

## Plan

# Traduction et Sémantique Analyse descendante, l'outil Yacc

Luigi Santocanale  
LIF, Université de Provence  
Marseille, FRANCE

12 février 2010

Analyse et grammaires LL(1)  
Des idées  
NULL, FIRST et FOLLOW  
Construction de l'APD

Les outils yacc et bison  
Les débuts  
Ajout d'actions

## Plan

$w \in L(\mathcal{G})$  : analyse descendante récursive

Analyse et grammaires LL(1)  
Des idées  
NULL, FIRST et FOLLOW  
Construction de l'APD

Les outils yacc et bison  
Les débuts  
Ajout d'actions

- Construire un arbre de dérivation (ou une DG) de  $w$  à partir de l'axiome  $S$ .
- Essayer, de façon récursive, toutes les productions ...
  - ... pas efficace, mais certaines fois on peut être chanceux.
  - On peut s'aider en lisant un morceau du mot  $w$  (prévision)
- La pile implicite des appels récursifs peut être substituée par une pile explicite d'un AP.

## Analyse LL(1)

### Un exemple

Soit  $\mathcal{G}$  :

- Idée :
- en lisant le mot  $w$  à partir de la gauche – left-to-right parse
  - en lisant un caractère à la fois – lookahead 1
  - reconstruire une dérivation gauche du mot  $w$  à partir du symbole  $S$  – leftmost derivation

$$\begin{array}{l} S \rightarrow aT \\ T \rightarrow bT \mid c \end{array}$$


- Le mot  $abc \in L(\mathcal{G})$  car
  - $abc \Rightarrow aT \Rightarrow abT \Rightarrow abc$
- Le mot  $aba \notin L(\mathcal{G})$  car
  - $aba \Rightarrow aT \Rightarrow abT \Rightarrow \text{err}$  : aucune règle à appliquer.

5/33

6/33

### Vers une généralisation

On peut implémenter cet algorithme par un APD :



- Un non-terminal  $A$  peut « engendrer à gauche »  $a \in \Sigma$ , par une suite de productions :

$$\begin{array}{l} A \rightarrow BC \\ B \rightarrow aB \mid \dots \\ C \rightarrow aD \mid \epsilon \mid \dots \end{array}$$

- Un non-terminal  $A$  peut s'effacer, c'est-à-dire engendrer  $\epsilon$  :

$$A \rightarrow BC$$

$$B \rightarrow \epsilon \mid \dots$$

$$C \rightarrow aD \mid \epsilon \mid \dots$$

Si la recherche est guidée par un couple  $(a, A)$ , on peut dépiler  $A$  et considérer le « symbole suivant » sur la pile.

7/33

8/33

## Obstacles

## NULL, FIRST et FOLLOW

On veut construire un APD. Cela n'est pas possible si :

- plusieurs productions du même non-terminal engendrent  $a$ :

$$\begin{aligned} A &\rightarrow aB \mid CD \\ C &\rightarrow aE \mid \dots \end{aligned}$$

- un non-terminal  $A$ 
  - ▶ peut s'effacer,
  - ▶ engendre  $a$ ,
  - ▶ un non-terminal  $B$ , qui peut suivre  $A$  dans la pile, engendre aussi  $a$ :

$$\begin{aligned} A &\rightarrow aB \mid \varepsilon \\ B &\rightarrow aD \\ E &\rightarrow AB \end{aligned}$$

9/33

## Le calcul de NULL

NULL est le plus petit ensemble sous-ensemble de  $V$  tel que :

1. si  $A \rightarrow \varepsilon$ , alors  $A \in \text{NULL}$ ,
2. si  $A \rightarrow X_1 \dots X_n$  et  $X_1, \dots, X_n \in \text{NULL}$ , alors  $A \in \text{NULL}$ .

