LIF15 – Théorie des langages formels

*Sylvain Brandel*
2021 – 2022
sylvain.brandel@univ-lyon1.fr

CM 10

# ANALYSE SYNTAXIQUE

Source : Xavier Urbain

# Automates finis

- Transducteurs rationnels
  - Automates finis avec transitions étiquetées par une sorte

➔ génération de tokens

- Erreurs jusqu'ici LEXICALES

# Grammaires

- Type 0
  - Grammaires générales — Pas de restrictions
- Type 1
  - Grammaires contextuelles — $uAv \rightarrow uwv$
  - Grammaires croissantes — Si $w \rightarrow w' \in R$ alors $|w| \leq |w'|$
- Type 2
  - Grammaires hors contexte — Si $w \rightarrow w' \in R$ alors $w \in V$
- Type 3
  - Grammaires régulières

# Grammaires

- Grammaires croissantes

$S \rightarrow ABCS$
$S \rightarrow T_c$
$CA \rightarrow AC$
$BA \rightarrow AB$
$CB \rightarrow BC$
$CT_c \rightarrow T_cc$
$CT_c \rightarrow T_bc$
$BT_b \rightarrow T_bb$
$BT_b \rightarrow T_ab$
$AT_a \rightarrow T_aa$
$T_a \rightarrow \varepsilon$

$S \rightarrow aSTc$
$S \rightarrow aTc$
$cT \rightarrow Tc$
$T \rightarrow b$

$S \rightarrow aSBc$
$S \rightarrow abc$
$cB \rightarrow Bc$
$bB \rightarrow bb$

(contextuelle)

$S \rightarrow aSBC$
$S \rightarrow aBC$
$CB \rightarrow HB$
$HB \rightarrow HC$
$HC \rightarrow BC$
$aB \rightarrow ab$
$bB \rightarrow bb$
$bC \rightarrow bc$
$cC \rightarrow cc$

- Grammaire croissante ➔grammaire contextuelle

# Grammaires

$S \rightarrow ABCS$

$S \rightarrow T_c$

$CA \rightarrow AC$

$BA \rightarrow AB$

$CB \rightarrow BC$

$CT_c \rightarrow T_c c$

$CT_c \rightarrow T_b c$

$BT_b \rightarrow T_b b$

$BT_b \rightarrow T_a b$

$AT_a \rightarrow T_a a$

$T_a \rightarrow \varepsilon$

$S \Rightarrow ABCS$

$\Rightarrow ABCABCS$

$\Rightarrow ABCABCT_c$

$\Rightarrow ABACBCT_c$

$\Rightarrow ABABCCT_c$

$\Rightarrow AABBCCT_c$

$\Rightarrow AABBCT_c c$

$\Rightarrow AABBT_b cc$

$\Rightarrow AABT_b bcc$

$\Rightarrow AAT_a bbcc$

$\Rightarrow AT_a abbcc$

$\Rightarrow T_a aabbcc$

$\Rightarrow aabbcc$

# Dérivations

- Expressions arithmétiques sur {+, $\times$ , (, ), id, cte} tokens
- E $\rightarrow$ id | cte | E + E | E $\times$ E | (E)

x + 2.5 $\times$ 4 + (y + z)

E $\Rightarrow$ E + E
$\Rightarrow$ id + E
$\Rightarrow$ id + E $\times$ E
$\Rightarrow$ id + cte $\times$ E
$\Rightarrow$ id + cte $\times$ E + E
$\Rightarrow$ id + cte $\times$ cte + E
$\Rightarrow$ id + cte $\times$ cte + (E)
$\Rightarrow$ id + cte $\times$ cte + (E + E)
$\Rightarrow$ id + cte $\times$ cte + (id + E)
$\Rightarrow$ id + cte $\times$ cte + (id + id)

- Dérivation : gauche
- Parenthésage implicite : (x + (2.5 $\times$ (4 + (y + z))))

