

## Grammaires et Analyse Syntaxique - Cours 6

### Introduction à l'analyse ascendante

Ralf Treinen



treinen@irif.fr

5 mars 2025

© Ralf Treinen 2020–2025

## Analyse descendante : avantages et inconvénients

- ▶ **Avantage** : facile à implémenter à la main quand la grammaire est LL(1).
- ▶ **Inconvénient** : peut nécessiter des contorsions de la grammaire quand la grammaire n'est pas LL(1).
- ▶ Des modifications de la grammaire bousculent la structure de l'arbre de dérivation.
- ▶ Un changement fondamental de la grammaire est gênant car on s'intéresse à la fin aussi à la structure trouvée par l'analyse (l'arbre de dérivation) qui maintenant ne correspond plus à la grammaire initiale.

## Analyse descendante

- ▶ Nous avons vu aux cours 4 et 5 une méthode d'analyse *descendante* (angl. : *top-down*, ou dans le contexte de l'analyse grammaticale *recursive descent*) :
- ▶ L'analyse descendante construit l'arbre de dérivation en commençant par la racine, et puis ajoute dans l'arbre des enfants dans un ordre descendant et de gauche à droite.
- ▶ L'analyse descendante correspond à la construction d'une dérivation gauche.
- ▶ Cette dérivation gauche est construite dans l'ordre naturel : on commence avec l'axiome, et on termine sur le mot d'entrée.
- ▶ On a assez peu d'information pour guider la construction : Le non-terminal courant, et le symbole suivant de l'entrée.

## Analyse ascendante

- ▶ L'alternative à l'analyse descendante est l'analyse *ascendante* (angl. : *bottom-up*) :
- ▶ L'analyse ascendante construit l'arbre de dérivation en commençant par les feuilles, et en faisant grandir l'arbre par combinant des arbres existants par des nouveaux nœuds.
- ▶ Ça correspond à quel type de dérivation ? Voir la suite !
- ▶ Nous avons maintenant beaucoup plus d'informations pour guider la construction de l'arbre : on a déjà des arbres de dérivations qu'il suffit de combiner.
- ▶ Pour cette raison l'analyse ascendante peut être plus puissante que l'analyse descendante.

## Analyse descendante vs. analyse ascendante

- ▶ Exemple : la grammaire

$$E \rightarrow (E+E) \mid (E * E) \mid i$$

- ▶ Quand l'analyse *descendante* voit le symbole (, elle ne sait pas quelle production appliquer.
- ▶ Nous avons vu au cours 4 que cette grammaire n'est pas LL(1).
- ▶ Quand l'analyse *ascendante* voit que des parties de l'entrée sont reconnues comme étant des (, E, +, E, ), elle sait que ça correspond à la première production, et elle va combiner ces 5 arbres par un nouveau nœud E.


## Pile et Entrée pendant l'analyse ascendante

Règles :  $S \rightarrow E \$$   $E \rightarrow E + T \mid T$   $T \rightarrow T * F \mid F$   $F \rightarrow ( E ) \mid i$


Partie de l'entrée déjà lue :  $i+i$

Reste à lire :  $*i\$$

pile (sommet à droite) :



entrée :



## Analyse ascendante

- ▶ Elle lit l'entrée de gauche à droite.
- ▶ Le principe est que des parties de l'entrée sont combinées en des morceaux d'arbre de dérivation dès que possible.
- ▶ Structures de donnée de l'analyseur ascendant :
  - ▶ le reste de l'entrée qui reste à consommer
  - ▶ une pile de symboles de  $\Sigma \cup N$ . Elle représente la partie de l'entrée qu'on a déjà consommé, et pour laquelle on a déjà construit des morceaux d'arbre.
- ▶ Toutes les réductions (applications d'une règle dans le sens ascendant) se font sur la partie haute de la pile.
- ▶ Un non-terminal sur la pile est en vérité la racine d'un morceau d'arbre de dérivation.