Un algorithme standard :

```
null = []
null_next = {A ∈ V | A → ε}
tant que null != null_next faire
    null=null_next
    pour toute production A → X1...Xn
        si X1, ..., Xn ∈ null
            ajouter A à null_next
        fin pour
    fin faire
retourner null
```

Pour  $\mathcal{G} = \langle V, \Sigma, S, P \rangle$ , posons :

$$\begin{aligned} \text{NULL} &= \{ \text{non-termiaux qu'on peut « effacer »} \} \\ &= \{ A \in V \mid A \Rightarrow^* \varepsilon \} \end{aligned}$$

$$\begin{aligned} \text{FIRST}(X) &= \{ \text{termiaux qu'on peut « engendrer à gauche »} \\ &\quad \text{à partir de } X \in V \} \\ &= \{ a \in \Sigma \mid X \Rightarrow^* a\alpha \} \end{aligned}$$

$$\begin{aligned} \text{FOLLOW}(A) &= \{ \text{termiaux peuvent suivre } A \\ &\quad \text{dans un premier morceau d'une dérivation} \} \\ &= \{ b \in \Sigma \mid S \Rightarrow^* \alpha Ab\beta \} \end{aligned}$$

10/33

## Le calcul de FIRST

$$\begin{aligned} \{ \text{FIRST}(X) \mid X \in V \} \\ \text{est la plus petite collection de sous-ensembles de } \Sigma \text{ telle que :} \end{aligned}$$

1. si  $X = a \in \Sigma$ , alors  $\text{FIRST}(X) = \{ a \}$ ,
2. si

$$X \rightarrow Y_1 \dots Y_n Z \alpha$$

et  $Y_1, \dots, Y_n \in \text{NULL}$ , alors  $\text{FIRST}(Z) \subseteq \text{FIRST}(X)$ .

En fait, si  $a \in \text{FIRST}(Z)$  :

$$X \Rightarrow Y_1 \dots Y_n Z \alpha$$

11/33

12/33

## Caractérisation de FOLLOW (I)

## Caractérisation (et calcul) de FOLLOW (II)

Si  $c \in FIRST(X)$ , alors :

$$\begin{aligned} S \Rightarrow \dots \Rightarrow \dots A \dots \Rightarrow \dots \alpha B \textcolor{red}{Y}_1 \dots \textcolor{red}{Y}_n X \beta \dots &\Rightarrow \dots \\ &\Rightarrow \dots \alpha B X \beta \dots \Rightarrow \dots \Rightarrow \dots \alpha B c \beta \dots \end{aligned}$$

Si  $S \Rightarrow^* \dots Ad \dots$  – c'est-à-dire  $d \in FOLLOW(A)$  :

$$\begin{aligned} S \Rightarrow \dots \Rightarrow \dots A \dots \Rightarrow \dots \alpha B \textcolor{red}{Y}_1 \dots \textcolor{red}{Y}_n \dots &\Rightarrow \dots \\ &\Rightarrow \dots \alpha B \dots \Rightarrow \dots \Rightarrow \dots \alpha Bd \dots \end{aligned}$$

13/33

## Un exemple : FIRST

Soit  $\mathcal{G}$  :

$$\begin{array}{ll} E \rightarrow T \textcolor{red}{E}' & E' \rightarrow + T \textcolor{red}{E}' \mid \varepsilon \\ T \rightarrow F T' & T' \rightarrow * F \textcolor{red}{T}' \mid \varepsilon \\ F \rightarrow ( E ) \mid id & F \rightarrow ( E ) \mid id \end{array}$$

Les contraintes :

$$\begin{array}{ll} FIRST_E \supseteq FIRST_T & FIRST_{E'} \supseteq \{+\} \\ FIRST_T \supseteq FIRST_F & FIRST_{T'} \supseteq \{* \} \\ FIRST_F \supseteq \{(id\}) & \end{array}$$

La solution :

$$\begin{array}{ll} FIRST_E = \{(id\}\} & FOLLOW_E = \{\} \\ FIRST_T = \{(id\}\} & FOLLOW_T = \{+\,\} \\ FIRST_F = \{(id\}\} & FOLLOW_F = \{*,+\,\} \end{array}$$

$\{ FOLLOW(B) \mid B \in V \setminus \Sigma \}$   
est la plus petite collection de sous-ensembles de  $\Sigma$  telle que :

1. si  $A \rightarrow \alpha B \textcolor{red}{Y}_1 \dots \textcolor{red}{Y}_n X \beta$   
et  $Y_1, \dots, Y_n \in NULL$ , alors  $FIRST(X) \subseteq FOLLOW(B)$ ,
2. si  $A \rightarrow \alpha B \textcolor{red}{Y}_1 \dots \textcolor{red}{Y}_n$

et  $Y_1, \dots, Y_n \in NULL$ , alors  $FOLLOW(A) \subseteq FOLLOW(B)$ .

