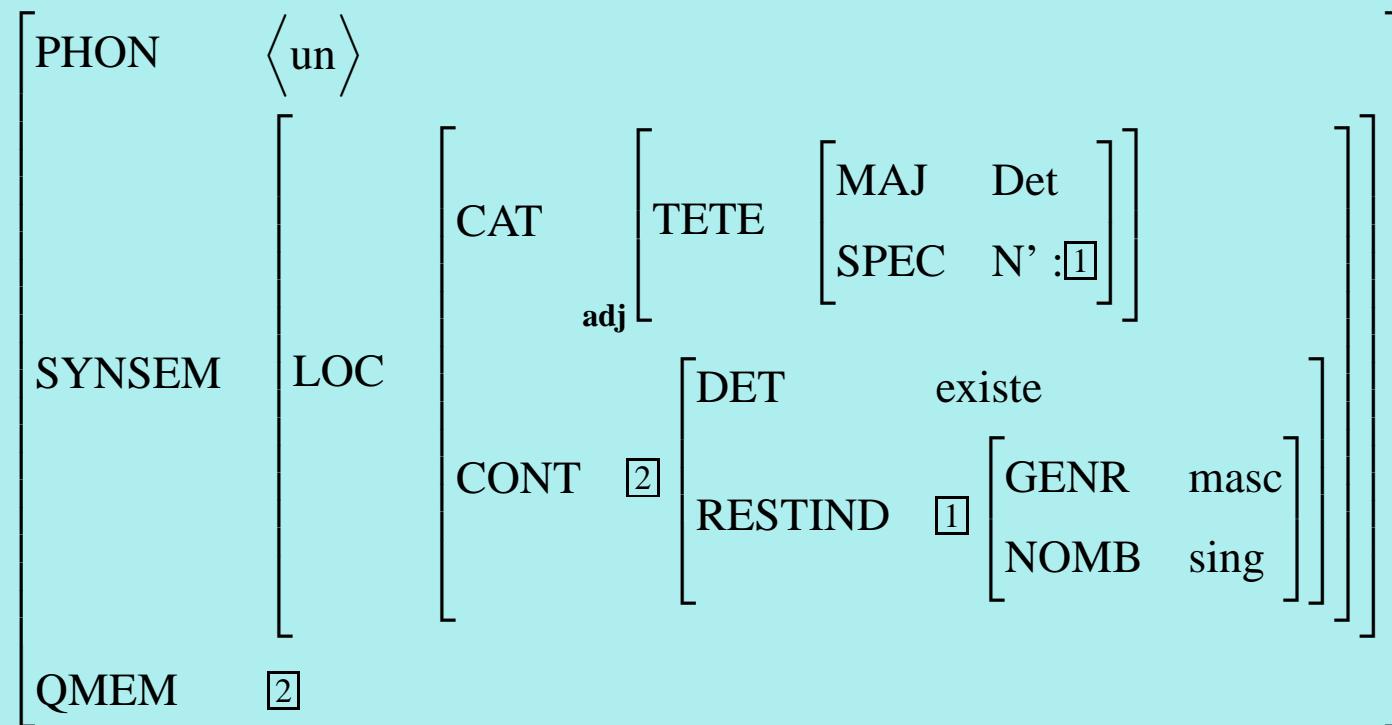
# Architecture HPSG

- entrées lexicales  
exploitant la notion de sous-catégorisation
- règles lexicales de dérivation de nouvelles entrées (ex. le passif)
- des schémas de construction des constituants
- des principes de bonne construction