## Actions dans l'analyse ascendante

- ▶ Il a quatre types d'action :
  - ▶ **shift** : transférer le symbole suivant de l'entrée sur le sommet de la pile ;
  - ▶ **reduce**  $N \rightarrow \alpha$  : remplacer une séquence  $\alpha$  qui se trouve en haut de la pile par un N, quand  $N \rightarrow \alpha$  est une règle de la grammaire ;
  - ▶ **accepter** ;
  - ▶ signaler une **erreur**.
- ▶ On parle aussi de *shift-reduce parser* car shift et reduce sont les actions essentielles.

## Shift

Situation de départ :

pile (sommets à droite) :

$x_1$	$x_2$	$x_3$
-------	-------	-------

entrée :

$a_1$	$a_2$	$a_3$	$a_4$
-------	-------	-------	-------

Situation après un **shift** :

pile (sommets à droite) :

$x_1$	$x_2$	$x_3$	$a_1$
-------	-------	-------	-------

entrée :

$a_2$	$a_3$	$a_4$
-------	-------	-------

## Exemple

- La grammaire  $G_1 = (\{i, +, *, (, ), \$\}, \{S, E, T, F\}, S, P)$ , où  $P$  est

$$\begin{aligned} S &\rightarrow E \$ \\ E &\rightarrow E + T \mid T \\ T &\rightarrow T * F \mid F \\ F &\rightarrow ( E ) \mid i \end{aligned}$$

- Cette grammaire engendre les expressions arithmétiques avec  $+$  et  $*$ , en prenant en compte la priorité de  $*$  sur  $+$ , et l'associativité à gauche de  $+$  et de  $*$ .
- En fait cette grammaire n'est pas LL(1), comme nous avons vu au cours 5.

## Reduce

Situation de départ :

pile (sommets à droite) :

$x_1$	$x_2$	$y_1$	$y_2$	$y_3$
-------	-------	-------	-------	-------

entrée :

$a_1$	$a_2$	$a_3$
-------	-------	-------

Situation après un **reduce**  $N \rightarrow y_1 y_2 y_3$  :

pile (sommets à droite) :

$x_1$	$x_2$	$N$
-------	-------	-----

entrée :

$a_1$	$a_2$	$a_3$
-------	-------	-------

## Exemple : actions du parseur

- Règles de la grammaire :

$$S \rightarrow E \$ \quad E \rightarrow E + T \mid T \quad T \rightarrow T * F \mid F \quad F \rightarrow ( E ) \mid i$$

- Actions : s (shift), r (reduce), a (accept)

pile	entrée	action	pile	entrée	action
	$i+i*i\$$	s	E+T	$*i\$$	s
i	$+i*i\$$	r $F \rightarrow i$	E+T*	$i\$$	s
F	$+i*i\$$	r $T \rightarrow F$	E+T*i	$\$$	r $F \rightarrow i$
T	$+i*i\$$	r $E \rightarrow T$	E+T*F	$\$$	r $T \rightarrow T * F$
E	$+i*i\$$	s	E+T	$\$$	r $E \rightarrow E + T$
E+	$i*i\$$	s	E	$\$$	s
E+i	$*i\$$	r $F \rightarrow i$	E\$		r $S \rightarrow E\$$
E+F	$*i\$$	r $T \rightarrow F$	S		a

## Exemple : quelle est la dérivation produite ?


- ▶ On regarde la suite des reductions sur la concaténation de pile et entrée :  
 $i+i*i\$ - F+i*i\$ - T+i*i\$ - E+i*i\$ - E+F*i\$ - E+T*i\$ - E+T*F\$ - E+T \$ - E\$ - S$
- ▶ Inverser l'ordre de cette séquence :  
 $S - E\$ - E+T \$ - E+T*F\$ - E+T*i\$ - E+F*i\$ - E+i*i\$ - T+i*i\$ - F+i*i\$ - i+i*i\$$
- ▶ C'est une dérivation droite !
- ▶ Donc, la parseur shift-reduce construit une dérivation droite dans un ordre inversé.
- ▶ Regardons cela maintenant avec construction de l'arbre de dérivation.

