


\*Introduction: la compilation.

Motivations : interpréter un code / convertir du LaTeX en HTML / ...

I) Rappels de théorie des langages1) langages rationnels (RAT)

def 1: un automate est un quintuplet  $\text{ct} = (Q, \Sigma, \delta, I, F)$  où  $Q$  est l'ensemble fini des états,  $\Sigma$  est l'alphabet (ensemble fini),  $\delta \subseteq Q \times \Sigma \times Q$  est l'ensemble des transitions,  $I \subseteq Q$  les états initiaux,  $F \subseteq Q$  les états finaux.

def 2: un chemin dans  $\text{ct}$  est une suite finie de transitions  $q_0 \xrightarrow{x_1} q_1 \xrightarrow{x_2} \dots \xrightarrow{x_n} q_n$ , où  $q_0 \in I$ . On dit que le mot  $x_1 \dots x_n$  est l'étiquette du chemin et  $q_n$  l'état d'arrivée.

def 3: un mot  $x \in \Sigma^*$  est accepté par l'automate  $\text{ct}$  s'il est l'étiquette d'un chemin dans  $\text{ct}$  à l'état d'arrivée  $q_n \in F$ . On note  $L(\text{ct})$  le langage des mots acceptés par  $\text{ct}$ .

ex 4: (automate du motif). Soit  $x = x_1 \dots x_m \in \Sigma^*$ . On peut construire l'automate suivant en  $O(m)$ :

$\text{ct}_{\text{motif}} = \begin{array}{c} x_1 \\ \rightarrow \end{array} \circlearrowleft \begin{array}{c} x_2 \\ \rightarrow \end{array} \circlearrowleft \begin{array}{c} x_3 \\ \rightarrow \end{array} \circlearrowleft \dots \circlearrowleft \begin{array}{c} x_m \\ \rightarrow \end{array} \circlearrowright \end{pmatrix} \quad \text{De plus, } L(\text{ct}_{\text{motif}}) = \{x\}.$

ex 5: (automate des occurrences). Soit  $x \in \Sigma^*$ , P l'ensemble des préfixes de  $x$ . L'automate  $\text{ct}_x = (P, \Sigma, \delta, I, F)$ , où  $\delta = \{(u, a, f_{xu}), u \in P, a \in \Sigma\}$ , avec  $f_{xu}$  le plus petit suffixe de  $x$  préfixe de  $u$ , est l'automate minimal du langage  $\Sigma^* x$ .

Rq 6: l'automate du motif sera utilisé pour l'analyse lexicale ; l'automate des occurrences est utile pour la recherche de motif (langage impératif avec label/goto).

def 7: on considère des symboles faux  $\epsilon, *, |, +, (, ) \notin \Sigma$ . Le langage  $\mathcal{L}$  des expressions régulières est le plus petit langage contenant  $\Sigma \cup \{\epsilon\}$  tel que : si  $x \in \mathcal{L}, y \in \mathcal{L}$  alors  $x^*, (xy), x+, xy \in \mathcal{L}$ .

def 8: soit  $e \in \mathcal{L}$ . le langage rationnel  $L(e)$  est défini par induction :

- $\forall a \in \Sigma \cup \{\epsilon\}, L(a) = \{a\}$

- $\forall x \in \mathcal{L}, L(x) = \bigcup_{n \in \mathbb{N}} \{x^n, n \in \mathbb{N}\}$

- $\forall x \in \mathcal{L}, L(x^+) = \bigcup_{n \in \mathbb{N}^*} \{x^n, n \in \mathbb{N}\}$

- $\forall x, y \in \mathcal{L}, L(x|y) = L(x) \cup L(y)$

- $\forall x, y \in \mathcal{L}, L(xy) = \{w_1 w_2, w_1 \in L(x), w_2 \in L(y)\}$

Rq 9: on omet les parenthèses en cas de non-ambiguité.

thm 10: (Kleene) Soit  $\mathcal{L} \subseteq \Sigma^*$  un langage. On a l'équivalence :

(i) Il existe un automate  $\text{ct} \vdash q \quad \mathcal{L} = L(\text{ct})$  [ $\mathcal{L}$  est reconnaissable par automate].

(ii) Il existe  $e \in \mathcal{L}$   $\vdash q \quad \mathcal{L} = L(e)$  [ $\mathcal{L}$  est rationnel].

