Prolog
et
Traitement Automatique des Langues

Éric de la Clergerie
Eric.De_La_Clergerie@inria.fr

ALPAGE – INRIA
http://alpage.inria.fr

Cours M2 LI 2008

Aujourd'hui: Analyse syntaxique

Dixième partie X

Forêts partagées d'analyse

Forêts partagées

Ambiguïtés du langage $\Rightarrow$
Plusieurs analyses possibles par phrases !

Forêt $\equiv$ ensemble d'arbres d'analyse

Forêts partagées (ou *packed*) $\equiv$ Représentation compacte représentant des sous-arbres identiques ou similaires.

Graphes ET-OU

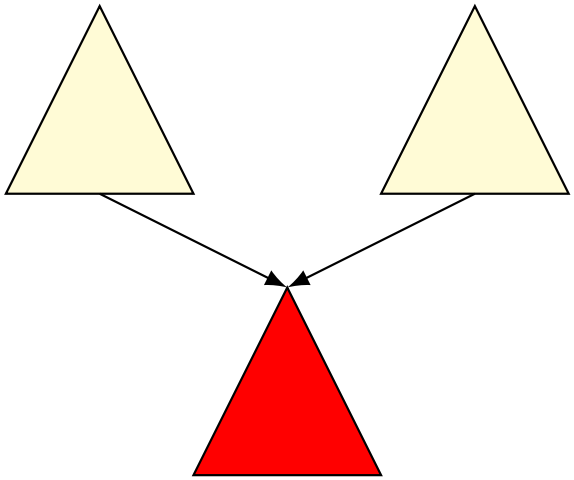

(g) Partage de sous-arbres

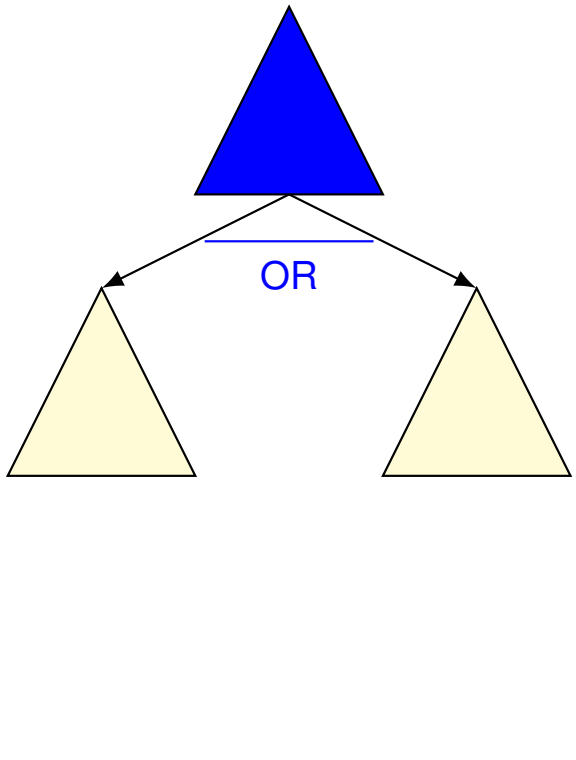

(h) Partage de contexte

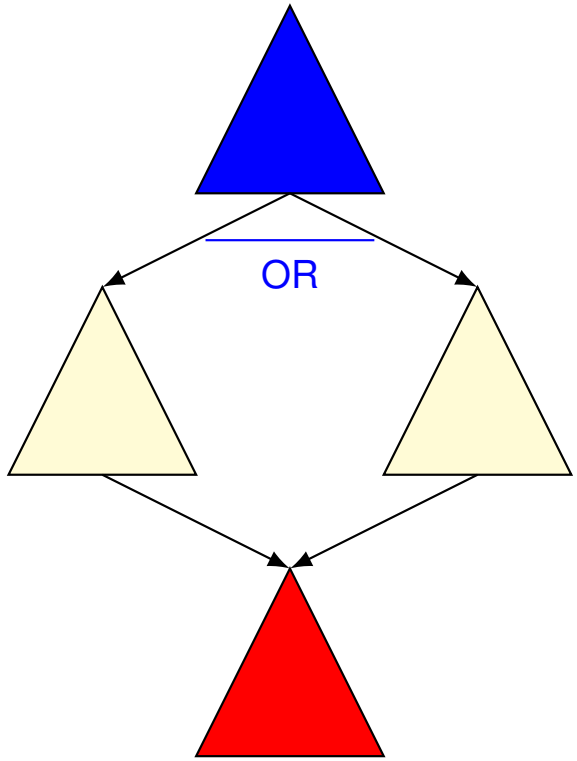

(i) Partage complet

Forêts partagées et arbres

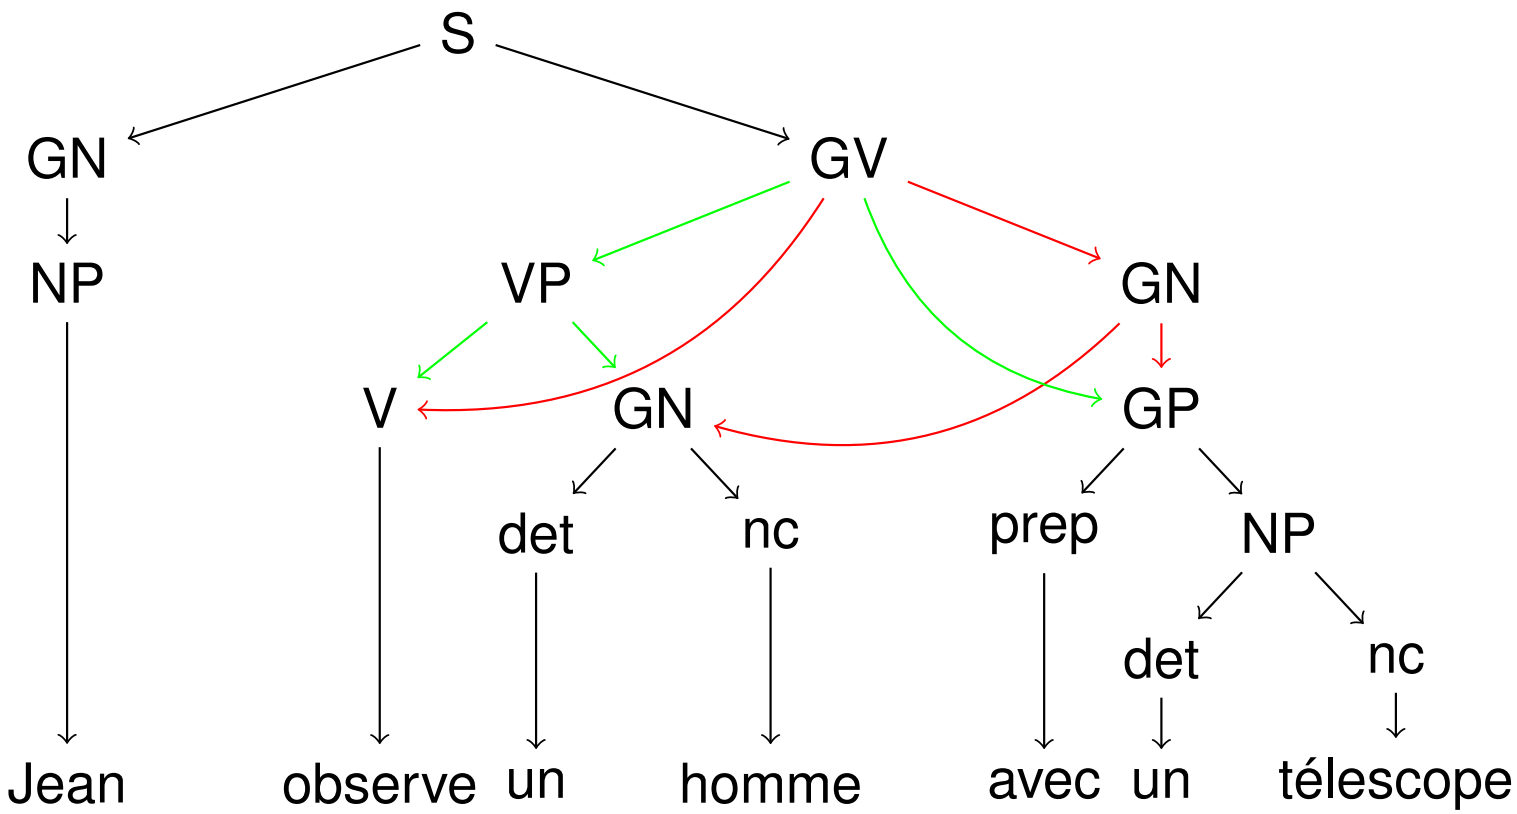

Forêts partagées et grammaires

Une forêt est une grammaire G' instance de G [Lang].

0 Jean 1 observe 2 un 3 homme 4 avec 5 un 6 télescope 7

```
s   --> np vp
np  --> pn
np  --> det n
np  --> np pp
vp  --> v np
vp  --> vp pp
pp  --> prep np
```

```
s07   --> np01 vp17
np01  --> pn01
vp17  --> v12 np27