Pour le calculer, on utilise un algorithme standard pour chercher la plus petite solution de contraintes monotones.

14/33

## Un exemple : FOLLOW

Soit  $\mathcal{G}$  :

$$\begin{array}{ll} E \rightarrow T \textcolor{red}{E}' & E' \rightarrow + T \textcolor{red}{E}' \mid \varepsilon \\ T \rightarrow F T' & T' \rightarrow * F \textcolor{red}{T}' \mid \varepsilon \\ F \rightarrow ( E ) \mid id & \end{array}$$

Les contraintes :

$$\begin{array}{ll} FOLLOW_E \supseteq \{\} \} & FOLLOW_{E'} \supseteq FOLLOW_E \\ FOLLOW_T \supseteq \{+\} \cup FOLLOW_E & FOLLOW_{T'} \supseteq FOLLOW_T \\ FOLLOW_F \supseteq \{*\} \cup FOLLOW_T & \end{array}$$

La solution :

$$\begin{array}{ll} FOLLOW_E = \{\} \} & FOLLOW_{E'} = \{\} \} \\ FOLLOW_T = \{+\,\} \} & FOLLOW_{T'} = \{+\,\} \} \\ FOLLOW_F = \{*,+\,\} \} & \end{array}$$

15/33

16/33

## Grammaires $LL(1)$

## Construction de l'APD

Pour  $\gamma \in V^*$  soit

$$FIRST(\gamma) = \{a \in \Sigma \mid \gamma \Rightarrow^* a\alpha\}$$

de façon que :

$$FIRST(X_1 X_2 \dots X_n) = \bigcup_{i=1, \dots, n} \{FIRST(X_i) \mid X_1, \dots, X_{i-1} \in NULL\}.$$

Définition : Une grammaire  $\mathcal{G}$  est  $LL(1)$  si, pour tout  $A$  tel que

$$A \rightarrow \alpha_1 \mid \dots \mid \alpha_n$$

on a :

- $FIRST(\alpha_i) \cap FIRST(\alpha_j) = \emptyset$  si  $i \neq j$ ,
- si  $A \in NULL$ , alors  $FIRST(\alpha_i) \cap FOLLOW(A) = \emptyset$ , pour  $i = 1, \dots, n$ .


## Les transitions

$\Delta$  est de la forme :

- Consommer  $a$  :




- Suivre une production :



si  $A \rightarrow X_1 \dots X_n$  et  $a \in FIRST(X_1 \dots X_n)$ .

- Effacer un non-terminal :



où  $A \in NULL$  et  $a \in FOLLOW(A)$ .

- Etant donné  $\mathcal{G}$ , on construit un AP  $M_{\mathcal{G}} = \langle \Sigma, Q, i, \Gamma, \Delta \rangle$ , tel que :

$$\begin{aligned} Q &= \{i\} \cup \{a \mid a \in \Sigma\}, \\ \Gamma &= V, \\ \Delta &: \text{page suivante.} \end{aligned}$$

- $M_{\mathcal{G}}$  est une APD si  $\mathcal{G}$  est  $LL(1)$ .

- Cet AP accepte par ruban et pile vide.

- Le AP

- $M_{\mathcal{G}}$  est une APD si le sommet de la pile  $A$ ,

- lit un caractère  $a$  et le sommet de la pile  $A$ ,
- si  $A \rightarrow \alpha$  avec  $\alpha \in FIRST(A)$ , alors construit l'étape

$$wA\beta \Rightarrow w\alpha\beta$$

d'une dérivation gauche,


- si  $A \Rightarrow^* \varepsilon$  avec  $b \in FOLLOW(A)$ , alors construit les étapes

$$wA\beta \Rightarrow^* w\beta$$

d'une dérivation gauche.