Rq 11: on dispose d'un algorithme pour poser d'une expression régulière à un automate.

2) Langages algébriques (ALG).

def 12: une grammaire algébrique sur un alphabet  $\Sigma$  est un quadruplet  $G = (\mathcal{N}, T, S, R)$  où  $\mathcal{N}$  est l'ensemble fini des non-terminaux,  $T \subseteq \Sigma$  est l'ensemble des terminaux,  $S \in \mathcal{N}$  est l'axiome et  $R \subseteq \mathcal{N} \times (\mathcal{N} \cup T)^*$  l'ensemble des règles.

def 13: Soient  $u, v \in (\mathcal{N} \cup T)^*$ . On dit que  $u$  se dérive en  $v$  ( $u \Rightarrow v$ ) s'il existe  $\alpha, \beta \in (\mathcal{N} \cup T)^*$  et  $X \in \mathcal{N}$  tq  $\begin{cases} u = \alpha X \beta \\ v = \alpha w \beta \end{cases}$  et  $(X \Rightarrow w) \in R$ .

def 14: un mot  $w \in \Sigma^*$  est engendré par une grammaire  $G = (\mathcal{N}, T, S, R)$  si  $S \xrightarrow{G} w$ , où  $\xrightarrow{G}$  est la clôture réflexive transitive de  $\Rightarrow$ .

On note  $L(G)$  le langage des mots engendrés par la grammaire  $G$ .

ex 15: le langage  $L(a^*)$  est engendré par la grammaire  $\{S \xrightarrow{} aS\}$

ex 16: (Langage de Dyck sur  $n$  paires de parenthèses).

La grammaire  $G_{\text{Dyck}}$  :  $\begin{cases} S \xrightarrow{} a_1 S a_1 \\ S \xrightarrow{} a_2 S a_2 \\ \vdots \\ S \xrightarrow{} a_n S a_n \\ S \xrightarrow{} E \end{cases}$  engendre le langage des mots bien parenthésés avec au plus  $n$  types de parenthèses.

ex 17: (expressions arithmétiques préfixes)  $G_{\text{pref}} : \begin{cases} S \xrightarrow{} +SS \\ S \xrightarrow{} c \end{cases}$

ex 18: (expressions arithmétiques postfixes)  $G_{\text{post}} : \begin{cases} S \xrightarrow{} SS+ \\ S \xrightarrow{} c \end{cases}$

thm 19: ( $\text{RAT} \subseteq \text{ALG}$ ).

Tout langage rationnel est algébrique (ie: engendré par une grammaire algébrique)

def 20: un arbre de dérivation est un arbre fini étiqueté par  $\mathcal{N} \cup T \cup \{\epsilon\} \vdash q$ :


- l'arbre est enraciné en  $S$ .
  - Si  $T$  est l'étiquette d'un noeud interne et  $a_1 \dots a_n$  ses fils, alors  $(T \xrightarrow{} a_1 \dots a_n) \in R$ .
- On appellera frontière d'un arbre le mot obtenu par concaténation des feuilles de gude.

def 21: une grammaire est ambiguë s'il existe un mot à deux arbres différents.

def 22: un langage algébrique est non-ambigu s'il est engendré par une grammaire non-ambiguë. Dans le cas contraire, il est dit "intrinsèquement ambigu".

ex 23: les grammaires  $G_{\text{Dyck}}$ ,  $G_{\text{pref}}$ ,  $G_{\text{post}}$  sont non-ambiguës.

La grammaire  $\begin{cases} S \xrightarrow{} S+S \\ S \xrightarrow{} S \times S \\ S \xrightarrow{} c \end{cases}$  est ambiguë :

II) Analyse lexicale

But: transformer un texte en une liste de lexèmes (terminaux d'une grammaire).

Intérêts : → filtration des commentaires  
 → mise en page ("1+2" et "1 + 2" représentent le même programme)  
 → repérage des types.  
 → décoration des lexèmes (nom du fichier, n° de ligne, nbre de caractères,...)  
 → repérage des erreurs lexicales (motif interdit).

Def 24 : (règle d'analyse lexicale). Soit  $T$  l'ensemble fini des types de lexèmes.

Une règle d'analyse lexicale sur l'alphabet  $\Sigma$  est la donnée :

- d'une expression régulière  $e$  sur  $\Sigma$  tq  $e \not\in L(e)$ .
- d'un type de lexème  $t$  et  $T$ .