# Dérivations

- Expressions arithmétiques sur {+, $\times$ , (, ), id, cte}
- E $\rightarrow$ id | cte | E + E | E $\times$ E | (E)

x + 2.5 $\times$ 4 + (y + z)

E $\Rightarrow$ E + E
$\Rightarrow$ E + (E)
$\Rightarrow$ E + (E + E)
$\Rightarrow$ E + (E + id)
$\Rightarrow$ E + (id + id)
$\Rightarrow$ E $\times$ E + (id + id)
$\Rightarrow$ E $\times$ cte + (id + id)
$\Rightarrow$ E + E $\times$ cte + (id + id)
$\Rightarrow$ E + cte $\times$ cte + (id + id)
$\Rightarrow$ id + cte $\times$ cte + (id + id)

- Dérivation droite
- Parenthésage implicite : (((x + 2.5) $\times$ 4) + (y + z))

# Dérivations

- $(((x + 2.5) \times 4) + (y + z)) \neq (x + (2.5 \times (4 + (y + z))))$
- Dérivation droite avec $((x + (2.5 \times 4)) + (y + z))$ ?
- G ambiguë si $\exists$ w $\in$ L(G) tq plusieurs dérivations droite pour w.
- Lever l'ambiguïté
  - Pas toujours faisable
  - Cas faciles : 1) Nouveau non terminal par niveau de priorité
    2) Récursif gauche si associatif gauche (resp. droite)

# Dérivations

- Expressions arithmétiques sur {+, $\times$ , (, ), id, cte}
- E $\rightarrow$ id | cte | E + E | E $\times$ E | (E)
- + < $\times$ + moins prioritaire que $\times$
- + et $\times$ : associatifs à gauche x+y+z = (x+y)+z

E $\rightarrow$ E + T | T
T $\rightarrow$ T $\times$ F | F
F $\rightarrow$ id | cte | (E)

- Unique derivation gauche ou droite
- Un peu plus long et complexe mais univoque

# Arbre syntaxique

- Plusieurs dérivations pour un même résultat (permutations, etc.)
  - ➔ Représentation invariante
  - ➔ Représentation unique lorsque G non ambiguë

- Soit G = (V, $\Sigma$, R, S), arbres de syntaxe de G :
  - Nœuds internes étiquetés par V
  - Feuilles étiquetées par $\Sigma$
  - Si nœud interne N a k fils $a_1, \ldots, a_k$ alors $N \rightarrow a_1 \ldots a_k \in R$

- Arbre de dérivation : $\Lambda = S$ feuilles $\in \Sigma$

# Arbre syntaxique

- Exemple

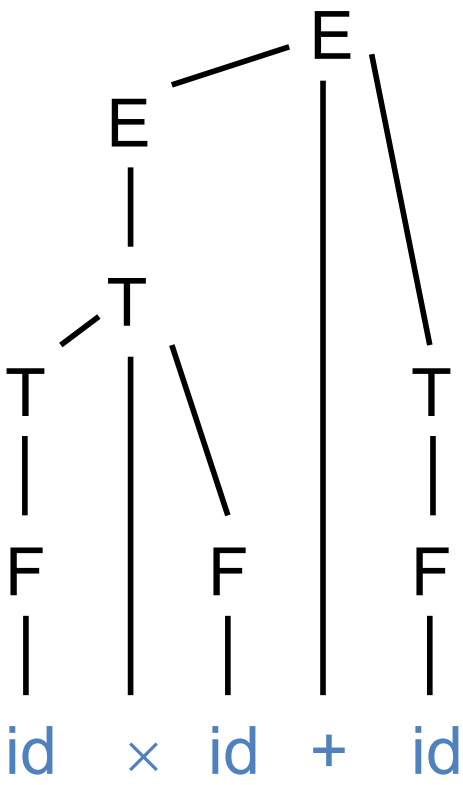


- Arbre de la dérivation E $\Rightarrow^*$ id × id + id

# Arbre syntaxique

- Un arbre de dérivation = plusieurs dérivations
  ➔ Stratégies de parcours (parent avant fils)