18/33

## Notre premier exemple




17/33

19/33

20/33

## Le deuxième exemple

## Plan



## Histoire de Yacc

- Écrit entre 1975 et 1978 par S.C. Johnson at Bell Labs
- « Yet Another Compiler Compiler »
- Berkeley yacc, écrit en 1985 par B. Corbett  
algorithmes améliorés, licence Berkeley
- Bison : évolution du Berkeley Yacc,  
distribué sous licence GNU (GPL)

## Structure d'un fichier yacc : déclarations

```
/** Déclarations **/  
%{  
/* Décl. du code C */  
#include <stdio.h>  
#include <stdlib.h>  
}  
  
/* Décl. des terminaux */  
%token PLUS MULT  
%token PG PD  
%token ID
```

## Structure d'un fichier yacc : grammaire


## Structure d'un fichier yacc : code

```
%  
/* Section Grammaire */  
  
exp: term expp  
;  
expp: PLUS term expp  
|  
;  
term: facteur temp  
;  
temp: MULT facteur temp  
|  
;  
facteur: PG exp PD  
| ID  
;  
  
%  
/* Section Code C **/  
  
int yyerror(char *str){  
    fprintf(stderr,"erreur : %s\n",str);  
    exit(EXIT_FAILURE);  
}  
  
int main(int argc, char * argv []){  
    yyparse();  
    printf("Analyse terminee\n");  
    exit(EXIT_SUCCESS);  
}
```

25/33

## Interactions avec lex et le lexer

À la compilation :



## Le fichier lex et son include

Le fichier lex :

```
%{  
#include "yaccexample.tab.h"  
%}  
%option noyywrap  
%%  
[a-zA-Z]+ {return ID;}  
\C {return PG;}  
\V {return PD;}  
\+ {return PLUS;}  
\* {return MULT;}  
%%
```

Le fichier yacc :  
yaccexample.tab.h:

```
/* Tokens */  
/*  
#define PLUS 258  
#define MULT 259  
#define PG 260  
#define PD 261  
#define ID 262  
*/
```

27/33


28/33

## À l'exécution

## Structure d'un fichier yacc : déclarations

```
/* Déclarations */
%{
    /* Décl. du code C */
    #include <stdio.h>
    #include <stdlib.h>
    %}
    /* Décl. des terminaux */
    %token PLUS MULT
    %token PG PD
    %token CONST
```

29/33



## Structure d'un fichier yacc : grammaire

```
%%
/* Section Grammaire */
start: exp {printf("Resultat : %d\n", $1);}
;
exp: term expp { $$ = $1 + $2;}
;
expp: PLUS term expp { $$ = $2 + $3;}
| { $$ = 0;}
;
term: facteur temp { $$ = $1 * $2;}
;
temp: MULT facteur temp { $$ = $2 * $3;}
| { $$ = 1;}
;
facteur: PG exp PD { $$=$2;}
| CONST { $$=$1;}
;
```

%

## Structure d'un fichier yacc : code

```
/* Section Code C */
int
yyerror(char *str){
    fprintf(stderr,"erreur : %s\n", str);
    exit(EXIT_FAILURE);
}

int
main(int argc, char * argv[])
{
    yyparse();
    printf("Analyse terminee.\n");
    exit(EXIT_SUCCESS);
}
```

30/33

31/33

## *Le fichier lex et son include*

Le fichier lex :

```
%{  
#include "yaccexample2.tab.h"  
%}  
%option noyywrap  
%%  
[0-9]+ {  
    yyval = atoi(yytext);  
    return CONST;  
}(  
\{  
\)  
\)  
\+  
\*  
%%
```

Le fichier

```
yaccexample2.tab.h :  
/* Tokens. */  
#define PLUS 258  
#define MULT 259  
#define PG 260  
#define PD 261  
#define CONST 262
```