

Grammaires et Analyse Syntaxique - Cours 6

Introduction à l'analyse ascendante

Ralf Treinen



Université
Paris Cité



`treinen@irif.fr`

5 mars 2025

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 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 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.

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.


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 :



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 α 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 (sommet à droite) :

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

entrée :

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

Situation après un **shift** :

pile (sommet à droite) :

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

entrée :

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

Reduce

Situation de départ :

pile (sommet 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 (sommet à droite) :

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

entrée :

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

Exemple

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

$$S \rightarrow E \$$$

$$E \rightarrow E + T \mid T$$

$$T \rightarrow T * F \mid F$$

$$F \rightarrow (E) \mid i$$

- ▶ 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.

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)

<i>pile</i>	<i>entrée</i>	<i>action</i>	<i>pile</i>	<i>entrée</i>	<i>action</i>
	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, le parseur shift-reduce construit une dérivation droite dans un ordre inversé.
- ▶ Regardons cela maintenant avec construction de l'arbre de dérivation.

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!*



Efficacité

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

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 α 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 β est également en haut de la pile (c'est possible quand α est un suffixe de β 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 :

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

a_1	a_2
-------	-------

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

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

a_1	a_2
-------	-------

2. Soit **shift** :

x_1	x_2	y_1	y_2	y_3	a_1
-------	-------	-------	-------	-------	-------

a_2

Deux Reduce possibles

Pile :

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

1. Soit **reduce N** $\rightarrow y_1y_2y_3$:

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


2. Soit **reduce M** $\rightarrow y_2y_3$:

x_1	x_2	y_1	M
-------	-------	-------	-----

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 : $i+i*i\$$



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 : $i+i*i\$$ 

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 $*$.

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 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 .
- ▶ Peut 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.


Exemple : pile $E+T*F$ 

En gris la partie “à deviner”.

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 $E+T * F$

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


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 ϵ , 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.

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.
- ▶ α et β peuvent être ϵ .
- ▶ Une règle $N \rightarrow \epsilon$ donne lieu à un seul item : $[N \rightarrow .]$

Exemple

- ▶ Soit la grammaire $E \rightarrow (E+E) \mid i \quad S \rightarrow E \$$
- ▶ Les items sont :
 $[E \rightarrow \cdot(E+E)], [E \rightarrow (\cdot E+E)], [E \rightarrow (E \cdot +E)],$
 $[E \rightarrow (E+ \cdot E)], [E \rightarrow (E+E \cdot)], [E \rightarrow (E+E) \cdot],$
 $[E \rightarrow \cdot i], [E \rightarrow i \cdot],$
 $[S \rightarrow \cdot E \$], [S \rightarrow E \cdot \$], [S \rightarrow E \$ \cdot]$
- ▶ 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

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

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

L'automate caractéristique non-déterministe : états

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

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

où S est l'axiome de la grammaire.

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

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

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

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 :

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

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 ϵ

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


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

- ▶ Une action **reduce** remplace en haut de la pile une séquence α 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.

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 *conflict 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 *conflict 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).

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



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