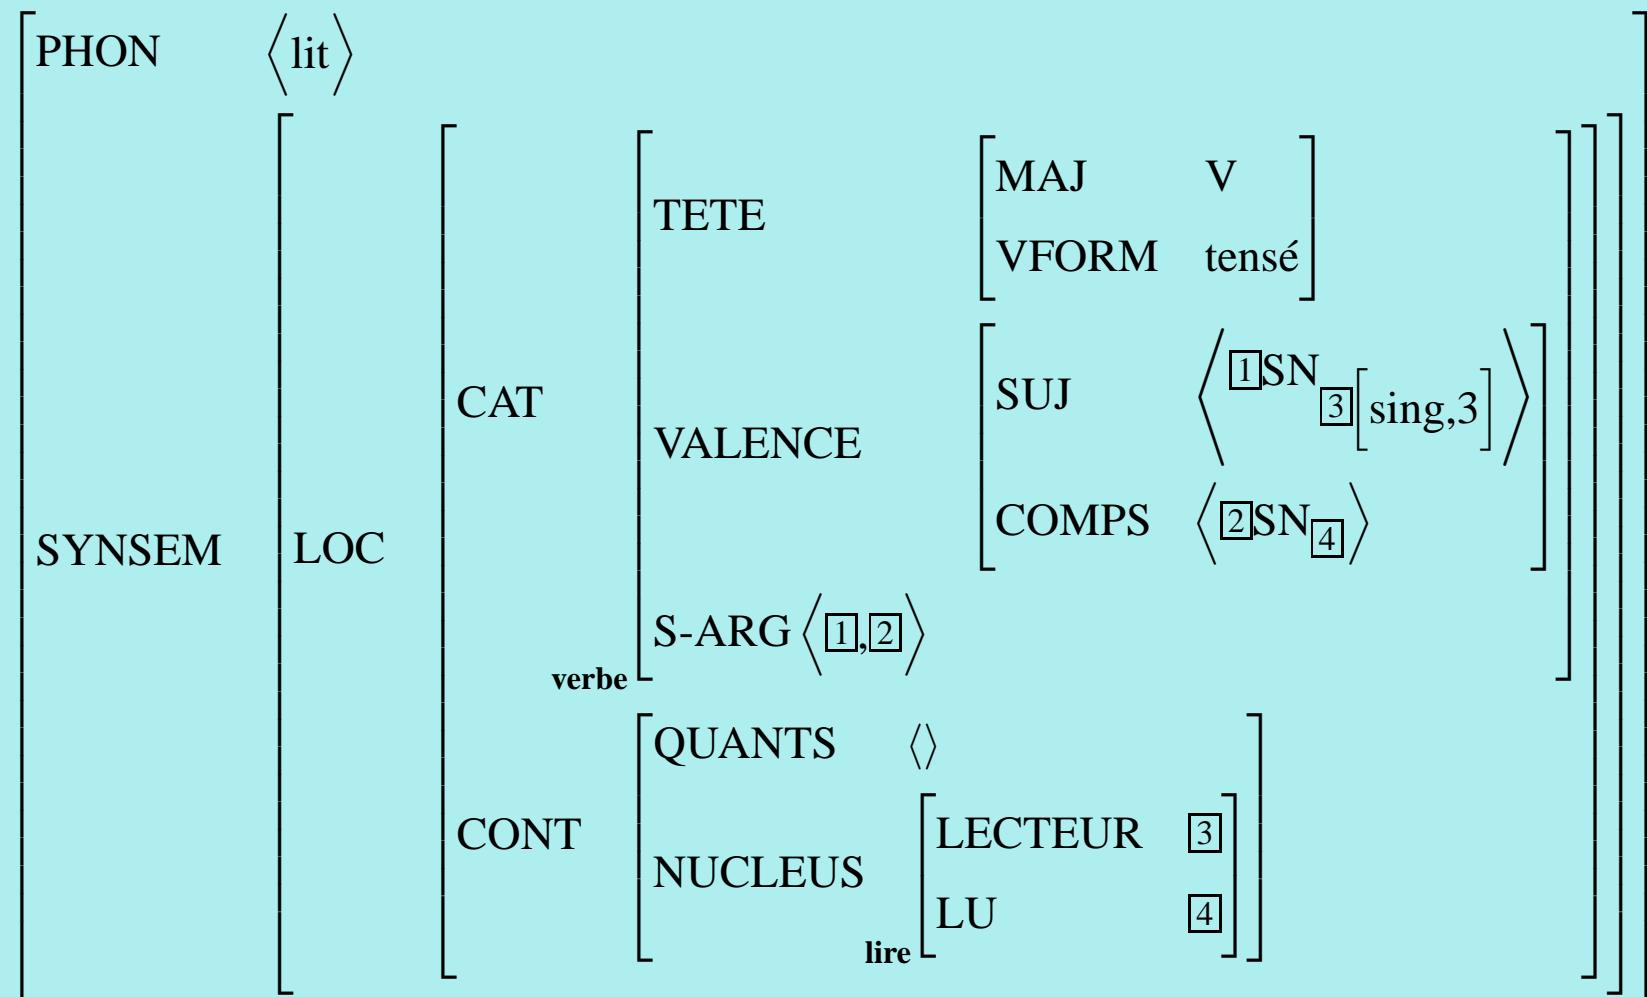
# Nom



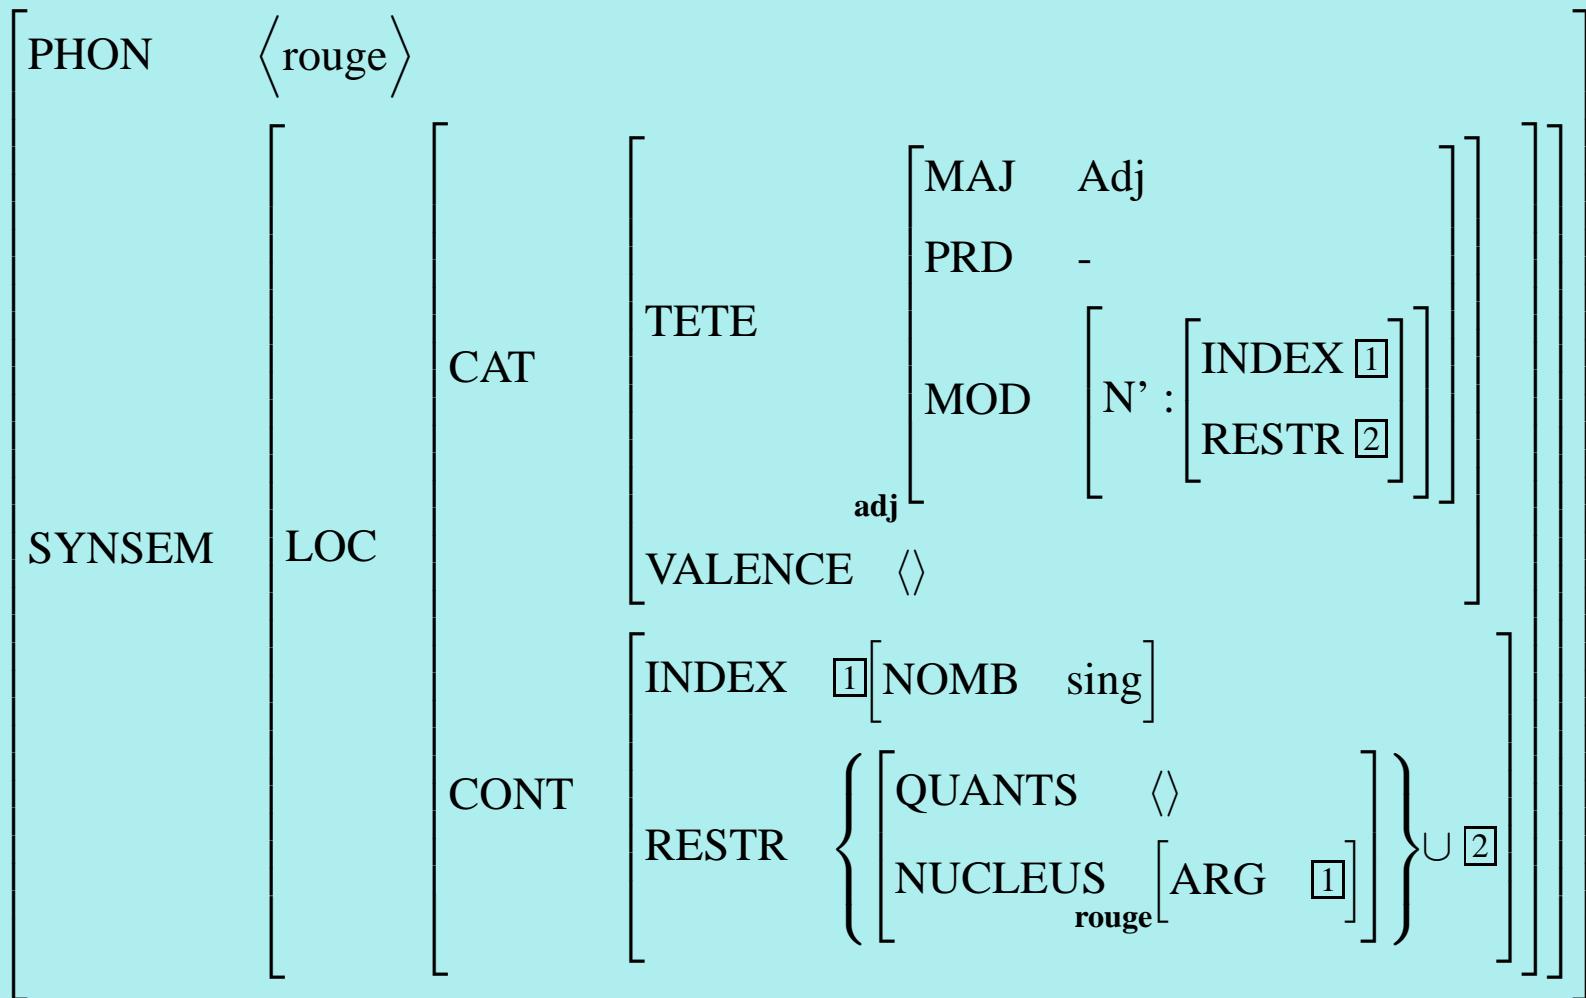
# Article



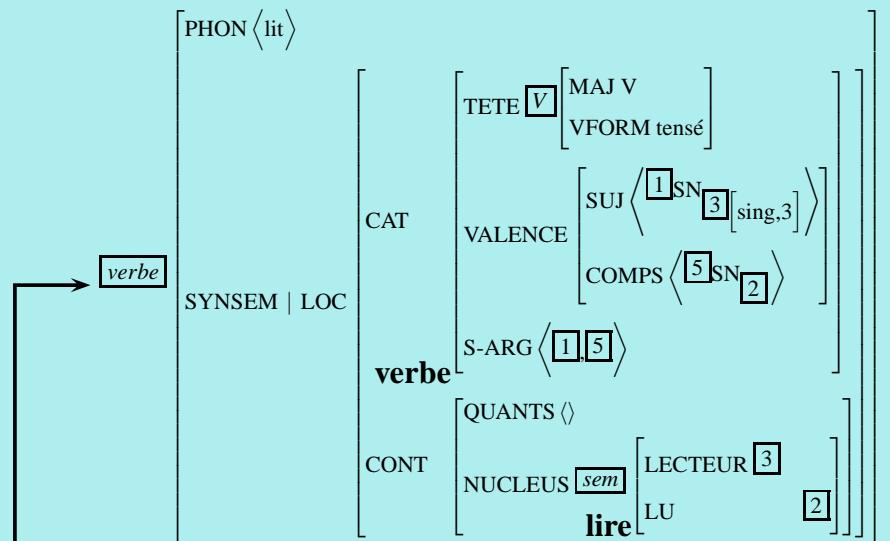
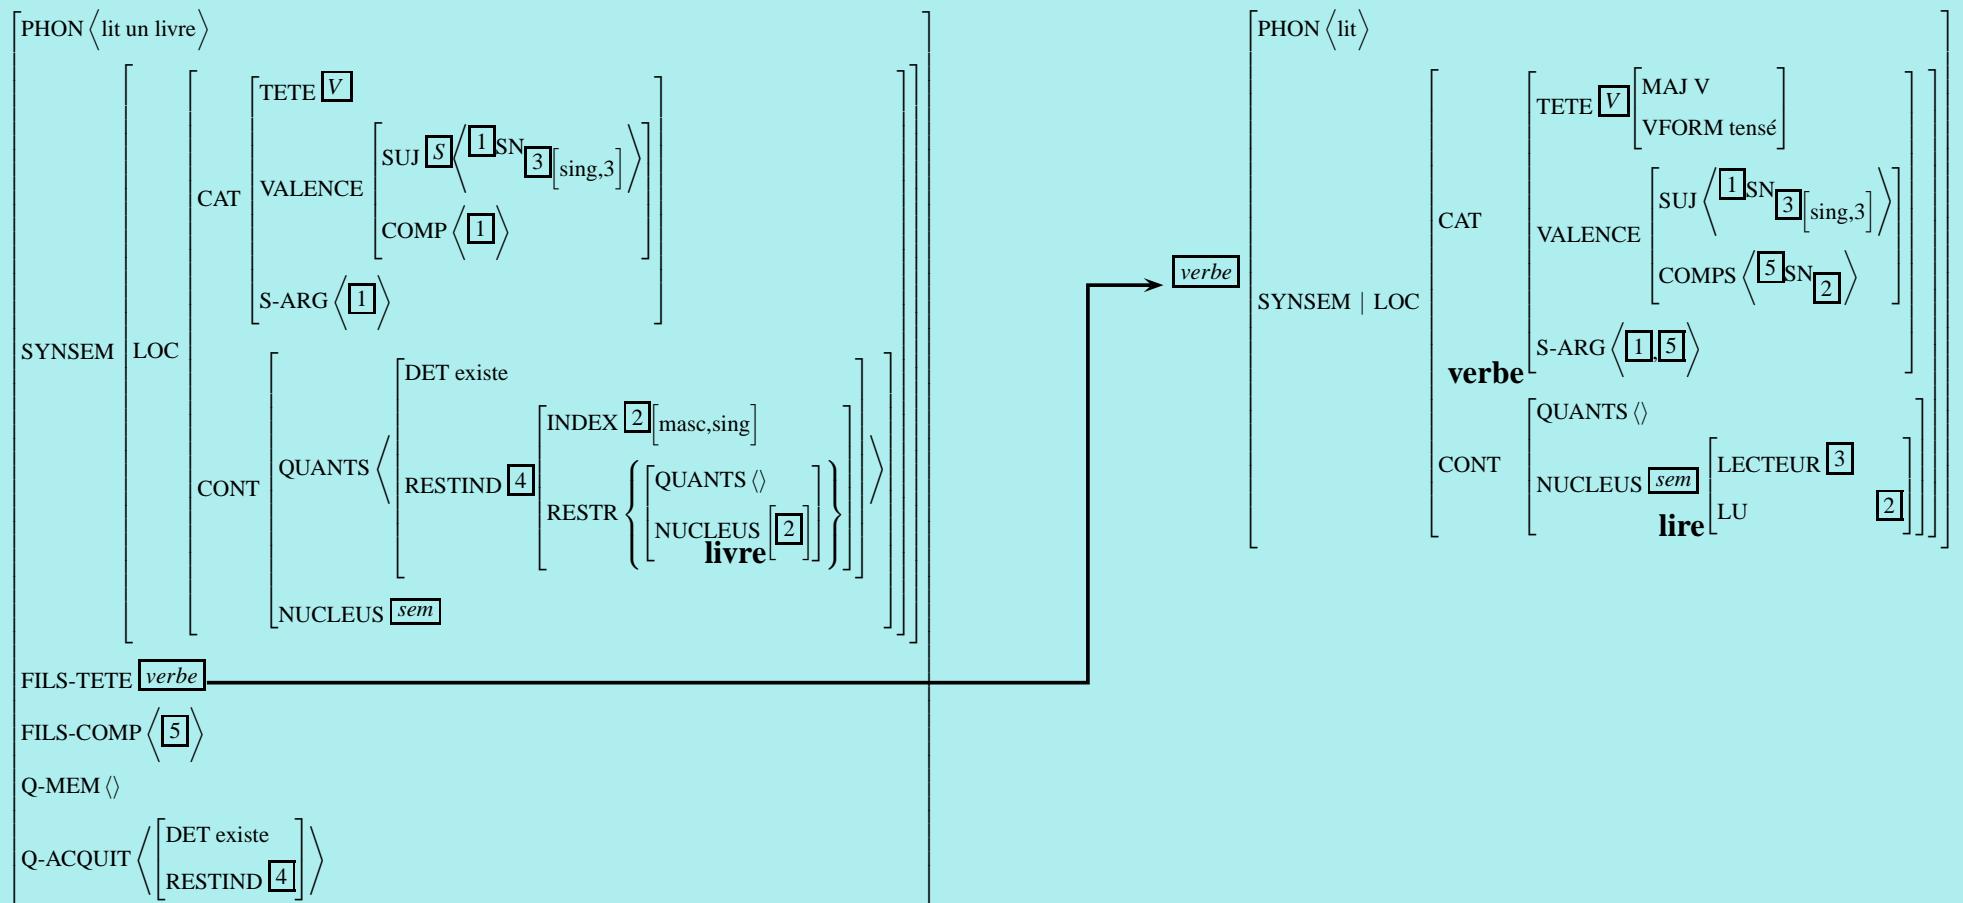
# Verbe