- Pour arbre de dérivation : mot des feuilles $\in$ L(G)

- Réciproque : produire un arbre, récurrence sur longueur de dérivation
  - Nulle : arbre = feuille a
  - $N \Rightarrow^n w_1 M w_2 \Rightarrow w_1 a_1 \dots a_k w_2$ :
    ajout de k fils au nœud M de l'arbre de $N \Rightarrow^n w_1 M w_2$

- G ambiguë si $\exists$ w $\in$ L(G) avec deux arbres de dérivation distincts

- Construction de l'arbre vers le haut ou vers le bas ?

# Analyse descendante

- Exemple : grammaire de Dick

  (1) $S \rightarrow (S)S$
  (2) $S \rightarrow \varepsilon$

- (((())())()) ∈ L(G) ?

- Construction de l'arbre :
  - Lecture à partir de la gauche — Left
  - Construction dérivation gauche — Left
  - Règle déterminée par 1 caractère à produire — 1

    ➔ LL(1)

# Analyse descendante

- Efficace
- Simple

- Pas toutes LL(1)
- Si récursif à gauche → échec

- Par exemple $E \rightarrow E + T \mid T$

  $T \rightarrow T \times F \mid F$

  $F \rightarrow id \mid cte \mid (E)$ pas faisable

# Analyse ascendante

$E \rightarrow E + T \mid T$

$T \rightarrow T \times F \mid F$

$F \rightarrow id \mid cte \mid (E)$

- Récursive gauche …
- $E \rightarrow T$ ou $E \rightarrow E + T$ ?

  ➔ Analyse ascendante
- Construction de l'arbre
  - Lecture à partir de gauche
  - Dérivation droite à l'envers

    ➔ LR
- En particulier construction d'une forêt

# Analyse ascendante

$E \rightarrow E + T \mid T$

$T \rightarrow T \times F \mid F$

$F \rightarrow id \mid cte \mid (E)$

- Racine de forêt : suite des racines des arbres la constituant
- Opérations :
  - 1. Lecture — Shift
  - 2. Enracinement — Reduce

Sur juxtaposition f f' construction de fN si $N \rightarrow \Lambda(f')$

$id \times id + id$ ?

# Syntaxe abstraite

- Type et signification : depuis l'arbre de syntaxe
- Utilisateur : ce qu'on écrit
- Concrète : presque comme on écrit  Impropre à bonne compréhension

➔ niveau intermédiaire : syntaxe abstraite dépolluée

- On veut :
  - Objectif 1 : sans ambiguïté
  - Objectif 2 : sans scories
  - Objectif 3 : structure et valeurs

# Syntaxe abstraite

- T ensemble d'étiquettes abstraites
- $\Sigma = T \cup \{(; ); ,\}$
- G = (V, $\Sigma$, R, S) abstraite si
  1. Règles : $N \rightarrow t$
     ou $N \rightarrow t(N_1, \ldots, N_k)$ pour $N_i \in V$, $t \in T$
  2. Occurrence t unique dans G

- Mot généré : expression abstraite

$T = \{p, m, cte\}$ $E \rightarrow p(E,E) \mid m(E,E) \mid cte$

$T = \{+, \times, cte\}$ $E \rightarrow +(E,E) \mid \times(E,E) \mid cte$

# Syntaxe abstraite

- G abstraite nécessairement non ambiguë  Objectif 1  OK
- Représentation arborescente :
  - facile grâce à la forme des règles

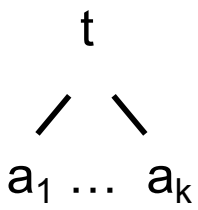


- Arbre de syntaxe abstraite A de sorte N : nœuds dans T et
  - $N \rightarrow t \in R$  et $A = t$

    ou
  - $N \rightarrow t(N_1, \ldots, N_k) \in R$  et $\Lambda(A) = t$
- A a alors k fils ASA de sortes respectives $N_1 \ldots N_k$