Cette règle est notée  $e \rightarrow t$ .

Algo 25 : Entrée : texte  $\in \Sigma^*$ ; liste de règles  $(e_j \rightarrow t_j); j \in 1 \dots n$   
 Sortie : liste de lexèmes correspondant au texte.

Analyse - lexicale (texte) :

```

  Si texte = "" retourner []
  Si non :
    (lexème, suite) ← Analyse - aux (texte)
    retourner lexème :: Analyse - lexicale (suite)
  
```

Analyse - aux (texte) :

```

  fin ← 0   // position de fin du plus long préfixe connu
  iAut ← -oo // indice de l'automate du plus long préfixe
  iTexte ← 1
  Tant que (Il existe un ctes motif non-blocké) et (iTexte <= longueur(texte)) :
    pour j ← 1 à n :
      faire lire texte[iTexte] à l'automate ctes
      Si ctes motif est dans un état final :
        si fin < iTexte :
          fin ← iTexte
          iAut ← j
        incrementer iTexte
  Si iAut = 0 : erreur ("le texte ne contient aucun préfixe connu")
  préfixe ← texte[1 ... fin]
  lexème ← (préfixe, tiAut)
  retourner (lexème, texte - préfixe)
  
```

→ Complexité temporelle :  $O(\text{longueur}(\text{texte}))$

ex 26 : pour analyser le texte  $a^n$  avec les règles /  $a \rightarrow \text{lettre} - a$   
 il faut  $\frac{n(n+1)}{2}$  lectures.

Rq 27 : A la fin de l'analyse lexicale, on dispose d'une table des symboles dans laquelle on a stocké les informations souhaitées (type, lignes...).

### III) Analyse syntaxique

But : déterminer si un mot est reconnu par une grammaire, et construire une dérivation ou l'arbre syntaxique.

#### 1) Algorithmes génériques.

thm 28 : Soit  $G = (Df, T, S, R)$  une grammaire algébrique sur l'alphabet  $\Sigma$  et  $m \in \Sigma^*$ . Notons  $a$  le nombre maximal de symboles d'une partie droite d'une règle dans  $R$ . Alors :

$m \in L(G) \iff$  il existe une dérivation reconnaissant  $m$  dans  $G$ , de longueur inférieure à  $a^{|\text{mt}| \times |Df|}$

→ Il suffit de parcourir les dérivations de longueur  $\leq a^{|\text{mt}| \times |Df|}$

Def 29 : une grammaire est en forme normale de Chomsky si ses règles sont de la forme " $N \rightarrow NL$ " ou " $N \rightarrow a$ ",  $N, M, L \in Df$ ,  $a \in T$ .

prop 30 : Pour toute grammaire  $G$ , il existe une grammaire  $G'$  en forme normale de Chomsky tq  $L(G') = L(G) \setminus \{E\}$  (détaille  $|G'| = G(|G|^2)$ )

algo 31 : (CYK) Entrée : une grammaire  $G$  en forme normale de Chomsky, un mot  $w \in \Sigma^*$ .

Sortie : oui si  $w \in L(G)$ , non sinon

Algorithme, correction, terminaison, complexité  $\Sigma$ .

DEV1

#### 2) Algorithmes linéaires.

##### a) Analyse descendante.

Principe 32 : on part de l'axome et on le dérive pour arriver au texte.

ex 33 : un algorithme simple permet d'analyser la grammaire  $G_{\text{pref}}$  [cf Annexe 1] (la lecture du caractère courant permet de choisir la règle à appliquer).

⚠ ce n'est pas le cas pour toutes les grammaires :  $G_2 \left\{ \begin{array}{l} S \rightarrow TSS \\ T \rightarrow + \\ S \rightarrow C \end{array} \right.$   $G_{\text{pref}} \left\{ \begin{array}{l} S \rightarrow U + SS \\ U \rightarrow E \\ S \rightarrow C \end{array} \right.$

def 34 : (premier( $\vec{\alpha}$ ))