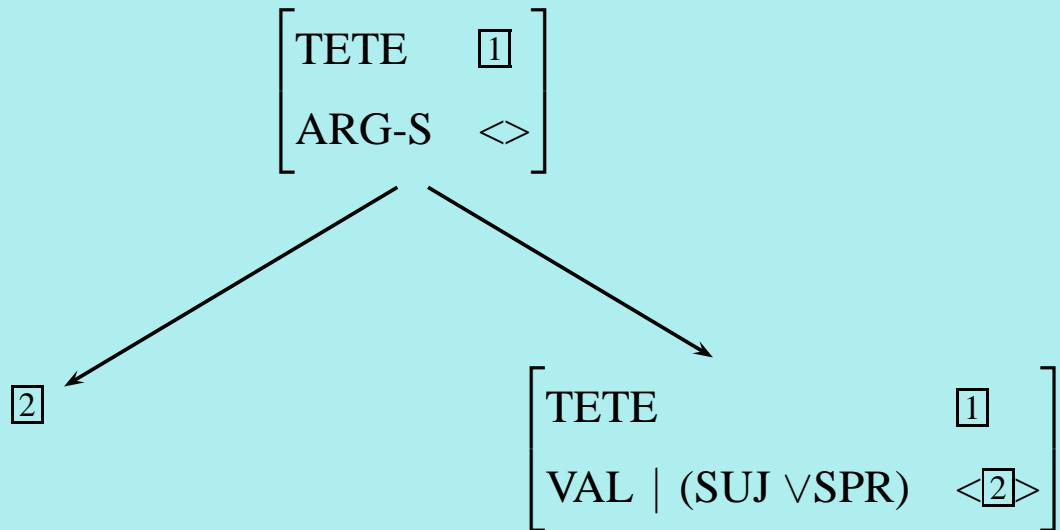
# Adjectif



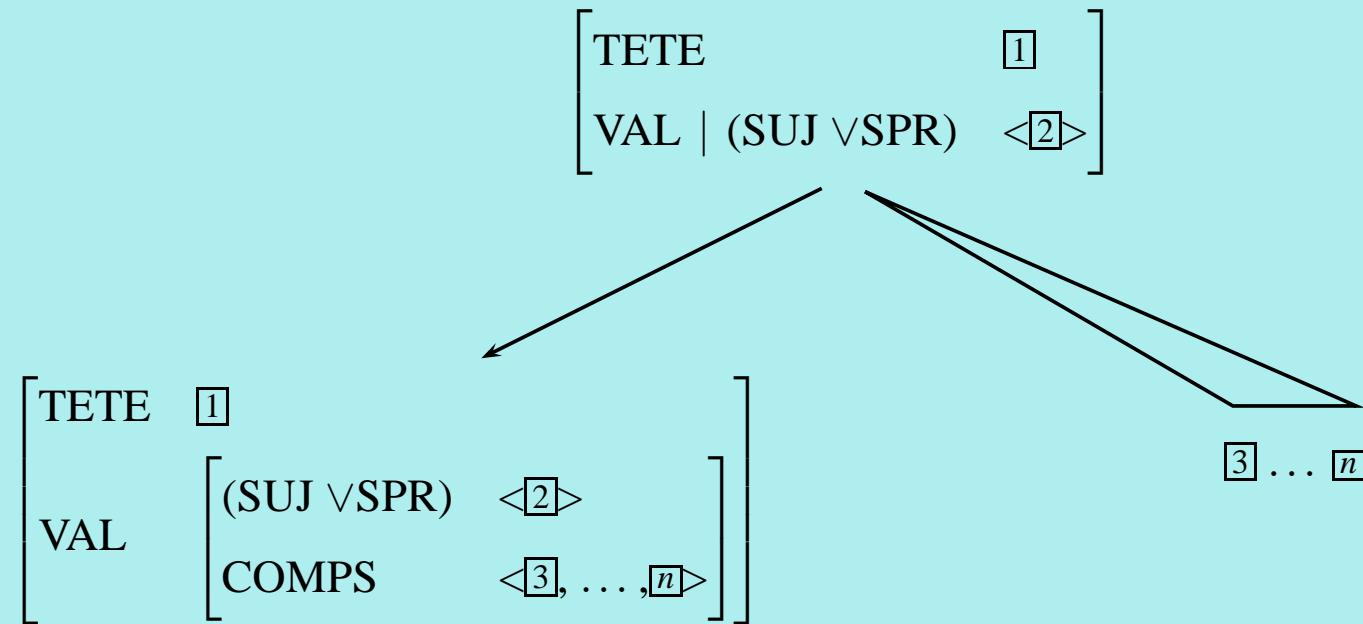
# Fragment de phrase (Syntagme Verbal)