vp17  --> vp14 pp47
np27  --> np24 pp47
n37   --> n34 pp47
np24  --> det23 n34
pp47  --> prep45 np57
np57  --> det56 n67
vp14  --> v12 np24
```

```
pn01 --> Jean
 v12 --> observe
det23 --> un
 n34 --> homme
prep45 --> avec
det56 --> un
 n67 --> télescope
```

Certains non-terminaux (vp17) définis plusieurs fois (ambiguïtés).
Certains non-terminaux (v12,np24,pp47) utilisés plusieurs fois (partage).

Forêts partagées et grammaires (suite)

En fait, une forêt partagée représente l'intersection d'une grammaire avec un langage régulier (engendré par un automate à états finis [FSA]).

$$L(G') = L(G) \cap \{\text{“Jean observe un homme avec un télescope”}\}$$

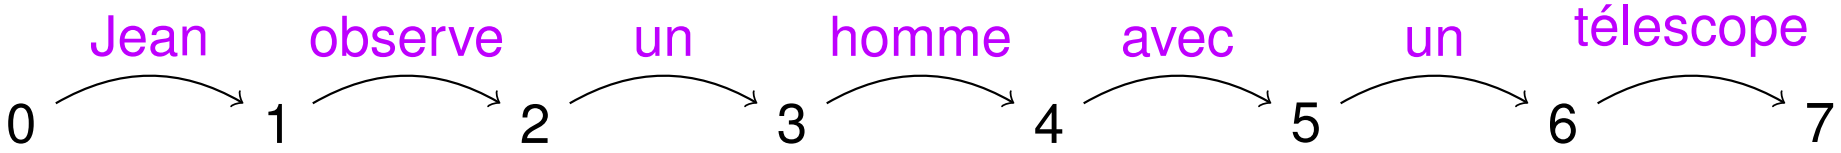

Chaîne vs FSA

Une chaîne peut être remplacée par un FSA en entrée d'analyse :

$$L(G') = L(G) \cap L(FSA)$$

"[mot illisible] observe [mots illisibles] avec un télescope"

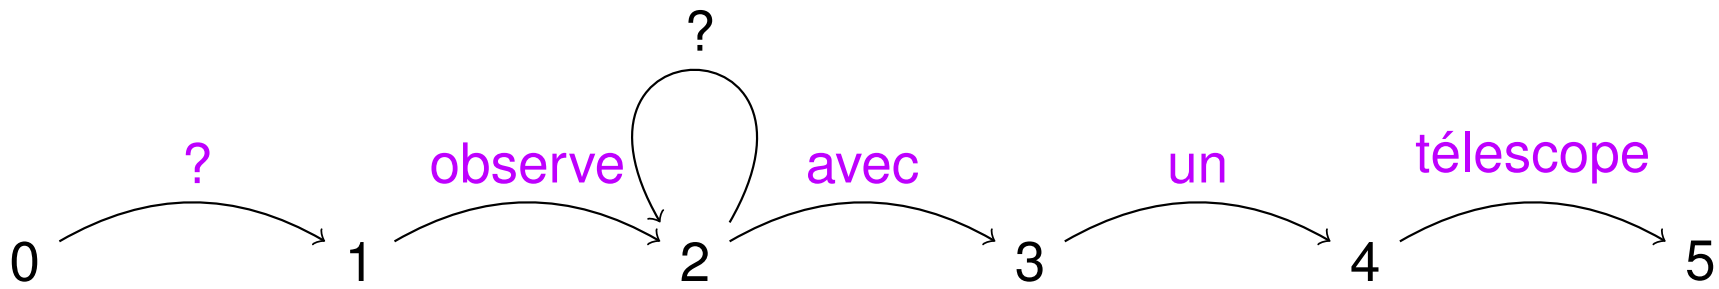

Représentation par une base de faits (pour les DCGs)

```
'C'(0,_,1).  'C'(1,observe,2).  'C'(2,_,2).  'C'(2,avec,3).
'C'(3,un,4).  'C'(4,télescope,5).
```

