

# Feuilles de TD Langages Formels 2016-2017

## 1 Expression rationnelle

### 1.1 Expression rationnelle d'un langage

$$L_1 = \{w \mid w \text{ commence par } ab\}$$

$$L_2 = \{w \mid w \text{ termine par } bb\}$$

$L_3 = \{w \mid w \text{ commence par } ab \text{ et termine par } bb\}$

$L_4 = \{w \mid w \text{ contient trois occurrences successives de la lettre } a\}$

$$L_5 = \{w \mid w \text{ ne commence pas par } ba\}$$

$$L_6 = \{w \mid w \text{ ne termine pas par } bba\}$$

### 1.2 Expression rationnelle utilisée en pratique

1. L'outil fgrep sous unix permet de filtrer les lignes d'un fichier qui contiennent une sous chaîne matchant une expression rationnelle. On utilise le caractère `|` pour écrire la somme `+` et le produit `.` est implicite. Ecrire une commande fgrep qui filtre les lignes contenant le mot malloc ou free d'un fichier toto.c
2. Lorsque un script saisit une adresse email sur une page web, il peut commencer par repérer une éventuelle faute de frappe en vérifiant le plus possible que l'utilisateur a bien rentré quelque chose qui ressemble à une adresse email; si cela n'est pas le cas, il peut redemander l'adresse. Pour cela, le script peut utiliser l'automate associé à l'expression rationnelle décrivant les adresses email. On suppose que les identifiants contiennent seulement des lettres, et éventuellement un '.' pour séparer le prénom du nom. Ecrire cette expression. on utilisera les notation simplifiée standard  $e^+ = e.e^*$
3. La première étape d'un compilateur et l'analyse lexicale, qui découpe le texte d'un programme en unité lexicale appelée token. Un token peut être un mot clef, un identifiant, une constante numérique. On utilise des expressions rationnelles pour identifier la nature des différents tokens.

Ecrire l'expression rationnelle décrivant un identificateur comme une lettre suivie d'une suite de lettre ou de chiffre, un entier, un flottant. On utilisera LA simplification de notation  $e^? = e|\epsilon$  qui signifie que  $e$  est optionnel.

4. Comment peut faire l'analyseur lexical pour repérer les différents mots clefs de façon simple?

### 1.3 Expression rationnelle d'un langage, plus compliqué

$L_7 = \{w \mid w \text{ ne contient pas deux occurrences successives de la lettre } a\}$

$L_8 = \{w \mid w \text{ ne contient pas trois occurrences successives de la lettre } a\}$

$L_9 = \{w \mid \text{le nombre de } a \text{ dans } w \text{ est pair}\} = \{w \mid |w|_a = 0 \pmod{2}\}$

$L_{10} = \{w \mid |w|_a = 1 \pmod{3}\}$

## 2 Démonstration d'égalité entre deux langages

Les égalités suivantes sont-elles vraies? si oui, le démontrer sinon donner un contre-exemple.

1.  $L^* = L^*.L^* = (L^*)^*$
2.  $L.(M \cap N) = (L.M) \cap (L.N)$
3.  $(L^*.M)^* = \Lambda + (L + M)^*.M$

## 3 Automates reconnaissant un langage donné.


Donner des automates reconnaissant les langages suivants : (pour les entiers comme pour les mots habituels, on considère que les caractères sont lus de gauche à droite, donc en commençant par les bits de poids forts)

- des entiers pairs, des entiers impairs, des puissances de 2,
- $A = \{0, 1\}$ ,  $L = \{w \mid w \text{ code une puissance de } 4\}$
- $A = \{0, 1\}$ ,  $L = \{w \mid w \text{ code la somme de deux puissances de } 4\}$
- $A = \{a, b\}$ ,  $L = \{w \mid w \text{ commence par } abaaba\}$
- $A = \{a, b\}$ ,  $L = \{w \mid w \text{ contient } aabaaab\}$
- $A = \{a, b\}$ ,  $L = \{w \mid w \text{ commence par } abb \text{ et termine par } bba\}$