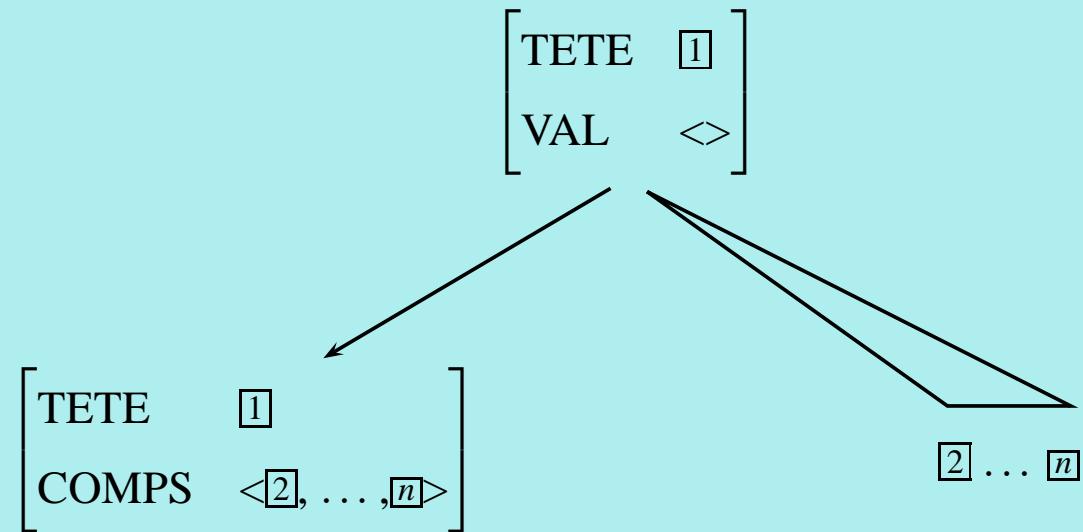
## Schéma 1 : Constituants saturés



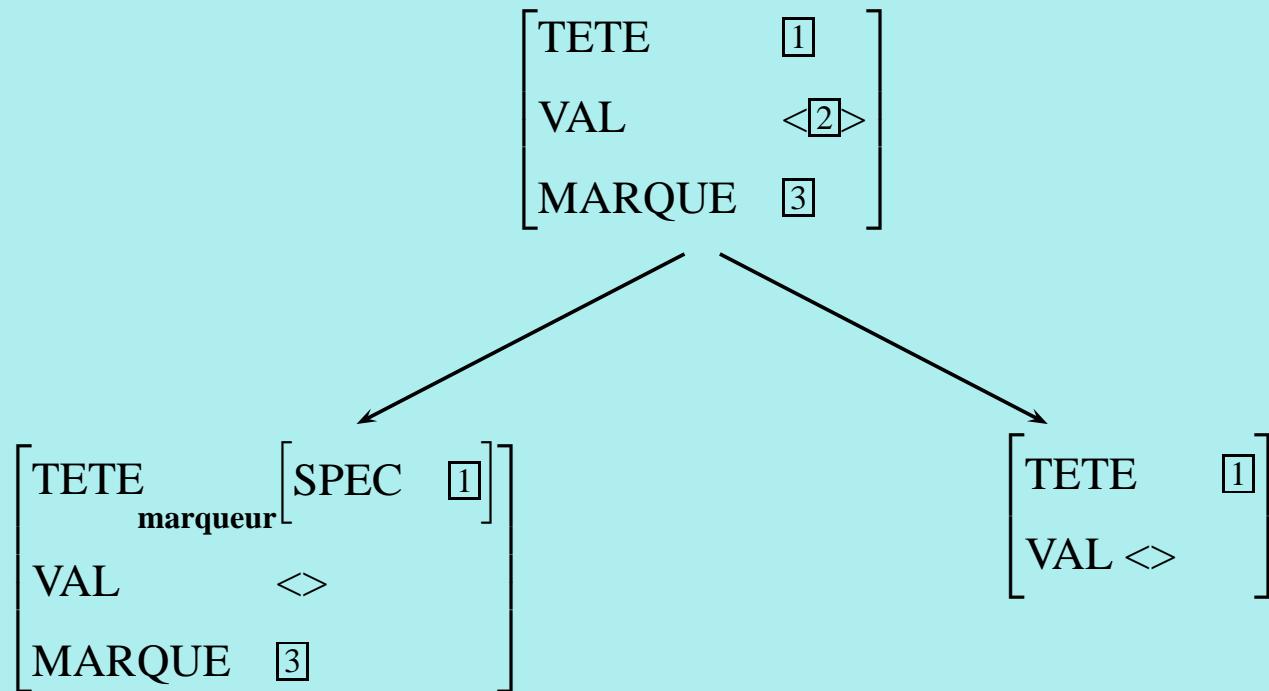
## Schéma 2 : Constituants non spécifiés



## Schéma 3 : Constituants avec compléments catégorisés

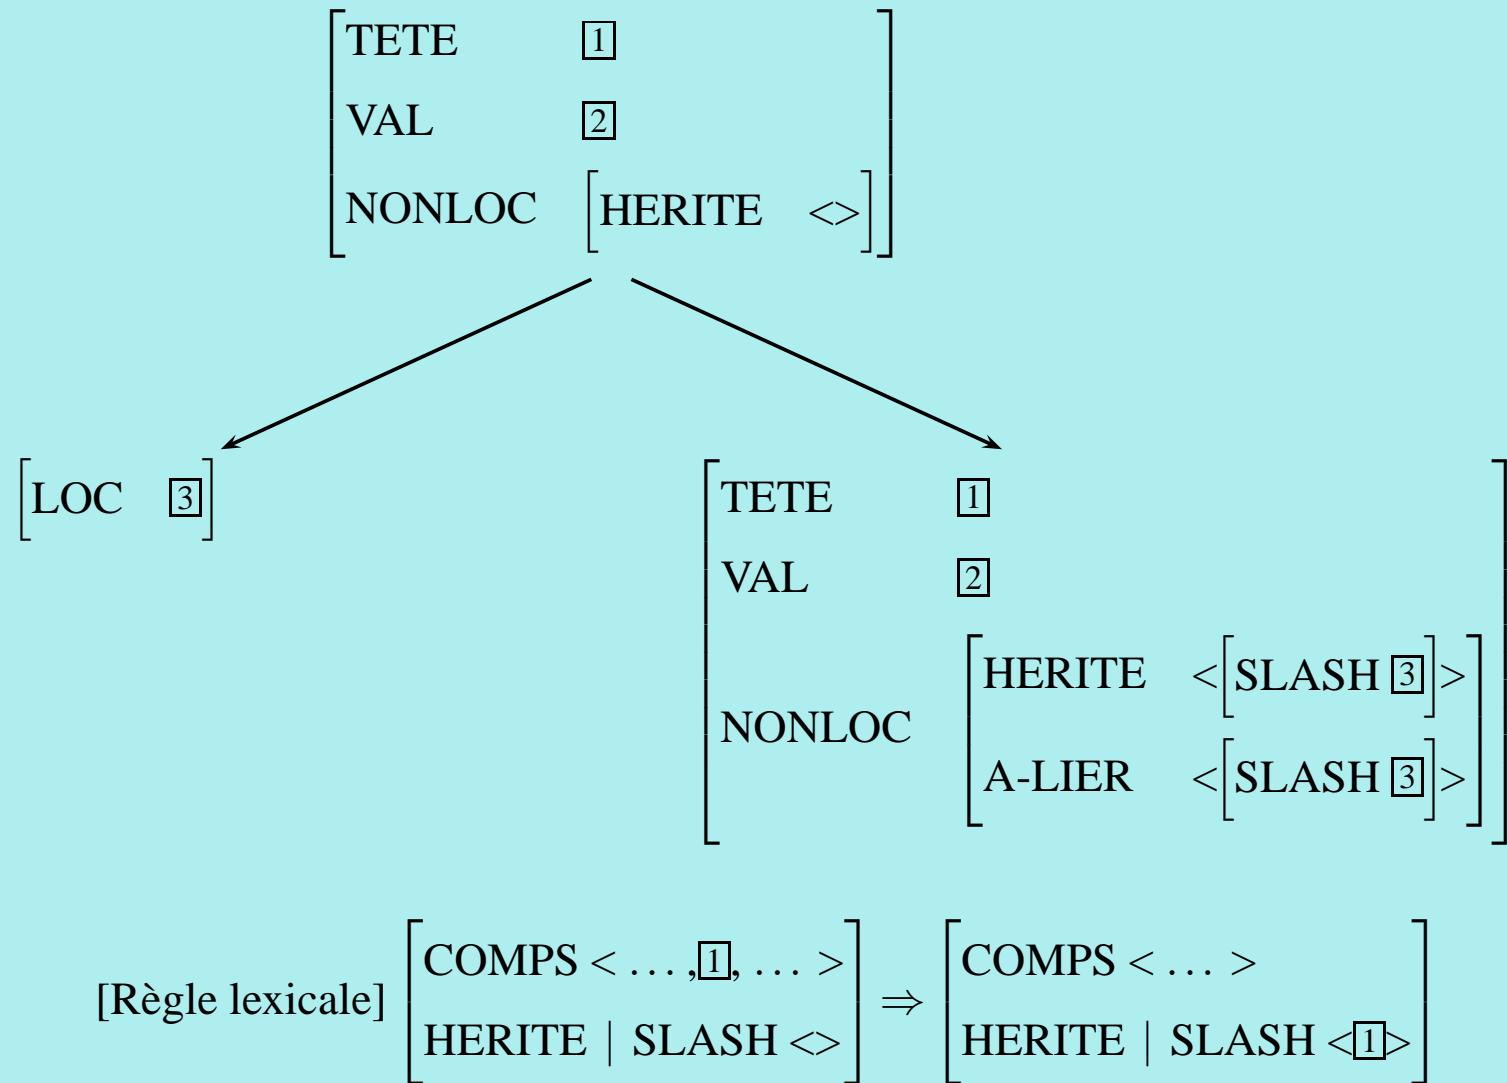


## Schéma 4 : Constituants marqués



Permet le traitement des prépositions et de phrases telles que « [que Jean parte] m'inquiète ».