## Efficacité

- ▶ Pour appliquer une opération de *reduce*  $N \rightarrow \alpha$  il faut chercher une occurrence de  $\alpha$ .
- ▶ L'intérêt de la construction d'une dérivation droite construite à l'envers est qu'il suffit de chercher  $\alpha$  dans la pile.
- ▶ En plus, si on réussit à éviter des *shift* prématurés, il suffit de regarder seulement le haut de la pile !

## Exemple de l'exécution d'un parseur *shift/reduce*

$S \rightarrow E \$ \quad E \rightarrow E + T \mid T \quad T \rightarrow T * F \mid F \quad F \rightarrow ( E ) \mid i$   
 Situation initiale Après *Shift* Après *Reduce*  $F \rightarrow i$  Après *Reduce*  
 $T \rightarrow F$  Après *Reduce*  $E \rightarrow T$  Après *Shift* Après *Shift* Après *Reduce*  
 $F \rightarrow i$  Après *Reduce*  $T \rightarrow F$  Après *Shift* Après *Shift* Après *Reduce*  
 $F \rightarrow i$  Après *Reduce*  $T \rightarrow T * F$  Après *Reduce*  $E \rightarrow E + T$  Après *Shift* Après *Reduce*  $S \rightarrow E \$$  *Accept!*




## Prendre fausse route

- ▶ Attention le parseur peut a priori aussi prendre une fausse route.
- ▶ Dans une situation où il y a en haut de la pile  $\alpha$  et  $N \rightarrow \alpha$  est une règle :
  - ▶ On peut faire un **reduce**  $N \rightarrow \alpha$ , ou un **shift**
  - ▶ Quand il y a une autre règle  $M \rightarrow \beta$ , et  $\beta$  est également en haut de la pile (c'est possible quand  $\alpha$  est un suffixe de  $\beta$  ou l'inverse) :  
 on peut faire **reduce**  $N \rightarrow \alpha$  ou **reduce**  $M \rightarrow \beta$
- ▶ Comment éviter que notre parseur prenne fausse route ?

## Shift ou Reduce ?


Configuration :



1. Soit **reduce**  $N \rightarrow y_1 y_2 y_3$  :




2. Soit **shift** :



## Exemple 1 : un shift prématuré


$S \rightarrow E \$ \quad E \rightarrow E + T \mid T \quad T \rightarrow T * F \mid F \quad F \rightarrow ( E ) \mid i$

Entrée :  $i+i*i\$$




## Deux Reduce possibles


Pile :



1. Soit **reduce**  $N \rightarrow y_1 y_2 y_3$  :



2. Soit **reduce**  $M \rightarrow y_2 y_3$  :




## Le problème dans l'exemple 1

- ▶ Dans l'exemple 1 on a obtenu en haut de la pile :  $T +$
- ▶ Même si ce qui suit dans l'entrée se réduit vers  $T$  on aura en haut de la pile :  $T + T$
- ▶ On a bien  $S \rightarrow E+T \rightarrow T+T$
- ▶ Mais ce n'est **pas** une dérivation droite !
- ▶ On fait on n'a **pas** que  $S \xrightarrow{d} T+T$
- ▶ On aurait du réduire le premier  $T$  à  $E$  avant de shifter le  $+$

## Exemple 2 : un reduce prématuré

$S \rightarrow E \$ \quad E \rightarrow E + T \mid T \quad T \rightarrow T * F \mid F \quad F \rightarrow ( E ) \mid i$


Entrée :  $i+i*i\$$



## Exemple 3 : mauvais choix de la règle dans une réduction

$S \rightarrow E \$ \quad E \rightarrow E + T \mid T \quad T \rightarrow T * F \mid F \quad F \rightarrow ( E ) \mid i$

Entrée :  $i+i*i\$$



## Le problème dans l'exemple 2

- ▶ Dans l'exemple 2 on a obtenu en haut de la pile :  $E + E$
- ▶ Or,  $E+$  se réduit seulement si on a après un  $T$ .
- ▶ Peu importe le mot  $w \in \Sigma^*$  qu'on trouve après, on ne peut pas avoir que  $Ew \rightarrow^* T$ .
- ▶ On n'aurait pas du réduire le deuxième  $T$  à  $E$  mais shifter le  $*$ .