Forêt d'analyse pour une phrase incomplète

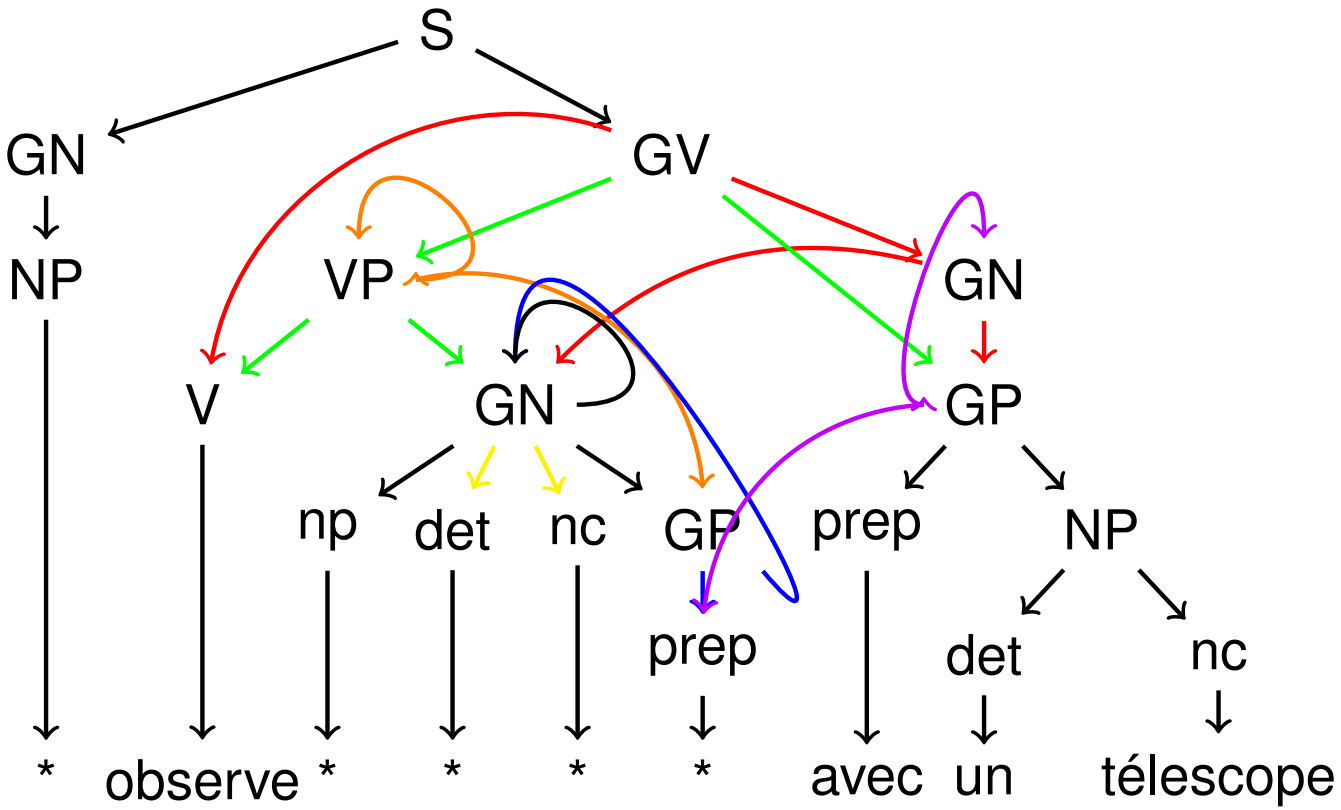

Grammaire pour une phrase incomplète

```
 s05 --> np01   vp15
np01 --> pn01
vp15 --> v12    np25
vp15 --> vp12   pp25
np25 --> np22   pp25
vp12 --> vp12   pp22
vp12 --> v12    np22
pp25 --> prep22 np25
pp25 --> prep23 np35
np22 --> np22   pp22
np22 --> det22  n22
np22 --> pn22
pp22 --> prep22 np22
np35 --> det34  n45
```

```
  pn01 --> *
   v12 --> observe
  pn22 --> *
 det22 --> *
   n22 --> *
prep22 --> *
prep23 --> avec
 det34 --> un
   n45 --> télescope
```

FSA

Les analyseurs tabulaires immédiatement adaptables pour prendre en entrée un FSA (ou un treillis de mots).

Analyser un FSA peut se faire en complexité temps $O(n^3)$ pour les CFGs où n est le nombre d'états du FSA.

FSAs (ou treillis de mots) utiles pour

- des phrases bruitées ou incomplètes (données orales)
- les ambiguïtés lexicales
- les ambiguïtés de segementation

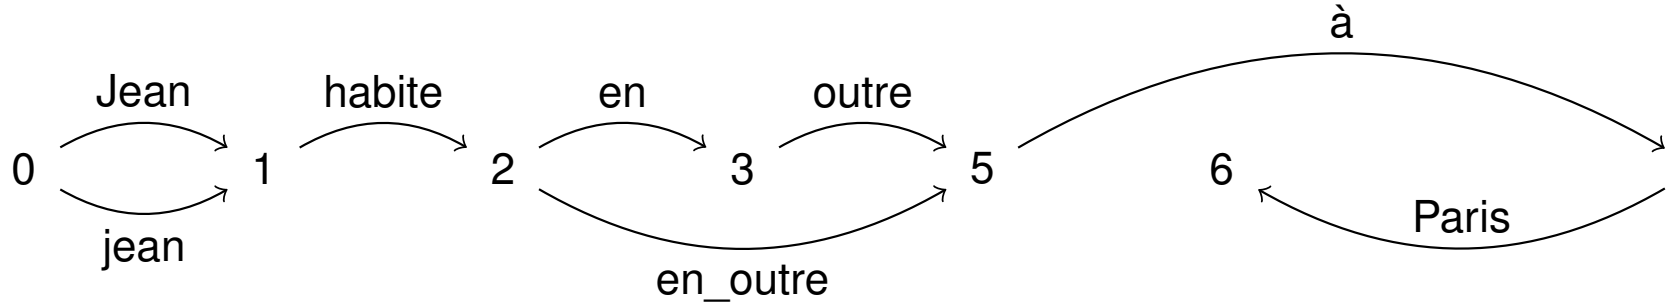

FSA décorables avec des probablités ou des poids (FSA pondérés)

Extraction des forêts

Les forêts constructibles ou extractibles après l'analyse

L'extraction utilise des pointeurs arrières (*backpointers*) allant des objets tabulés à leurs parents

Partant d'une réponde (`S07`), les backpointers sont suivis pour retrouver des instanciations des productions et identifier les non-terminaux.