## Schéma 5 : Extraction



# Les principes

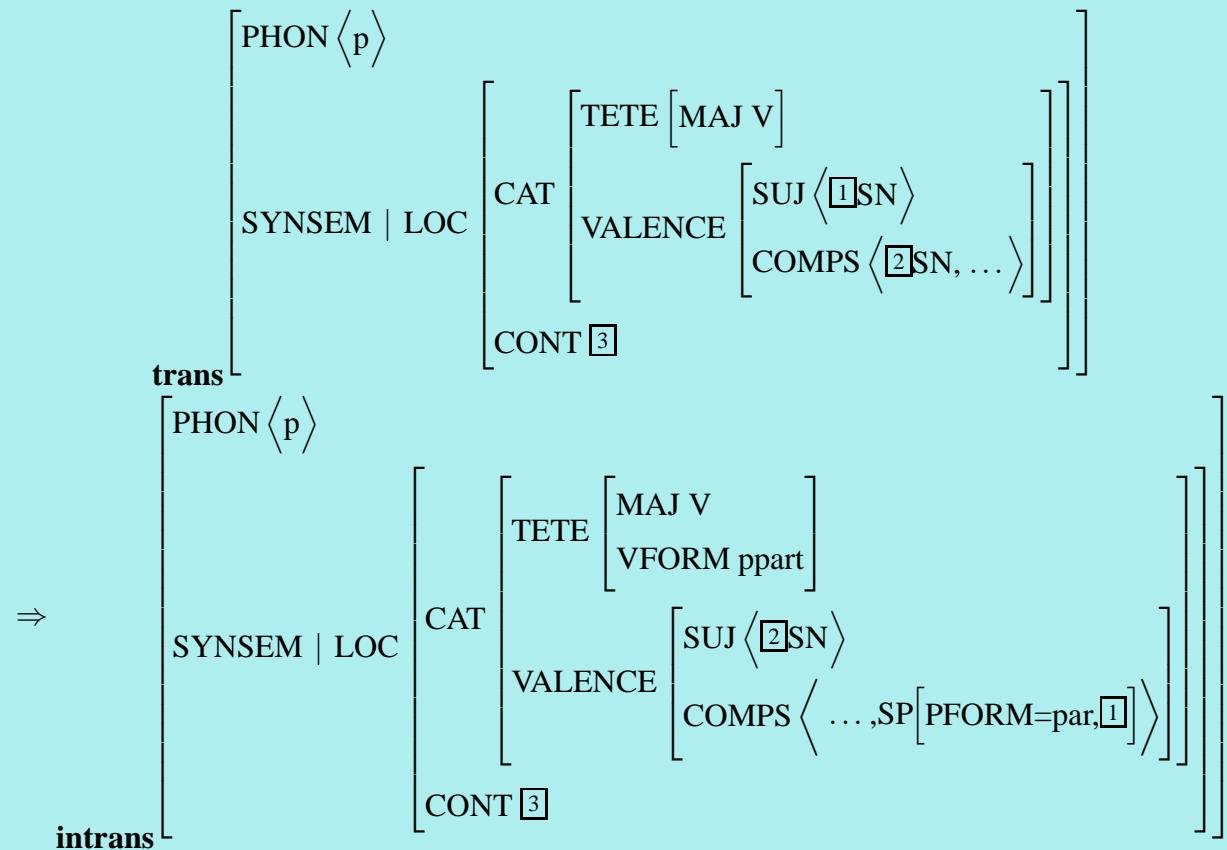
**Principe de tête** Les valeurs des traits de tête entre un syntagme et sa tête sont identiques

**Principe de valence** La valence d'un syntagme est la valence de sa tête moins la liste des fils (non tête).

**Principes des traits non locaux** La valeur des traits non locaux hérités est l'union des valeurs des traits hérités des fils, moins la valeur à lier du syntagme racine.

# Règle lexicale : le passif

Construction d'une entrée lexicale pour les verbes transitifs : manger  $\Rightarrow$  mangé



# Syntaxe ALE : entrée lexicale

persuade --->

% object equi

word,

synsem:loc :( cat :( head :( verb ,

mod:none, vform:bse , aux:minus , inv :minus ),

subcat :[( @ np(Ind1)),

( @ np(Ind2), @ case(acc )),

( @ vp(VCont),

loc : cat :( head:vform:inf ,

subcat :[( @ np(Ind2 ))]]),

marking:unmarked),

cont :( nucleus :( persuading , persuader:Ind1 , persuaded:Ind2 , soa\_arg:VCont),

quants :[]),

conx:backgr: e\_set ),

(@ empty\_non\_loc),

qstore : e\_set .

# Syntaxe ALE : schéma

```
schema1 rule (Mother,phrase,synsem:loc:cat : subcat :[]) ===>
cat > (SubjDtr,non_word,synsem:SubjSyn),
cat > (HeadDtr,phrase),
goal > ( head_feature_principle (Mother,HeadDtr),
           inv_minus_principle (Mother),
           subcat_principle (Mother,HeadDtr,[SubjSyn]),
           marking_principle (Mother,HeadDtr),
           spec_principle (SubjDtr,HeadDtr),
           semantics_principle (Mother,HeadDtr,[SubjDtr ]),
           parochial_trace_principle (SubjDtr),
           nonlocal_feature_principle (Mother,HeadDtr,[SubjDtr ]),
           single_rel_constraint (Mother),
           clausal_rel_prohibition (Mother),
           relative_uniqueness_principle (Mother,[SubjDtr ,HeadDtr]),
           conx_consistency_principle (Mother,[SubjDtr ,HeadDtr]),
           deictic_cindices_principle (Mother,[SubjDtr ,HeadDtr])).
```

# Grammaires Catégorielles [CG]

Calcul de Lambek (1958)

Steedman (1998) Combinatory Categorial Grammars

- Théorie plus linguistique, non centrée sur une notion de constituant  $\Rightarrow$  traitement de la coordination et constituants incomplets
- Formalisme :  $\lambda$ -calcul (et combinateurs)

# Applications

$$\frac{X/Y : f \quad Y : a}{X : fa} >$$

$$\frac{Y : a \quad X/Y : f}{X : fa} <$$

$$\begin{array}{c}
 \text{Pierre} \qquad \qquad \qquad \text{mange} \qquad \qquad \qquad \text{une pomme} \\
 \hline
 \text{SN :pierre'} \quad \dfrac{}{(P \setminus SN) / SN : \lambda x. \lambda y. manger' xy} \quad \text{SN :pomme'} \\
 \hline
 \dfrac{}{(P \setminus SN) : \lambda y. manger' pomme' y} \\
 \hline
 P : manger' pomme' pierre'
 \end{array}$$

- Puissance générative des CFG  $\Rightarrow$  nécessaire d'ajouter des combinateurs supplémentaires
- Possibilité de décorer les non-terminaux avec des structures de traits

# Coordination (simple)

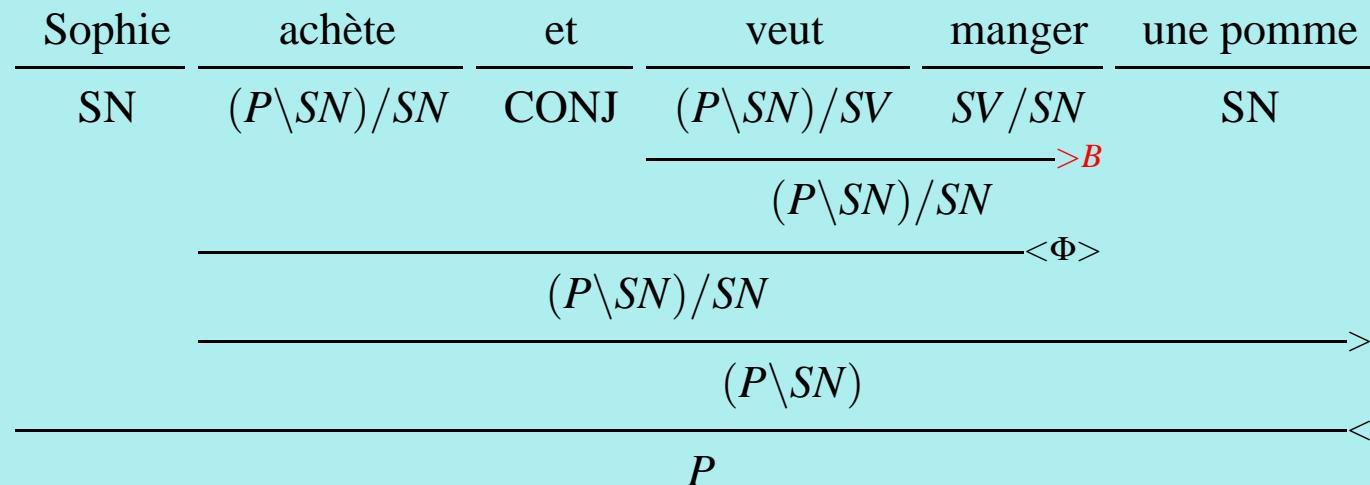
$$\frac{X \quad CONJ \quad X}{X} <\Phi>$$