## Le problème dans l'exemple 3

- ▶ Dans l'exemple 3 on a obtenu en haut de la pile :  $T * T$
- ▶ Or,  $T*$  se réduit seulement si on a après un  $F$ .
- ▶ Peu importe le mot  $w \in \Sigma^*$  qu'on trouve après, on ne peut pas avoir que  $Tw \rightarrow^* F$ .
- ▶ On n'aurait pas du réduire par la règle  $T \rightarrow F$  mais réduire par la règle  $T \rightarrow T * F$ .


## La grande question qui reste

- ▶ Comment savoir, étant donnée la pile, quelle action faire quand les derniers symboles sur les pile peuvent être réduits par une production :
  - ▶ choix entre shift et reduce ;
  - ▶ dans le cas de reduce, choix de la règle quand il y en a plusieurs.
- ▶ Ça semble compliqué : il faut savoir si on arrivera à la fin de combiner tous les morceaux d'arbre en un seul arbre de dérivation.
- ▶ La surprise est : il y a une solution très efficace à ce problème due à Donald Knuth.
- ▶ Et cette solution utilise les automates du L2.

## Quelle est la structure de la partie "à deviner" ?

- ▶ C'est un morceau d'arbre qui commence par l'axiome  $S$ .
- ▶ Tous les nœuds à deviner sont étiquetés par des non terminaux, et leurs enfants constituent le côté droit d'une règle pour ce non-terminal.
- ▶ On peut dans l'arbre soit descendre vers un fils, soit passer au frère suivant.
- ▶ Quand on passe au frère suivant on vérifie que c'est justifié par un symbole qu'on trouve sur la pile.

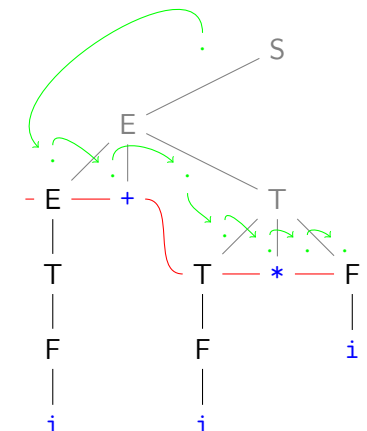
## Exemple : pile $E+T*F$



En gris la partie "à deviner".

## Exemple : pile $E+T*F$

$S \rightarrow E \$$   $E \rightarrow E + T \mid T$   $T \rightarrow T * F \mid F$   $F \rightarrow ( E ) \mid i$



## Un automate

- ▶ Il s'agit de l'exécution d'un automate !
- ▶ Les états sont les points verts - l'information dans un état est la production de la grammaire, et l'endroit où on est dans le côté droit de la règle.
- ▶ L'automate peut "deviner" quelque chose car il s'agit d'un automate non déterministe.
- ▶ L'automate peut descendre par une transition  $\epsilon$ , ou passer d'un enfant au suivant par une transition étiquetée par un symbole de la pile.
- ▶ On appelle cet automate l'*automate caractéristique* de la grammaire. Nous allons le définir précisément dans la suite.

## Exemple

- ▶ Soit la grammaire  $E \rightarrow (E+E) \mid i \quad S \rightarrow E \$$
- ▶ Les items sont :  
[E → .(E+E)], [E → (.E+E)], [E → (E.+E)],  
[E → (E+.E)], [E → (E+E.)], [E → (E+E).],  
[E → .i], [E → i.],  
[S → .E \$], [S → E.\$], [S → E \$.]
- ▶ Donc 11 états même pour une grammaire si simple.
- ▶ En général : Pour  $k$  règles de la grammaire avec longueurs des côtés droits  $n_1, \dots, n_k$ , le nombre d'items est

$$\sum_{i=1 \dots k} (n_i + 1)$$

- ▶ Dans le cas de la grammaire pour les expressions arithmétiques avec priorités : 21 items.