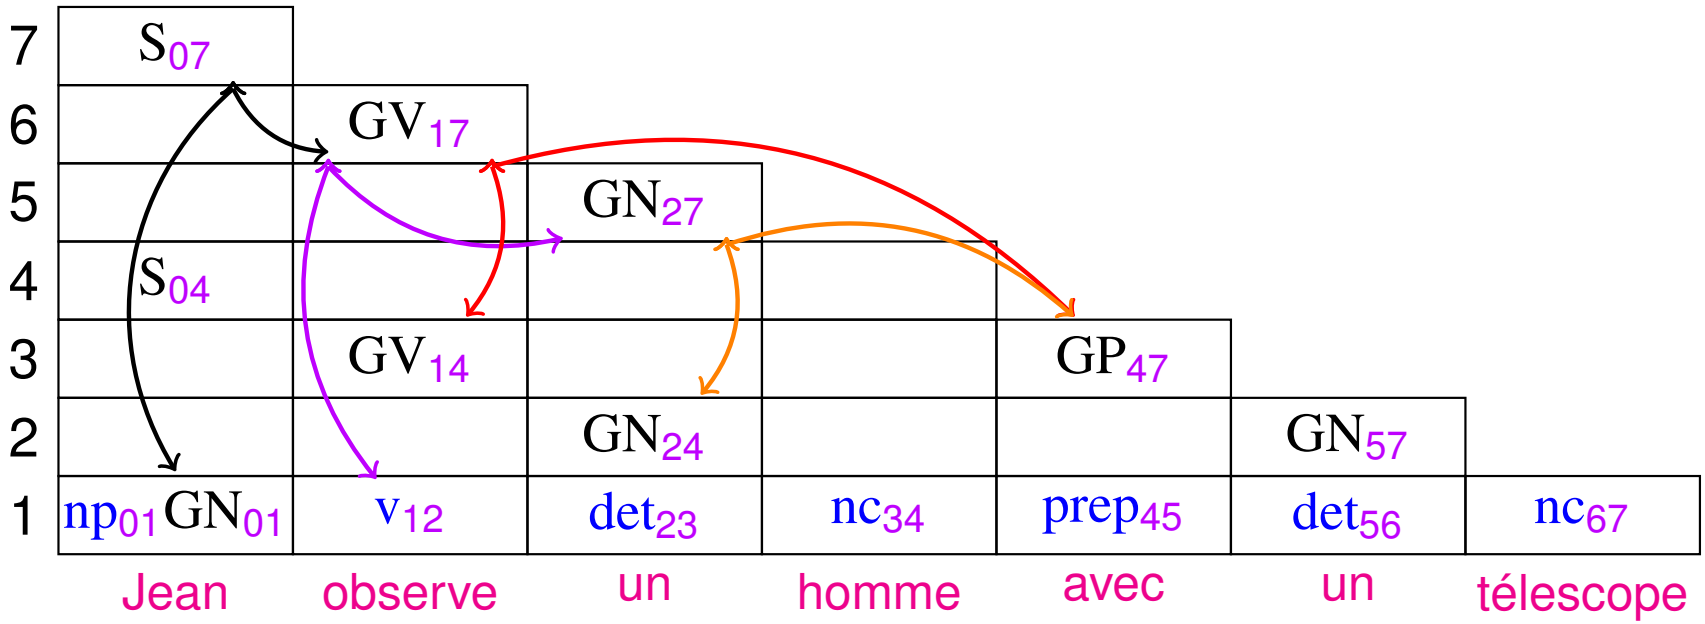

Note : La complexité en place augmente de $O(n^2)$ à $O(n^3)$ pour des grammaires binarisées (forme normale de Chomsky).

Extraction de forêts : filtrage

Pour des stratégies d'analyse autre que CKY :

- suivre les binarisations des règles pointées
- collecter les constituants (passifs) complets (et re-démarrer l'extraction de ceux-ci)
- éliminer les étapes de prédictions

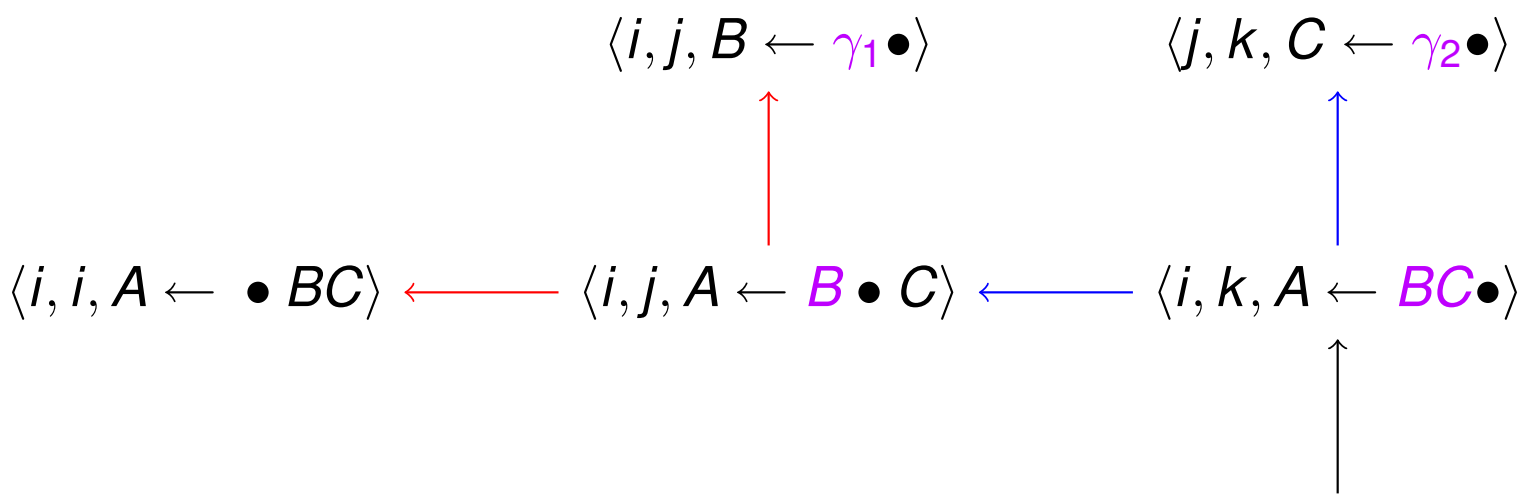

Retourne la production $A_{ik} \leftarrow B_{ij} C_{jk}$ et redémarre de C_{jk} et B_{ij} (sauf si déjà extraits).

Exploiter les forêts

Une forêt partagée d'analyse permet :

- stockage d'un nombre exponentiel (ou même infini) d'arbres au sein d'une structure en complexité polynomiale en place ($O(n^3)$ pour les CFG)
  $\Rightarrow$ format d'entrée pour des traitements post-analyse

- focus sur les points d'ambiguïté
  $\Rightarrow$ aide pour la désambiguïsation post-analyse
  (éventuellement avec une supervision humaine).

Grammaires d'unification sans interaction

Forêt d'analyse pour les grammaires d'unification sont "sans-interaction" [Dymetman]

> *Un grammaire sans interaction peut être utilisée pour énumérer les réponses sans échec de l'unification*

```
p(X,Y) :- q(X,Y),r(X,Y).
q(Z,f(Z)).      r(a,T).      r(_,g(_)).
?- p(X,K).      %% X=a  K=f(a)
```

Une grammaire possible sans interaction :

```
p(X,Y) :- q(X,Y),r(X,Y).
q(Z,f(Z)).          r(a,f(a)).
```

Une autre :

```
p(a,f(a)) :- q(a,f(a)),r(a,f(a)).
q(a,f(a)).          r(a,f(a)).
```

Forêts partagées et DyALog

Les analyseurs DyALog acceptent l'option `-forest` pour extraire la forêt partagée

```
%% Yves loves Sabine
s{inv=> -, mood=> mood[ind,subj]}(0,3) 1 <-- [subj]2 [<>]3 [obj]4
np{gen=> masc, num=> sing }(0,1)       2 <-- [<>]5
tag_anchor(loves,1,2,tn1)              3 <--
np{gen=> fem, num=> sing }(2,3)        4 <-- [<>]6
tag_anchor(Yves,0,1,np)                5 <--
tag_anchor(Sabine,2,3,np)              6 <--
```

Ambiguïté≡ disjonctions de productions

```
%% Yves searches the flowers on the table
s{}(0,7) 1 <-- ([subj]2 [<>]3 [obj]4 [vp]5 | [subj]2 [<>]3 [obj]
    6)
```