Sophie	achete	et	mange	une pomme
SN :s'	$(P \setminus SN) / SN : \lambda x. \lambda y. acheter' xy$	CONJ :et'	$(P \setminus SN) / SN : \lambda x. \lambda y. manger' xy$	SN :p'
$<\Phi>$				
$(P \setminus SN) / SN : \lambda x. \lambda y. et' (acheter' xy) (manger' xy)$				>
$(P \setminus SN) : \lambda y. et' (acheter' p'y) (manger' p'y)$				$<$
$P : et' (acheter' p's') (manger' p's')$				

Mais ne permet pas de traiter toutes les coordinations

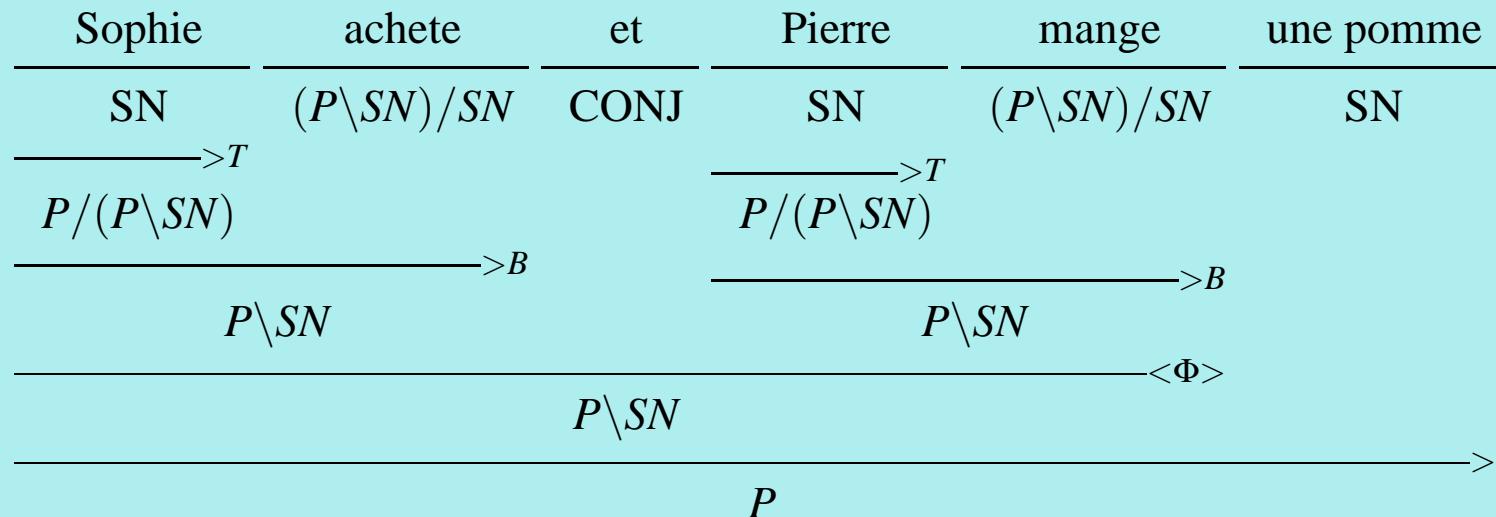
# Composition

$$\frac{X/Y : \textcolor{red}{f} \quad Y/Z : \textcolor{red}{g}}{X/Z : \lambda x. f(gx)} > B$$



# Montée de type (type-raising)

$$\frac{SN : \textcolor{red}{a}}{T / (T \setminus SN) : \lambda f.f\textcolor{red}{a}} > T$$



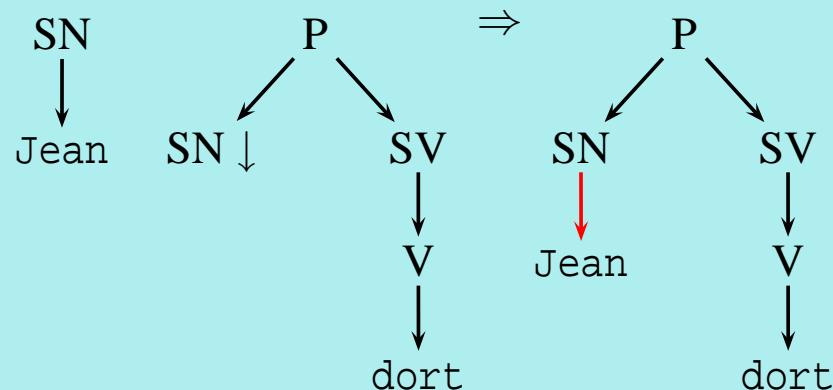
Restriction des montées de type.

# Grammaires d'arbres adjoints [TAG]

Joshi (1975) Tree Adjunct Grammars

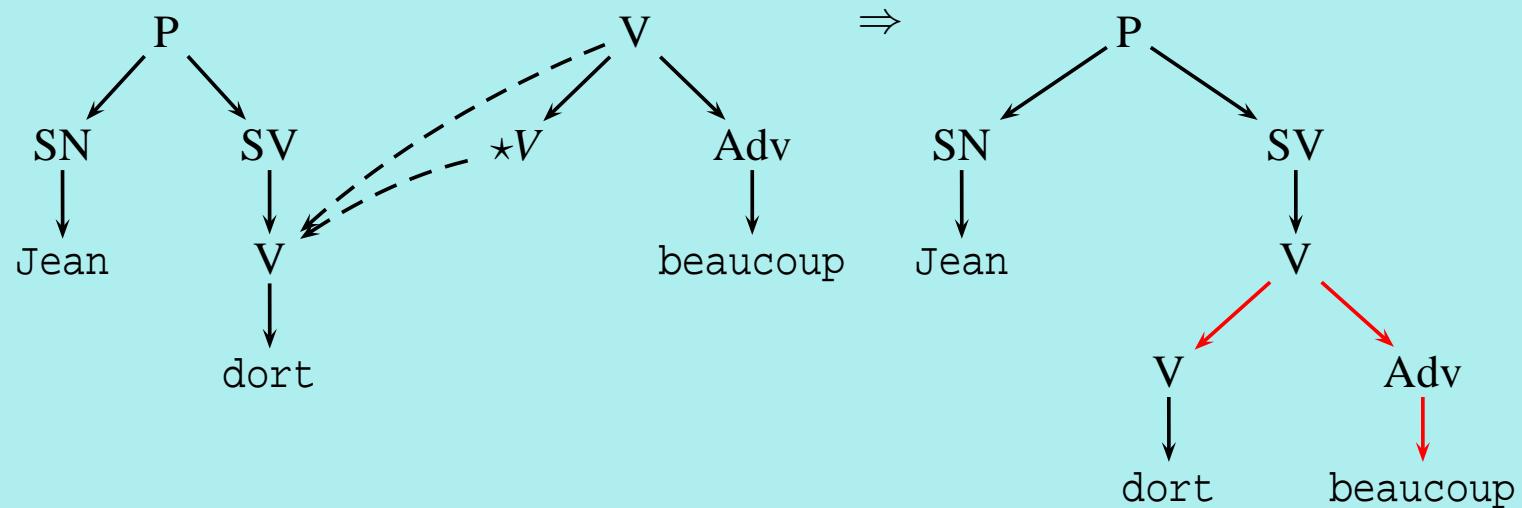
**Théorie** lexicale, catégorisation, tête, constituants