## Les items

### Définition

Soit  $G = (\Sigma, N, S, P)$  une grammaire. Un *item* de  $G$  est une expression de la forme

$$[N \rightarrow \alpha.\beta]$$

où  $N \rightarrow \alpha\beta \in P$ .

Un item de la forme  $[N \rightarrow \alpha.]$  est *complet*.

- ▶ C'est à dire, un item consiste en une règle de la grammaire, plus une position (indiqué par le symbole ".") dans le côté droit de la règle.
- ▶  $\alpha$  et  $\beta$  peuvent être  $\epsilon$ .
- ▶ Une règle  $N \rightarrow \epsilon$  donne lieu à un seul item :  $[N \rightarrow .]$

## L'automate caractéristique non-déterministe : états

- ▶ L'ensemble d'états : c'est l'ensemble des items.
- ▶ Les états initiaux sont

$$\{[S \rightarrow .\alpha] \mid S \rightarrow \alpha \in P\}$$

où  $S$  est l'axiome de la grammaire.

- ▶ Sur l'exemple : l'état initial est  $[S \rightarrow .E \$]$
- ▶ Les états acceptants sont les items complets :

$$\{[N \rightarrow \alpha.] \mid N \rightarrow \alpha \in P\}$$

- ▶ Sur l'exemple : les états acceptants sont :  
 $[E \rightarrow (E+E).], [E \rightarrow i.], [S \rightarrow E $.]$



## L'automate caractéristique non-déterministe : transitions

1. Alphabet :  $\Sigma \cup N$
2. Premier type de transitions :

$$[N \rightarrow \alpha.x\beta] \xrightarrow{x} [N \rightarrow \alpha x.\beta]$$


où  $N \rightarrow \alpha x\beta \in P, x \in \Sigma \cup N$ .

3. Deuxième type de transitions :

$$[N \rightarrow \alpha.M\beta] \xrightarrow{\epsilon} [M \rightarrow .\gamma]$$

où  $N \rightarrow \alpha M\beta, M \rightarrow \gamma \in P$

## L'automate caractéristique non-déterministe sur l'exemple



## Rappel : Déterminiser et éliminer les transitions $\epsilon$

- ▶ Soit  $A = (\Sigma, Q, \delta, I, F)$  un automate non-déterministe avec  $\epsilon$ -transitions.

- ▶ On définit d'abord pour  $P \subseteq Q$  :

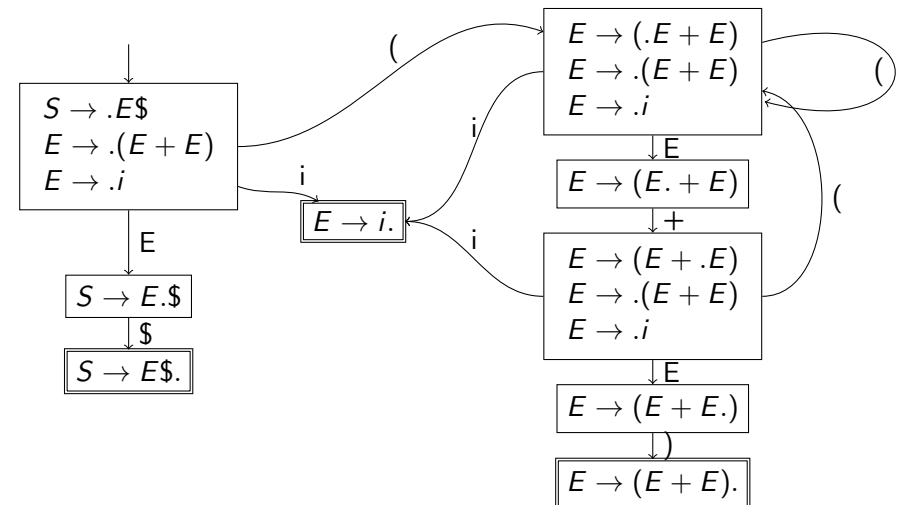
$$\epsilon\text{-cloture}(P) = \{q \in Q \mid \exists p \in P, q \in \delta^*(p, \epsilon)\}$$

- ▶ On construit  $A' = (\Sigma, 2^Q, \delta', I', F')$  avec

- ▶  $I' = \epsilon\text{-cloture}(I)$
- ▶  $\delta'(P, a) = \bigcup_{p \in P} \epsilon\text{-cloture}(\delta(p, a))$
- ▶  $F' = \{P \subseteq Q \mid P \cap F \neq \emptyset\}$

- ▶ Il convient de construire les états de  $A'$  au fur et à mesure.