Labels dans les forêts

Possibilité d'ajouter des labels sur les non-terminaux, pour une meilleur lecture des forêts

```
:-tagop(':').
s ---> subject:np, verb:v, object:np.
```

Forêts et DyALog (suite

Les forêts extraites avec DyALog peuvent être converties en des représentations XML et des vues graphiques

- vue graphe de dérivations
- vue graphe de dépendance

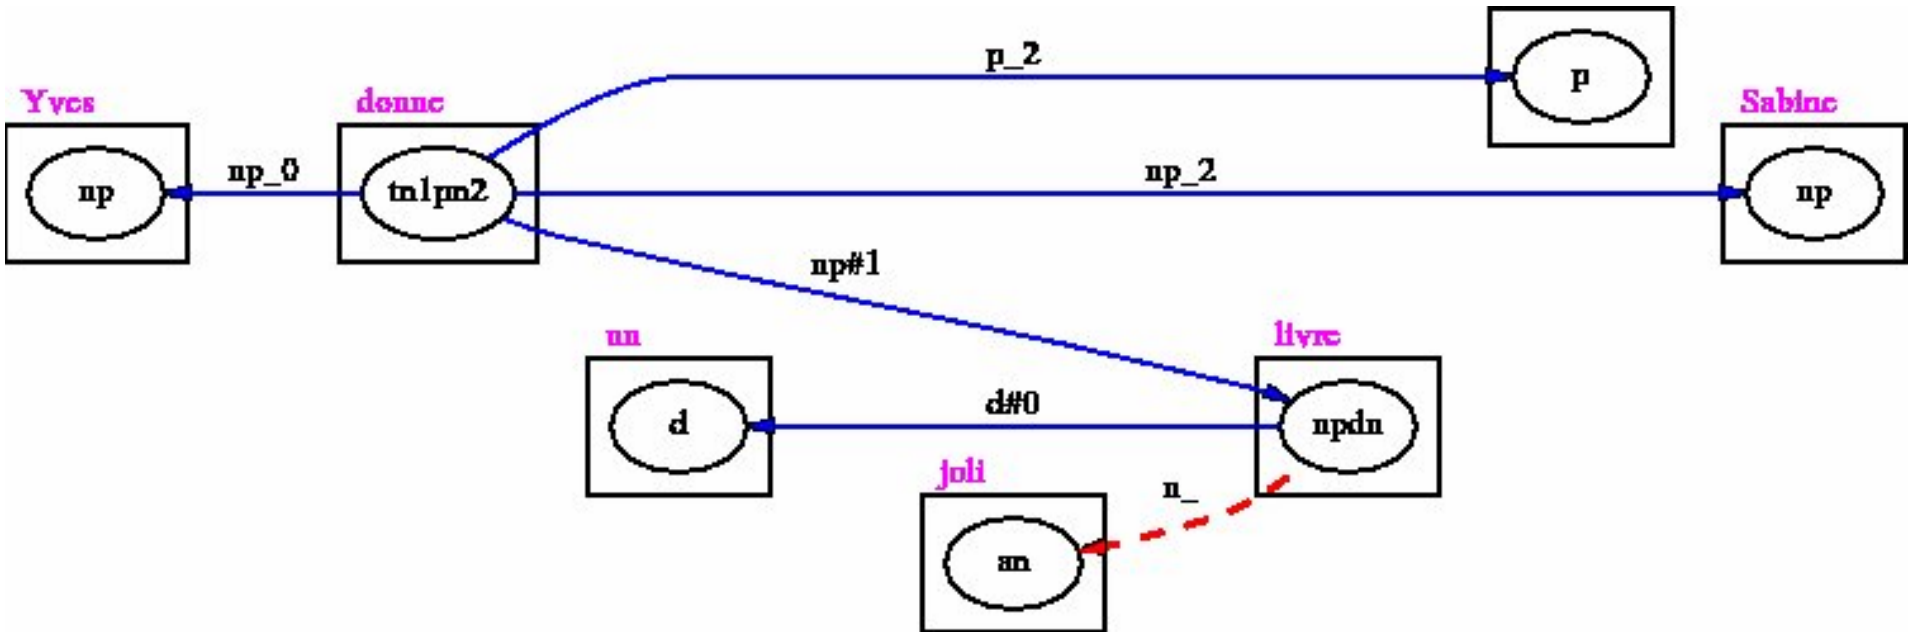

Test en-ligne : serveur d'analyseurs `http://alpage.inria.fr/demos`

Travailler sur les forêts

DyALog fournit des prédicats d'introspection permettant de travailler sur des pointeurs arrière des objets

```
%% forest(ObjAddr,Type,Parent1_Addr,Parent2_Addr,Label,Ind)

backptr(Answer) :-
    item_term(Item,Answer),
    recorded(Item,Item_Addr),
    forest(Item_Addr,Type,Parent1_Addr,Parent2_Addr,_).
```

```
forest_type(0,init).   % for initial objects                    bptr =
    init
forest_type(1,call).   % for objects resulting from call        bptr =
    call
forest_type(2,and).    % for std objects                        bptr =
    and(trans,item)
forest_type(3,or).     % for alternatives                       bptr =
    or(bptr1,bptr2)
```

Travailler sur les forêts (suite)

Existence d'une bibliothèque de plus haut niveau pour afficher les forêts

```
:-require 'forest.pl'
show_forest(Answer) :- wrapped_forest(Answer).
```

Onzième partie XI

Tabulation et suspension

Outline

Formulation fonctionnelle de Fibonacci

Fibonacci récursivement définie par : $\begin{cases} \text{fib}(n+2) = \text{fib}(n+1) + \text{fib}(n) \\ \text{fib}(2) = \text{fib}(1) = 1 \end{cases}$

- formule directe en fonctionel
- évaluation avec pile $\Rightarrow$faible consommation mémoire

```
int fib( int n ){
  if (n>2) return fib(n-1) + fib(n-2);
  else     return 1;
}
```

Formulation fonctionnelle de Fibonacci

Fibonacci récursivement définie par : $\begin{cases} \mathrm{fib}(n+2) = \mathrm{fib}(n+1) + \mathrm{fib}(n) \\ \mathrm{fib}(2) = \mathrm{fib}(1) = 1 \end{cases}$

- formule directe en fonctionel
- évaluation avec pile $\Rightarrow$faible consommation mémoire

```
int fib( int n ){
  if (n>2) return fib(n−1) + fib(n−2);
  else     return 1;
}
```

Mais programme non efficace :

$\mathrm{fib}(5)$

n	5	4	3	2	1
appels	1	1	2	3	5

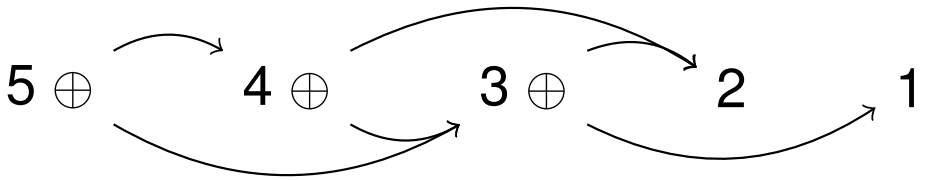

Remède : mémoriser appels et réponses à $\mathrm{fib}(n)$.