**Formalisme** manipulation d'arbres, avec les opérations de **substitution** et d'**ajonction**



# Adjonction

Permet de gérer les ajouts



# Principes de bonne formation

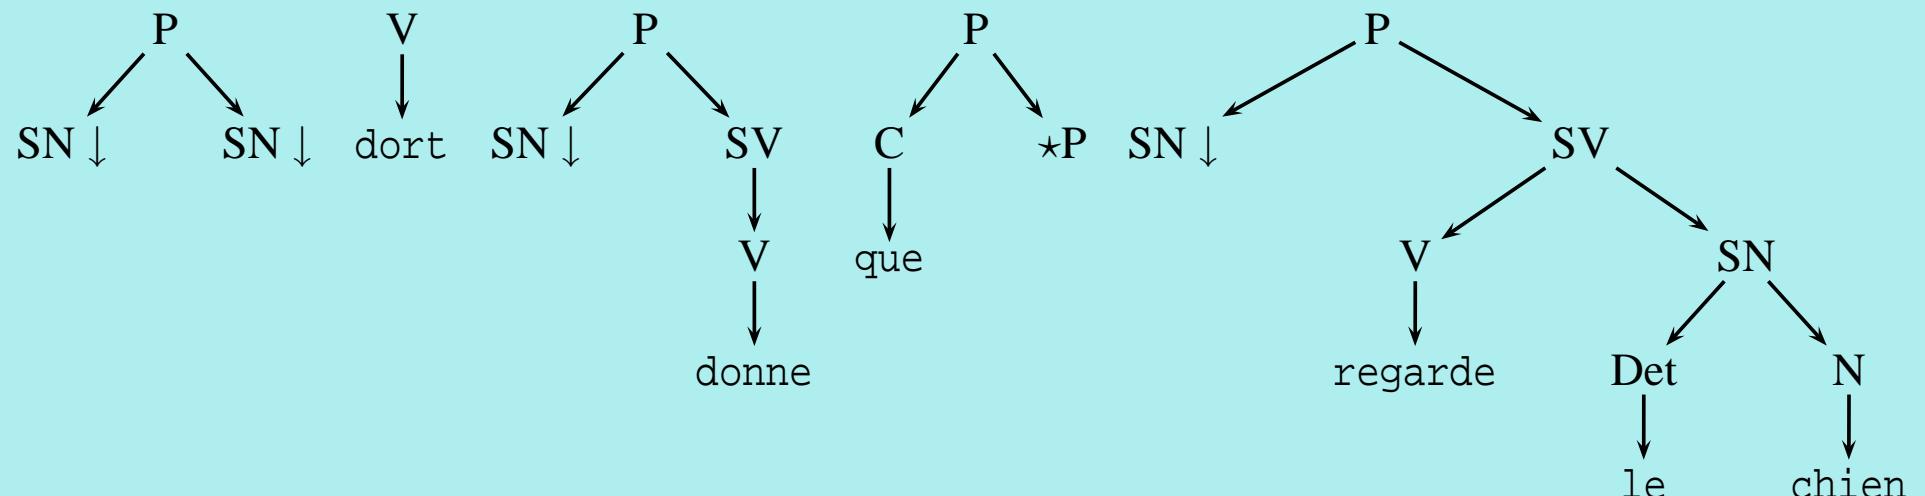
Pour tout arbre élémentaire :

**ancrage lexical** au moins une tête lexicale (non vide)

**catégorisation** un noeud pour chaque argument catégorisé par la tête (domaine de localité)

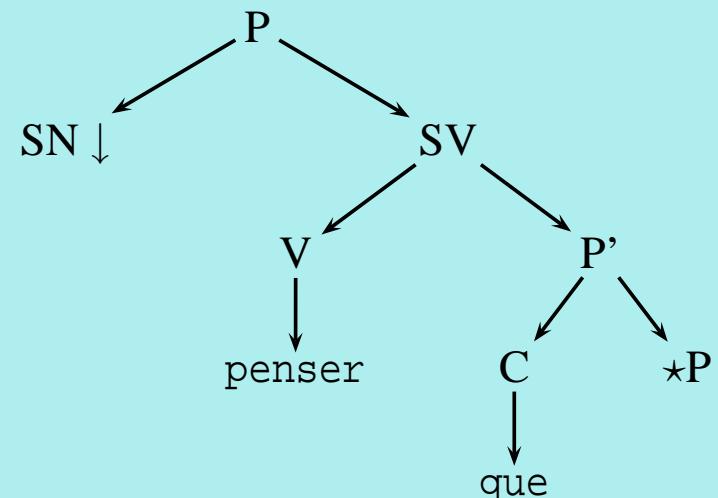
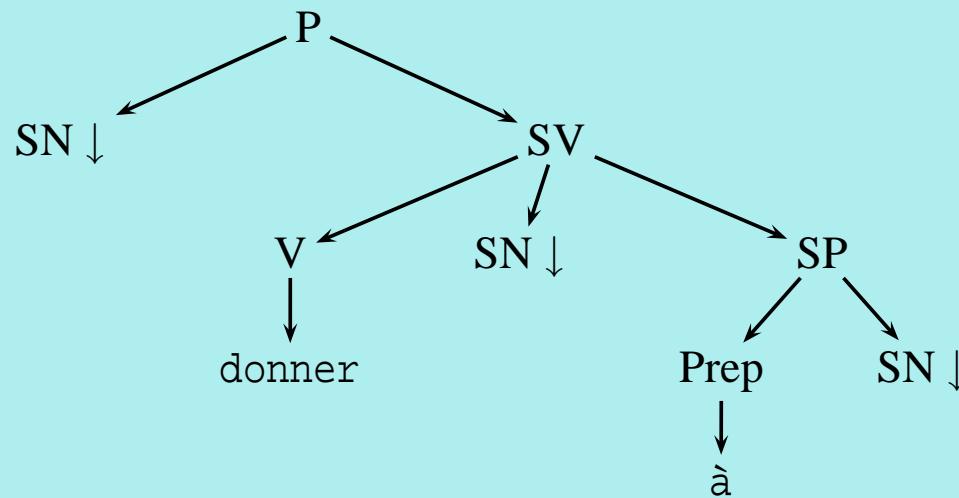
**Consistance sémantique** une association sémantique

**non-composition** une seule unité sémantique



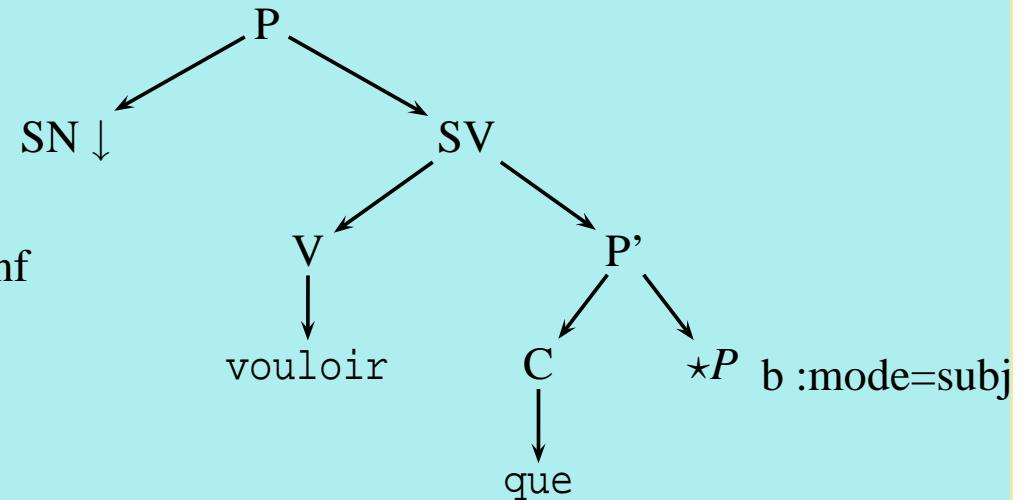
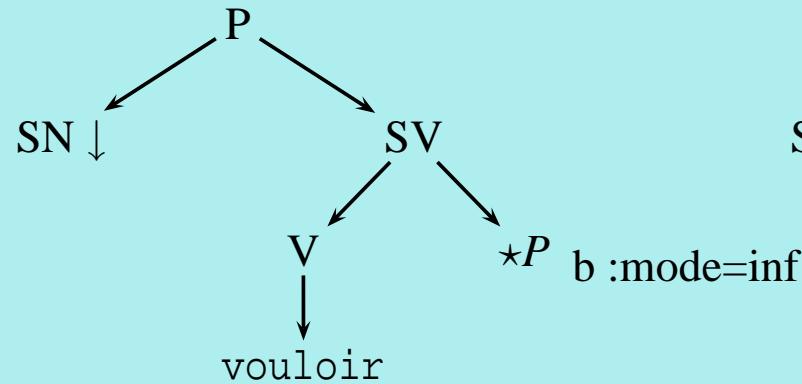
# Catégorisation