# Syntaxe abstraite

- Comparaison AS / ASA

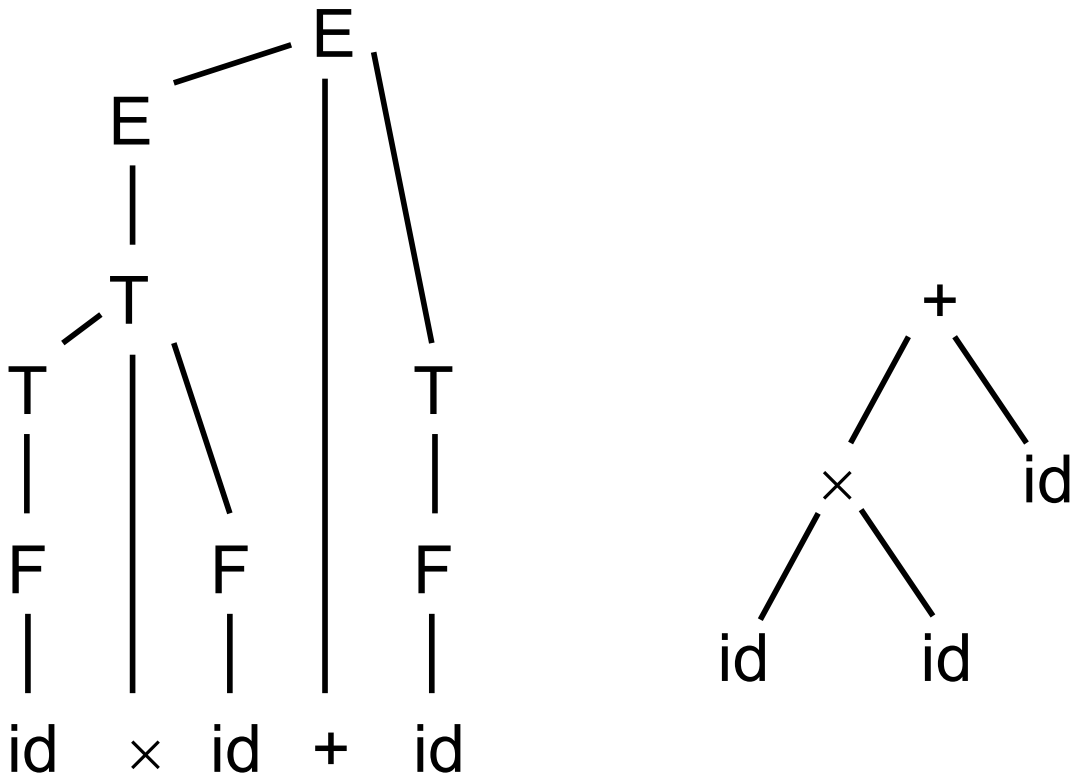





- Objectif 2 OK

# Syntaxe abstraite

- Pour valeurs : étiquette = langage rationnel

$$E \rightarrow +(E,E) \mid \times (E,E) \mid cte(Nat)$$
$$Nat \in (0|1| \cdot \cdot \cdot |9)+$$

- Objectif 3 OK

# Syntaxe abstraite

- Actions dans une grammaire

| | |
|---|---|
| $E \rightarrow E + T$ | $\{ +(E_1, T_1) \}$ |
| $E \rightarrow T$ | $\{ T_1 \}$ |
| $T \rightarrow T \times F$ | $\{ \times(T_1, F_1) \}$ |
| $T \rightarrow F$ | $\{ F_1 \}$ |
| $F \rightarrow Nat$ | $\{ cte(val(Nat_1)) \}$ |
| $F \rightarrow (E)$ | $\{ E_1 \}$ |

- Erreurs ici SYNTAXIQUES

# Grammaire du C