Memo-functions or cache

Mémorisation ajoutée à l'évaluation par pile en gardant des traces des appels et retours dans une table :

```
int fib( int n ){
  int r;
  if (tab_call_fib[n])          /**/
    return tab_ret_fib[n];/**/
  tab_call_fib[n]=1;            /**/
  if (n>2)
    r = fib(n-1)+fib(n-2);
  else { r = 1; }
  tab_ret_fib[n]=r;             /**/
  return r;
}
```

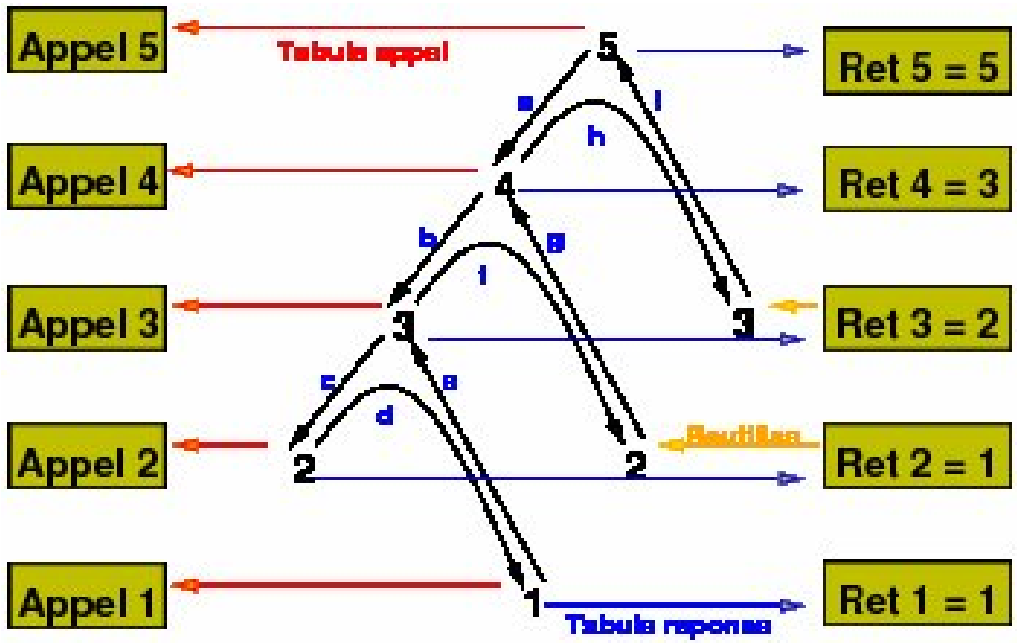

Version simplifiée

Note : Pour Fibonacci, la table des appels est non nécessaire, car pas de cycle.

```
int fib( int n ){
  int r;
  if (tab_ret_fib[n])       /**/
    return tab_ret_fib[n]; /**/
  if (n>2)
    r = fib(n-1)+fib(n-2);
  else { r = 1; }
  tab_ret_fib[n]=r;         /**/
  return r;
}
```

Que faire des boucles

Que faire des boucles dans les appels :

- souvent correspondent à des branches inutiles, qu'on peut ignorer
- mais pas toujours !
  Dépend de type d'agrégation de valeur qu'on souhaite appliquer.

Boucles

Exemples :

- OK sur trouver un chemin ($\exists$) ou le plus court chemin dans un graphe ($\min$)
- Pb sur trouver tout les chemins ($\cup$), le chemin le plus long ($\max$), la moyenne des chemins (avg), ...

$$\mathrm{sp}(x, f) = \min_{arc(x,z)} d(x, z) + \mathrm{sp}(z, f)$$

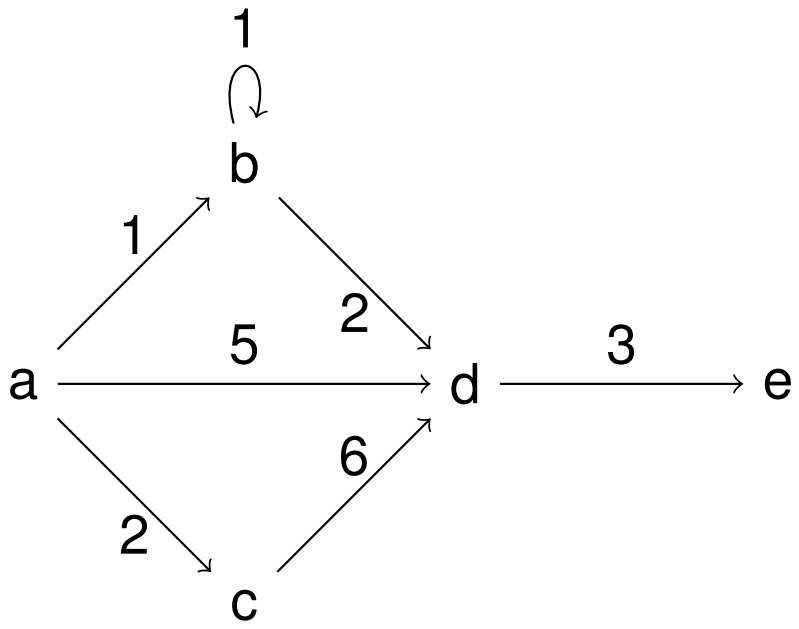

Memoization (Prolog)

Memoization (ou tabling) étend les mémo-fonctions pour la programmation en logique.
Extension : Gestion de la propagation des réponses au travers des boucles

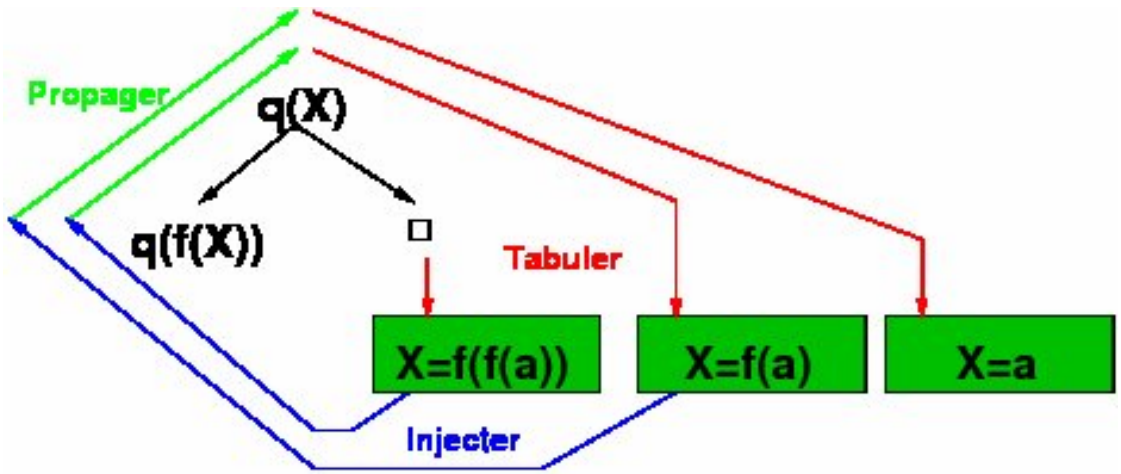

Notion de

noeud producteur avec une liste associée de réponses

noeud consommateur des réponses issues d'un noeud producteur

Memoization (2)