Immédiate dans la structure des arbres



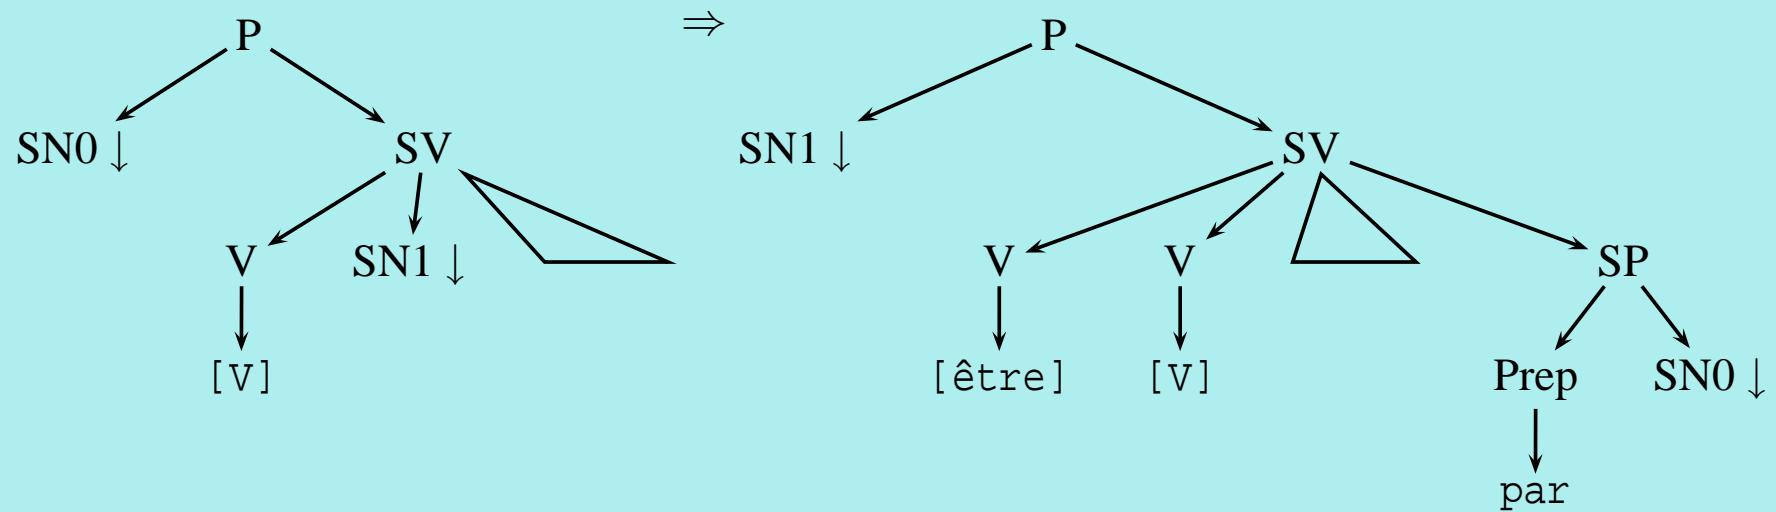
# TAG avec traits

Structures de traits top et bot associables aux noeuds :



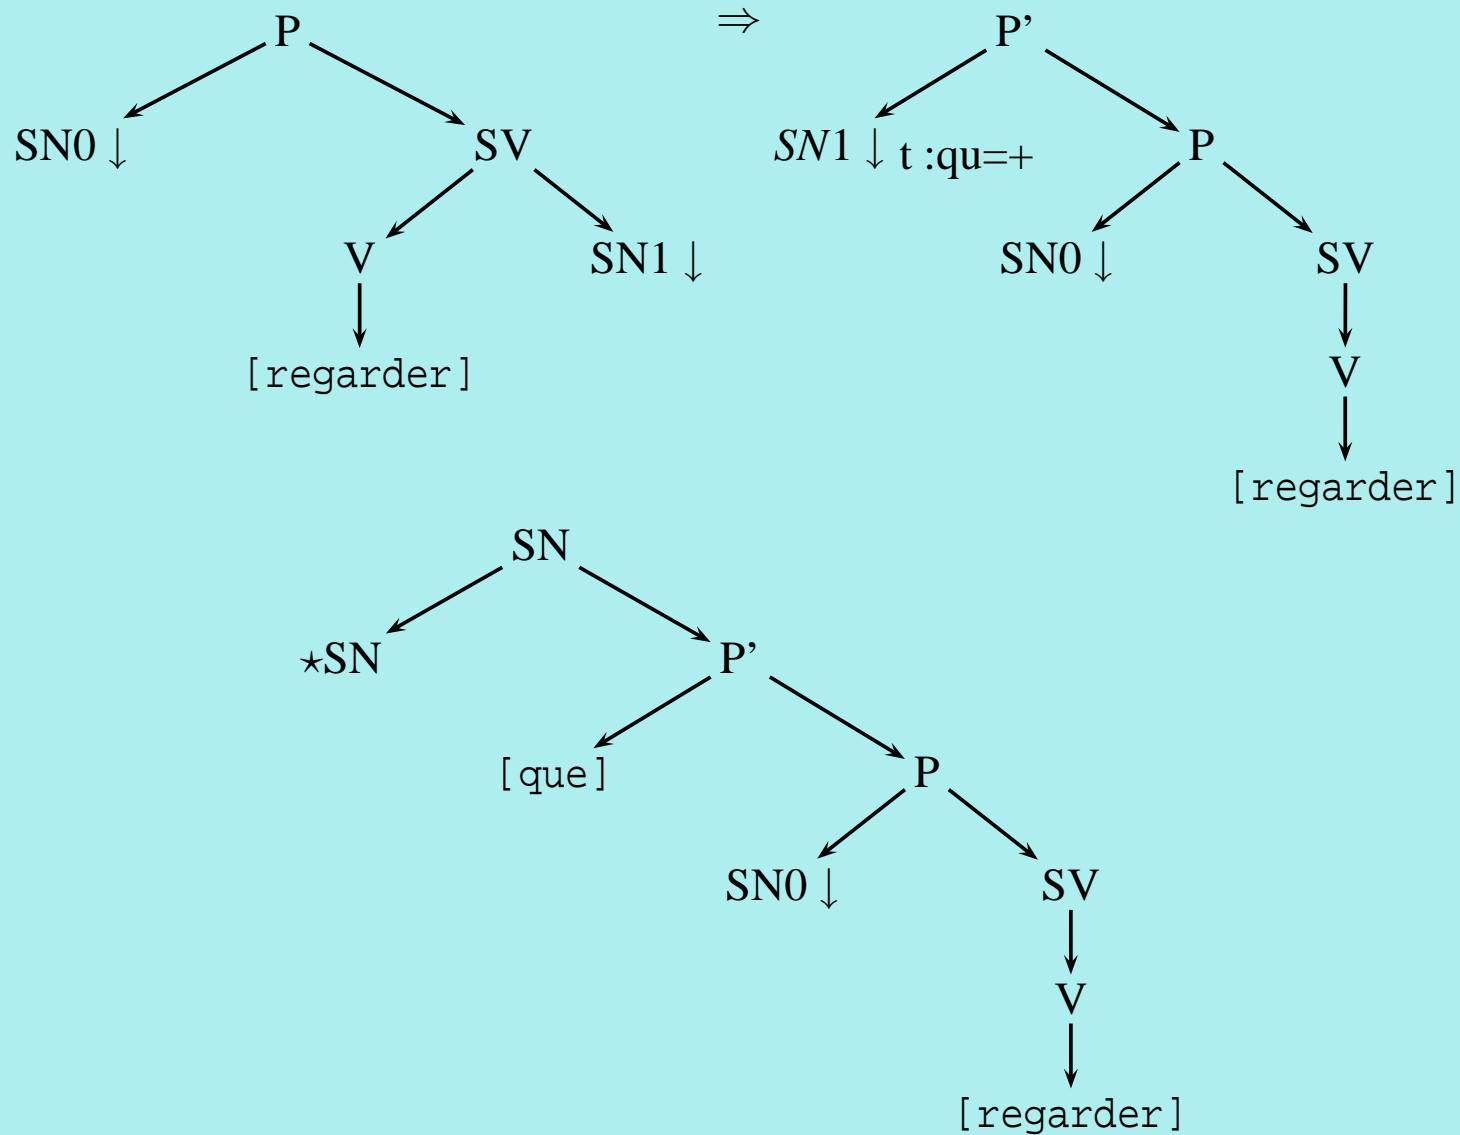
# Familles

Transformations lexicales pour gérer le passif :



L'ensemble des arbres obtenus est une **famille**

## Extraction



# Dépendances non bornées

Une succession d'ajonctions peut séparer un constituant extrait de son prédicat tête.

# Arbres de dérivation et sémantique

# Formalismes TAG dérivés

**TIG** Adjonction réduite (non enveloppante)

**Multi-Component Tag** insertion par substitution et/ou adjonction d'un ensemble d'arbres élémentaires dans un arbre.

**Dominance-Tree** Quasi arbres avec relations parents et ancêtres

Formalismes faiblement dépendant du contexte (MCS)  
⇒ complexité polynomiale.

# Grammaires de dépendance [DG]

Théorie :

- Remise en cause de la notion de constituant et d'arborescence des constituants
- Relations (dépendances) entre mots ( $\Rightarrow$  graphe de dépendance)
- Contraintes sur les dépendances

# Bibliographie

**Les nouvelles syntaxes – Grammaires d'unification et analyse du français** Anne Abeillé (1993).

**Une introduction à HPSG** Philippe Blache

<http://www.lpl.univ-aix.fr/~blache/papers/Intro-hpsg.ps.gz>

**The combinatory manifesto** Mark Steedman (Draft, novembre 2000) et transparents associés.

<http://www.cogsci.ed.ac.uk/~steedman/>

**Ressources HPSG** <http://lingo.stanford.edu/>

**Categorial Grammars Home Pages** <http://www.cs.man.ac.uk/ai/CG/>

**XTAG Group** <http://www.cis.upenn.edu/~xtag/>

**Dependency Grammars Home Page** <http://ufal.mff.cuni.cz/dg/dgmain.html>

**Les grammaires de dépendance** Revue T.A.L., volume 41 (2000), Sylvain Kahane éditeur.

<http://www.atala.org/tal/tal.html>