- Les écritures de flottants
- $A = \{/, *, c\}$ ,  $L$  est l'ensemble des commentaires, un commentaire étant un mot de la forme  $/ * w * /$ , et dans laquelle  $w$  ne contient pas d'occurrence de  $*/$ , ni de  $/*$ , ( $c$  représente l'ensemble des caractères autres que  $*$  et  $/$ ).
- $A = \{a, b, c\}$ ,  $L = \{w \mid w \text{ contient au moins une fois chacune des trois lettres}\}$
- $A = \{a, b\}$ ,  $L = \{w \mid w \text{ contient un nombre pair de fois le facteur } bab\}$
- A faire chez vous (possible).  $A = \{a, b\}$ ,  $L = \{w \mid |w|_a \text{ est pair, ainsi que } |w|_b\}$
- A faire chez vous .  $A = \{0, 1\}$ ,  $L = \{w \mid \text{en base 2, } w \text{ représente un nombre valant 1 modulo 3}\}$

## 4 Déterminisation

(Partiel 2000-01). Déterminisez :



### 4.1 Boum !

Soit  $L_n$  l'ensemble des mots sur  $\{a, b\}$  de longueur au moins  $n$  dont la  $n^{\text{ième}}$  lettre avant la fin est un  $b$ . Donnez un petit automate non-déterministe pour  $L_3$ . puis son déterminisé. Comparez leur nombre d'états.

### 4.2 Le barman, boxeur aveugle

Un barman et un client jouent au jeu suivant : Le barman met un bandeau sur les yeux qui le rend aveugle, et il met des gants de boxe qui l'empêchent de "sentir" si un verre est à l'endroit ou à l'envers. Devant le barman, se trouve un plateau tournant sur lequel sont placés quatre verres en carré. Ces verres peuvent être à l'envers ou à l'endroit. Le sens des verres est choisi par le client et est inconnu du barman. Si les verres sont tous dans le même sens, alors le barman gagne (Quand le barman gagne, un autre client, "arbitre", annonce qu'il a gagné et le jeu s'arrête.) Le barman peut répéter 10 fois l'opération suivante : Il annonce au client qu'il va retourner certains verres (par exemple le verre en bas à gauche et celui en bas

à droite). Le client fait alors tourner le plateau, puis le barman retourne les verres comme il l'a annoncé. Si les verres sont alors tous dans le même sens, le barman gagne.

1) On se place du point de vue du client. Donnez un automate dont les états sont les différentes configurations du plateau, les lettres les coups annoncés par le barman et où les flèches décrivent les évolutions possibles des configurations.

2) Donnez un automate non déterministe (avec éventuellement plusieurs états entrée) qui donne toutes les séquences d'annonces du barman pour lesquelles le client peut gagner (à condition de toujours faire les bons choix).

3) Donnez un automate qui donne les coups qui assurent au barman de gagner quel que soit le comportement du client.

4) Jouez-vous de l'argent contre le barman ?


Cible : On commence par bien maîtriser l'algorithme de minimisation sur deux exemples, puis l'exercice sur le calcul des résidus, (futur) permet d'avoir plus de recul par rapports au fondement théorique de la minimisation. Enfin l'exercice sur les congruences permet de se familiariser avec les relations d'équivalences.


## 5 Resolution d'équations

Rappel de cours : a tout automate on peut associer un système d'équations dont les variables représentent les langages reconnus par cet automate à partir de chacun de ses états.