Approche suivie dans le système XSB [D.S. Warren]

La memoization permet

- d'entrelacer des calculs avec et sans tabulation
- de savoir quand un noeud producteur a produit toutes ses réponses
- d'implanter plus facilement et complètement la négation

D'un autre coté, algorithme complexe :

- gestion des boucles enchâssées
- gestion de suspensions et reprises de continuations (avec soit sauvegarde de la pile de contrôle ou re-calcul)

Outline

Divers types de prédicats

Il existe plusieurs types de prédicats en DyALog organisé autour des notions de

- tabulation
- suspension

Classification repose aussi sur la notion de descendant
un prédicat `q` est un descendant de `p` ssi :

- `q` apparaît dans le corps d'une clause définissant `p`
- ou `q` est le descendant d'un descendant de `p`

Note : un prédicat récursif `p` est son propre descendant

Prédicats tabulés

Type par défaut pour les prédicats DyALog
Ces prédicats sont tabulés et suspendables (pour gérer des boucles)

Nécessaires pour les non-terminaux récursifs

```
np --> np,gp.
```

OK mais trop puissant pour fibonacci :

```
fib(0,1).
fib(1,1).
fib(N,M) :- N > 1,
    N1 is N-1, fib(N1,M1),
    N2 is N-2, fib(N2,M2),
    M is M1+M2.
```

Ces prédicats laissent une trace dans la forêt

Prédicats faiblement tabulés

Prédicat `p` faiblement tabulé :

- tabulé
- `p` et ses descendants non suspendables
  pas de boucles, ou boucles ignorées
- laisse une trace dans la forêt

```
:-light_tabulate fib/2, foo{}.
:-light_tabulate dcg(np{}).
:-light_tabulate dcg(_).
```

Le plus efficace pour fibonnaci

```
:-light_tabulate fib/2.
fib(0,1).
fib(1,1).
fib(N,M) :- N > 1,
    N1 is N-1, fib(N1,M1),
    N2 is N-2, fib(N2,M2),
    M is M1+M2.
```

Prédicats faiblement tabulés

Fonctionne pour “trouver un chemin” sur des graphes cycliques.

```
:-light_tabulate exists_path/2.
exists_path(N,N).
exists_path(N,M) :- arc(N,P),exists_path(P,M).
```

Prédicats prolog suspendables

Un prédicat `p` est de type prolog si

- non tabulé
- peut avoir des descendants suspendables
  $\Rightarrow$ entraîne une suspension indirecte de `p`
  $\Rightarrow$ oblige à tabuler le fragment de pile d'appel entre `p` et le point de suspension sur `q`
- ne laisse pas de trace dans la forêt

```
:-prolog foo/3.
```

Prédicats prolog non suspendables

Un prédicat `p` est de type prolog récursif si

- non tabulé
- tous les descendants (`p` inclus) sont non suspendables
- très proches du mode Prolog standard (profondeur d'abord, retours arrière) même problèmes que pour Prolog !
- ne laisse pas de trace dans la forêt

```
:-rec_prolog verbose/2.
verbose(Fmt,Args) :- option('-verbose'), format(Fmt,Args).
verbose(Fmt,Args) :- option('-noverbose').
```

Version peu efficace de fibonnaci :

```
:-rec_prolog fib/2.
fib(0,1).
fib(1,1).
fib(N,M) :- N > 1,
    N1 is N-1, fib(N1,M1),
    N2 is N-2, fib(N2,M2),
    M is M1+M2.
```

Prédicat prolog non suspendables

Cas particulier de prédicat récursivement prolog pour ceux définis par une seule clause.

- même propriétés que pour rec_prolog
- mais traitement plus efficace

```
:-std_prolog fib/2.
fib(N,M) :-
    ( N = 0 -> M = 1
    ; N = 1 -> M = 1
    ; N > 1,
     N1 is N-1, fib(N1,M1),
     N2 is N-2, fib(N2,M2),
     M is M1+M2
    ).
```

Prédicats extensionels

Prédicats uniquement définis

- en extension par une liste de faits
- et par aucune clause

Ils sont tabulés, non suspendables et ne laisse pas de trace dans la forêt.

```
:-extensional 'C'/3.
'C'(0,une,1).
'C'(1,pomme,2).

%% pour une trace dans la forêt
:-light_tabulate token/3.
token(L,Token,R) :- 'C'(L,Token,R).
```

Gardes

Utilisées pour contruire des conditionnelles IF-THEN-ELSE

```
( Guard -> TrueExp ; FalseExp )
```

Une garde est une expression non suspendable, donc construite à partir

- de prédicats non suspendables
  builtins, light_tabular , rec_prolog, std_prolog, extensional
- des opérateurs de corps de clauses
  conjonction, disjonction, conditionnelles ->

Note : une garde peut apparaître dans des prédicats suspendables

Outline

Parallélisme

Proposition de parallélisme pour Prolog Gupta, Santos Costa, Warren, Karlsson

- Parallélisme OR : les alternatives sont explorées en parallèle
- Parallèlisme AND : les littéraux d'un corps de clause sont explorés en parallèle
  $\Rightarrow$ nécessite communication pour les instanciations de variables
- concurrence : parallélisme AND avec points de synchronization
  $\Rightarrow$ gestion possible par suspension

Exemple

```
sendmore(Digits) :-
    Digits = [S,E,N,D,M,O,R,Y],          % Create variables
    Digits :: [0..9],                    % Associate domains to
     variables
    S #\= 0,                             % Constraint: S must be
     different from 0
    M #\= 0,
    alldifferent(Digits),                % all the elements must take
     different values
                  1000*S + 100*E + 10*N + D     % Other constraints
                + 1000*M + 100*O + 10*R + E
    #= 10000*M + 1000*O + 100*N + 10*E + Y,
    labeling(Digits).                    % Start the search
```

Programmation concurrente par contraintes

Formalisée par Saraswat

- existence d'un magasin (*store*) de contraintes
- tell (C) pour ajouter une contrainte *C* dans le magasin
  échec si cette contrainte rend le magasin incohérent
- ask(C) pour être averti dès que la contrainte *C* devient vraie grâce au magasin
- un propagateur de contraintes peut s'écrire en combinant `ask` et `tell`

```
solve :-
    set_constraints,
    propagate,
    display.
propagate :- ask(X<Y),ask(Y<Z),tell(X<Z).
...
```

Note : le store est nettoyé au moment des retours-arrière
i.e. élimination des contraintes ajoutées après le point de choix

Oz/Mozart

Langage multi-paradigmes :

- fonctionnel
- orienté objets
- programmation logiques
- contraintes
- concurrence
- distribué et mobilité