Soit  $G = (\mathcal{N}, T, S, R)$  une grammaire. Pour  $\vec{\alpha} \in (\mathcal{N} \cup T)^*$ , on définit :

$$\text{premier}(\vec{\alpha}) = \begin{cases} \{\alpha \in T \mid q \xrightarrow{\vec{\alpha}} a\beta, \beta \in (T \cup \mathcal{N})^*\} & \text{si } \vec{\alpha} \neq \epsilon \\ \{\alpha \in T \mid q \xrightarrow{\vec{\alpha}} a\beta, \beta \in (T \cup \mathcal{N})^*, U \not\models \alpha\} & \text{si } \vec{\alpha} \rightarrow^* \epsilon \end{cases}$$

où  $\Delta \notin \Sigma$  est un symbole frais.

def 35 : (suivant(N))

Soit  $G = (\mathcal{N}, T, S, R)$  une grammaire. Pour  $N \in \mathcal{N}$ , on définit :

$$\text{suivant}(N) = \begin{cases} \{\alpha \in T \mid S \xrightarrow{\vec{\alpha}} N a \vec{\beta}, \vec{\alpha}, \vec{\beta} \in (T \cup \mathcal{N})^*\} & \text{si } S \not\models \vec{\alpha} N \\ \{\alpha \in T \mid S \xrightarrow{\vec{\alpha}} N a \vec{\beta}, \vec{\alpha}, \vec{\beta} \in (T \cup \mathcal{N})^*, U \not\models \alpha\} & \text{si } S \rightarrow^* \vec{\alpha} N \end{cases}$$

où  $\Delta \notin \Sigma \cup \{\Delta\}$  est un symbole frais.

thm 36 : (calcul de premier)

La fonction premier est la plus petite partie de  $(T \cup \mathcal{N})^* \times (T \cup \{\Delta\})^*$

$$(i) \forall \alpha \in T, \text{premier}(\alpha) = \{\alpha\}$$

$$(ii) \text{premier}(\epsilon) = \{\Delta\}$$

$$(iii) \forall (N \rightarrow \epsilon) \in S, \text{premier}(\epsilon) \subseteq \text{premier}(N)$$

$$(iv) \forall (N \rightarrow \alpha_1 \dots \alpha_n) \in S, \text{premier}(\alpha_1 \dots \alpha_n) \subseteq \text{premier}(N)$$

$$(v) \text{Si } \Delta \notin \text{premier}(\alpha_i), \text{premier}(\alpha_i) \subseteq \text{premier}(\alpha_1 \dots \alpha_n)$$

$$(vi) \text{Si } \Delta \in \text{premier}(\alpha_i), \text{premier}(\alpha_i) \setminus \{\Delta\} \cup \text{premier}(\alpha_2 \dots \alpha_n) \subseteq \text{premier}(\alpha_1 \dots \alpha_n)$$

DEV2

def 37 : une grammaire G est dite LL(1) si pour tout  $N \in \mathcal{N}$ , en notant  $N \xrightarrow{\vec{\alpha}_1}, \dots, N \xrightarrow{\vec{\alpha}_n}$  les règles dont la partie gauche est N, on a :

(i) les ensembles  $\text{premier}(\vec{\alpha}_1), \dots, \text{premier}(\vec{\alpha}_n)$  sont deux à deux disjoints.

(ii) Si  $N \not\models \epsilon$ , alors  $\text{suivant}(N)$  est disjoint de chaque  $\text{premier}(\vec{\alpha}_i)$ .

ex 38 :   $G_{\text{pref}}^2, G_{\text{pref}}^3, G_{\text{dyck}} \in \text{LL}(1)$ .  $G_{\text{post}} \notin \text{LL}(1)$

def 39 :  Un langage est  $\text{LL}(1)$  s'il existe une grammaire  $\text{LL}(1)$  qui le reconnaît.

ex 40 :   $L(G_{\text{post}}) \in \text{LL}(1)$  [cf Annexe 2]

thm 41 :   $\text{RAT} \subseteq \text{LL}(1) \subseteq \{\text{langages non-ambigus}\}$

Analyse - LL(1) (texte) : arbre

$A, \text{texte}' = \text{Analyse - LL(1) - aux} (S, \text{texte})$

Si  $\text{texte}' \neq \epsilon$  : erreur "le mot n'est pas reconnu"  
retourner ( $A$ )

Analyse - LL(1) - aux ( $\alpha, \text{texte}$ ) : arbre x texte

si  $\alpha \in T$  :  
    si  $\text{texte}[1] = \alpha$  : retourner ( $\boxed{\text{texte}[1]}$ ,  $\text{texte}[2 \dots]$ )

sinon : erreur ("le mot n'est pas reconnu")