## Déterminiser avec élimination des $\epsilon$ -transitions



## Comment se servir de l'automate caractéristique ?

- ▶ On applique l'automate au mot sur la pile (la pile est lue du bas vers le haut).
- ▶ L'état du dernier élément de la pile peut nous dire quoi faire :
  - ▶ Si l'état contient un item complet (c.-à-d. de la forme  $[N \rightarrow \alpha.]$ ) on peut appliquer une action **reduce** pour cette règle.
  - ▶ Si l'état contient un item non complet (c.-à-d. de la forme  $[N \rightarrow \alpha.a\beta]$  et  $a \in \Sigma$ ) on peut appliquer une action **shift**.
- ▶ C'est une solution efficace qui évite de chercher en haut de la pile : il suffit de regarder l'état au sommet de la pile.

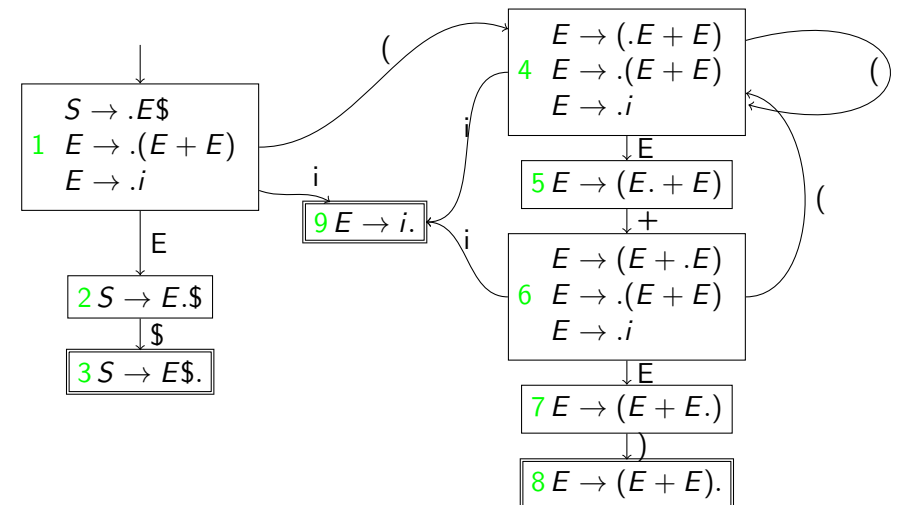
## Définitions LR(0)

- ▶ Dans l'automate caractéristique non-déterministe on a que chaque état contient exactement un item. Après détermination, un état peut contenir plusieurs items !
- ▶ Un état (ensemble d'items) a un **conflit shift-reduce** quand il contient à la fois un item complet et un item incomplet où le point est devant un symbole terminal (c.-à-d. de la forme  $[N \rightarrow \alpha.a\beta]$  avec  $a \in \Sigma$ ).
- ▶ Un état (ensemble d'items) a un **conflit reduce-reduce** quand il contient deux items complets différents.
- ▶ Une grammaire est dite **LR(0)** quand son automate caractéristique déterministe n'a pas de conflit (ni shift-reduce, ni reduce-reduce).

## Comment se servir de l'automate caractéristique (2) ?

- ▶ Une action **reduce** remplace en haut de la pile une séquence  $\alpha$  par un non-terminal  $N$ . Comment calculer son état ?
- ▶ On stocke sur la pile l'état avec **chaque** élément. Cela permet de calculer l'état de  $N$ , en faisant une transition de l'automate.

## Sur l'exemple (avec les états numérotés en vert)



C'est donc bien une grammaire LR(0) !