`http://www.mozart-oz.org/`

Mozart : exemple

```
proc {Ints N Xs}
   or N = 0 Xs = nil
   [] Xr in
      N > 0 = true Xs = N|Xr
      {Ints N-1 Xr}
   end
end
local
   proc {Sum3 Xs N R}
      or Xs = nil R = N
      [] X|Xr = Xs in
         {Sum3 Xr X+N R}
      end
   end
in proc {Sum Xs R} {Sum3 Xs 0 R} end
end
local N S R in
   thread {Ints N S} end
   thread {Sum S {Browse}} end
   N = 1000
end
```

DyALog et concurrence

La tabulation dans DyALog offre une forme réduite de concurrence :

- le store est donné par la table.
  Un `tell` correspond à ajouter un objet dans la table

```
tell(X) :- check_coherence(X).
```

- l'opération `ask` est donnée par le prédicat '$answers'(G) qui attend les réponses à `G` dans la table

```
ask(X) :- '$answers'(tell(X)).
```

Forme approchée de concurrence car :

- la table est une structure globale
- mais de backtrack sur la table

Exemple :

guidage DCG avec une approximation en langage régulier

```
?-recorded('N'(N)),phrase(approx_s,0,N),fail.
?-recorded('N'(N)),phrase('$answers'(approx_s),0,N),tag_phrase(s
    {},0,N).
%% Similar check for all DCG non-terminals
```

Exemple : coordination

Gestion de la coordination :

Idée : suivre des dérivations parallèles similaires à droite et gauche du coordonnant

```
%% one main parsing ''agent''
?-recorded('N'(N)), tag_phrase(s,0,N).
%% auxiliary ''agents'' for coords
?-coord_handler,fail.

coord_handler :-
        'C'(L, et, R),    % locate coordination places
        %% wait for derivations reaching coordination
        tag_phrase('$answers'(NT),K,L),
        tag_phrase(NT,gen_pos(Right,Left1),gen_pos(Right2,Left))
        .

%% Try to reuse a coordination handled by watch_coord
my_subst_handler(P,Bot,Left,Right,N) :-
        tag_phrase('$answers'(id=N at P),Left,Right1),
        tag_phrase(id=coord at <=> coo,Right1,Left2),
        tag_phrase('$answers'(id=N at P),
                   gen_pos(Left2,Left),gen_pos(Right,Right1)).
```

Exemple : méta-analyseur

Facile d'implémenter des méta-analyseurs tabulaires avec DyALog
mais plus difficile pour d'extraire la forêt partagée (séparation grammaires et méta-niveau)

```
:-mode([parse_node/5,parse_subtree/5], +(+,+,-,+,-) ).

parse_node( tag_node{ kind=>foot, cat=>Cat},
                    Left,Right, Adj_In, Left*Right
          ) :-
    '$answers'( register_continuation(Adj_In,Label,Old_Node,Old_Adj_In) )
    ,
    parse_subtree(Old_Node,Left,Right,Old_Adj_In,_).
parse_node( Node::tag_node{ kind=>std, cat=>Cat},
                    Left,Right, Adj_In,Adj_Out
          ) :-
  (   parse_subtree(Node,Left,Right,Adj_In,Adj_Out)
  ;
      register_continuation(Left,Cat,Node,Adj_In),
      parse_adj(Cat,Left,Right,Foot_Left*Foot_Right),
     '$answers'( parse_subtree(Node,Foot_Left,Foot_Right,Adj_In,Adj_Out)
    )
  ).

%% Register a continuation for the subtree below an adjunction node
register_continuation(Left,Cat,Node,Adj).
```

Douzième partie XII

Compléments sur DyALog

Lecture bidirectionnelle

```
s --> np,vp.
head(s,vp).   % ==> s --> np <+ vp
vp --> v(Type), v_args(Type).
head(vp,v).   % ==> vp --> v(Type) +> v_args(Type)
```

Lexicalisation

Lexicalization et DyALog

Non obligatoire dans les grammaires pour DyALog, mais permet une meilleure efficacité :
Principe : chargement conditionnel des clauses (ou arbres pour les TAGs) :

```
'$loader'( phrase([qui],_,_),
           ( np --> np, [qui], s_rel )
         ).
```

- Automatiquement induite pendant la compilation (option `-autoload`) pour TAG et TIG (noeuds lexicaux + ancres), DCG & BMG (lexicaux)
- Utiles pour tester des conditions plus spécifiques (pas nécessairement liées à la lexicalisation)

Robustesse

Robustesse et DyALog

- Facile de rendre des analyses partielles

```
% full parsing
?-recorded('N'(R)), L=0, phrase(S::s{},L,R).

% partial parsing
?-tag_phrase(s,L,R); phrase(np,L,R).
```

- possibilité d'utiliser des stratégies bidirectionnelles dirigées par les têtes(DCGs)
- utilisation des FSA en entrée : gestion des amabiguïtés, mots incnnus, ...
- prédicats d'introspection pour explorer le contenu de la table
  $\Rightarrow$ ouvre la voie vers des algorithmes de corrections

Modulation

dcg_mode(np/2,+(−,−),+,−)
Stratégie descendante : :−dcg_mode(_,+,+,−)
Stratégie ascendante : :−dcg_mode(_,−,−,−)

Définir son lecteur

```
:-skipper(skip_lexical).
:-std_prolog skip_lexical/3.
skip_lexical(Left,Token,Right) :-
    'C'(Left,
        lemma{ lex => Token, cat => epsilon },
        Right ).
```

Namespaces et modules

DyALog fournit

- la notion de namespaces pour éviter les conflits de noms : private !foo
- la notion demodules, fondée sur les namespaces et sur un mécanisme d'import

```
:-module(forest).              %% Forest module with namespace forest
:-import{ file=>'format.pl', preds => [format/2] }.
:-std_prolog display_forest/1.
....
:-end_require.                 %% public interface
```

```
:-import{ module=>forest, preds => display_forest/1 }. %% import
    forest module
```

Mais pas de vraie notion de prédicats privés (similaire à la notion de modules en Perl)

Modules

Directives `:-include`, `:-require`, `:-import` et `:-module/1` import et export.

```
:-import{ module=> sqlite,
          file => 'libdyalogsqlite.pl',
          preds => [
                     open/2,
                     close/1,
                     exec/4
                   ]
        }.

test :-
  argv([File]),
  open(File,DB),  %% équivalent à sqlite!open
  exec(DB,'create table toto (k TEXT,v INTEGER)',[],_R),
  exec(DB,'insert into toto(k,v) values (?,?)',[a,2],done),
  close(DB)
.
```

Interface vers C

```
socket_bind(Socket,Address) :-
  ( Address = 'UNIX'(Name) ->
      '$interface'( 'Socket_Bind_Unix'(Socket: int, Name: string)
    , [] )
  ;   Address = 'INET'(Host,Port),
      ( var(Port) -> In_Port = 0 ; In_Port = Port ),
        '$interface'( 'Socket_Bind_Inet'(Socket: int,
                                         Host: string,
                                         In_Port: int,
                                         Out_port: -int),
                      [] )
  ).
```