# les règles sont de la forme  $\alpha \rightarrow \vec{\beta}_1, \dots, \alpha \rightarrow \vec{\beta}_n$

Si  $\text{texte} = \epsilon$  :

    si  $\Delta \in \text{premier}(\alpha)$  et  $\Delta \in \text{suivant}(\alpha)$  :

*i*  $\leftarrow$  l'indice tq  $\Delta \in \text{premier}(\vec{\beta}_i)$

        sinon : erreur ("le mot n'est pas reconnu")

    Sinon :

        si  $\alpha \in \text{premier}(\alpha)$  et ( $\text{texte}[1] \in \text{suivant}(\alpha)$ ) :


*i*  $\leftarrow$  l'indice tq  $\alpha \in \text{premier}(\vec{\beta}_i)$

            sinon *i*  $\leftarrow$  l'indice tq  $\text{texte}[1] \in \text{premier}(\vec{\beta}_i)$

        si  $\vec{\beta}_i = \epsilon$  : retourner ( $\boxed{\alpha}, \text{texte}$ )

    Sinon :  $A_1, \text{texte}_1 \leftarrow \text{Analyse - LL(1) - aux} (\vec{\beta}_1[1], \text{texte})$

$A_2, \text{texte}_2 \leftarrow \text{Analyse - LL(1) - aux} (\vec{\beta}_1[2], \text{texte}_1)$

⋮  
Retourner ( $\alpha$  ,  $\text{texte}_n$ )

b/ Analyse ascendante

Principe : on part du texte et on remonte les règles pour obtenir l'entame.

def 43 : une situation  $L(R)$  d'une grammaire  $G$ , notée  $N \xrightarrow{\alpha_1 \dots \alpha_n} \gamma$  est :

- une règle  $(N \rightarrow \alpha_1 \dots \alpha_n) \in R$  avec  $N \in \mathcal{N}$ ,  $\alpha_1 \dots \alpha_n \in \mathcal{N} \cup T$

→ on note  $S_G$  l'ensemble des situations.

def 44 : la fermeture de  $E \subseteq S_G$  est la plus petite partie  $C_G(E)$  de  $S_G$  tq :

- $E \subseteq C_G(E)$

- $(N \rightarrow \alpha_1 \beta) \in C_G(E)$  et  $(L \rightarrow \gamma) \in E \Rightarrow (L \rightarrow \gamma) \in C_G(E)$ .

def 45 : l'automate  $L(R)$  d'une grammaire  $G$  est défini par :

- $Q = \{C_G(E), E \subseteq S_G\}$

- $I = \{C_G(S \xrightarrow{\vec{\alpha}} \vec{\beta}) \mid S \xrightarrow{\vec{\alpha}} \vec{\beta} \in E\}$

- $S : (E, \alpha) \mapsto C_G(N \xrightarrow{\vec{\alpha}} \vec{\beta}) \mid N \xrightarrow{\vec{\alpha}} \vec{\beta} \in E\}$

ex 46 :  Automate  $L(R)$  de la grammaire  $G_{\text{post}}$  [cf Annexe 3]

def 47 :  une grammaire  $G$  est dite  $L(R)$  si tout état de son automate qui contient une situation de la forme  $N \xrightarrow{\alpha_1 \dots \alpha_n}$  ne contient que celle-ci

prop 48 :  schéma des inclusions  $\text{RAT} \subseteq \text{LL}(1) \subseteq \text{LR}(0) \subseteq \text{ALG}$  [cf Annexe 4]


### Annexe 1 : Analyse G<sub>pref</sub>

mot lu	arbre en cours de construction
*****	---
+ <sub>p</sub> ****	(+)
++ <sub>p</sub> **	(+) ---
++1 <sub>p</sub> **	(+) (1) ---
++12 <sub>p</sub> *	(+) (1) (2)
++123 <sub>p</sub>	(+) (1) (2) (3)

### Annexe 2 : une grammaire LL(1) reconnaissant L(G<sub>post</sub>)

$$G_{\text{post}}^{\text{LL}(1)} : \begin{cases} S \rightarrow cT \\ T \rightarrow S + T \\ T \rightarrow \epsilon \end{cases}$$

### Annexe 3 : Automate LR(0) de G<sub>post</sub>



### Annexe 4 : schéma des inclusions