### 5.1 Exemple introductif

À l'aide du système d'équations précédent, que l'on résoudra par élimination et utilisation du lemme d'Arden, déterminer une expression rationnelle correspondant aux automates suivants : ( sur l'alphabet  $\mathcal{A} = \{a, b\}$  )






## 5.2 Exemple optionnel.



## 6 Minimisation

### 6.1 Construction de l'automate minimal.

Minimisez l'automates suivant (Partiel 99-00) :



### 6.2 Egalité entre automates.

Montrer que les deux automates suivants reconnaissent le même langage.

|          |   |   |   |   |
|----------|---|---|---|---|
| $\delta$ | 0 | 1 | 2 | 3 |
| a        | 1 | 2 | 1 | 3 |
| b        | 3 | 1 | 3 | 3 |

Etat initial : 0, état

terminal : 1

|          |   |   |   |   |   |   |
|----------|---|---|---|---|---|---|
| $\delta$ | 0 | 1 | 2 | 3 | 4 | 5 |
| a        | 1 | 2 | 3 | 2 | 2 | 5 |
| b        | 5 | 4 | 5 | 3 | 4 | 5 |

Etat initial : 0,

états terminaux : 1,3,4

## 6.3 Congruences

Rappel de cours : Si  $L$  étant un langage sur l'alphabet  $A$ , la relation de demi congruence syntaxique sur  $A^*$ , notée  $\sim_L$ , est définie par la relation suivante :  $x \sim_L y$  ssi  $\forall z \in A^*$ ,  $(xz \in L \Leftrightarrow yz \in L)$  C'est une relation d'équivalence. Deux mots sont en relation pour la demi congruence., si ils ont le même avenir avec  $\text{avenir}_L(u)$  qui est  $\{v | uv \in L\}$ . Si un automate  $A$  reconnaît  $L$ , à un état  $q$ , on associe un langage  $\text{Avenir}_L(q)$  qui est les mots qui mènent de cet état à un final. Ce langage est précisément celui qui se calcule en résolvant les équations associées à chaque nœud avec le Lemme d'arden. L'avenir d'un état est égal à l'avenir d'un mot qui y mène. Deux états peuvent être mergés, si ils ont le même avenir. Dans l'automate minimal, il y a donc un seul état par classe d'équivalence, la classe d'un état  $p$ , c'est l'ensemble des mots qui vont de  $q_0$  à  $p$ , et l'avenir de  $p$ , c'est les mots qui vont de  $p$  à un final.

Theoreme :  $L$  reconnaissable ssi si  $L$  a un nombre fini de classes, le nombre de classe étant en fait le nombre d'état dans le déterministe minimal

Si  $L$  reconnaissable, alors les classes sont en nombre fini, puisque il y a une classe par état. Si il y a un nombre fini de classe, alors on fait l'automate comme suit : un état par classe, ou, ce qui revient au même et rend la chose plus compréhensible, un état par avenir distinct. On met une flèche de  $p$  vers  $q$  avec la lettre  $a$  si  $\text{Classe}(p).a$  est inclus dans classe de  $q$ , ou (équivalent) si  $a^{-1}\text{Avenir}(p) = \text{Avenir}(q)$  L'état initial = celui de la classe contenant epsilon, ou dont l'avenir est celui de epsilon. Un état est final si il a epsilon dans son avenir.

### 6.3.1 Calcul de classe d'équivalence

Soit  $A = \{a, b\}$ . Pour chacun des langages ci-dessous, Déterminer les classes d'équivalences pour la relation de congruence syntaxique. Dire s'il est reconnaissable, et si oui, donner l'automate minimal le reconnaissant.

On procédera en choisissant d'abord des petits mots  $u$ , en calculant l'avenir de  $u$ , puis la classe de  $u$  qui est l'ensemble des mots qui ont le même avenir ; On choisit  $u$  seulement parmi les mots qui sont des préfixes d'un mot du langage, les autres mots ont tous le même avenir.

nir : l'ensemble vide, et sont donc dans la même classe qui correspond à un état poubelle dans l'automate minimal.

1.  $A^*$
2.  $\{a\}$
3.  $a^*b^*$
4.  $abba + ababa$
5.  $\{a^n b^n, n \geq 0\}$
6.  $\{uu \mid u \in A^*\}$
7. Les mots de longueur au moins égale à 4 et dont la 4ème lettre est un  $b$

## 6.4 Raisonnement sur des relations d'équivalence (difficile).

Soit  $L$  un langage, et  $\sim_L$  sa demi-congruence syntaxique.

On note  $\bowtie_L$  la relation sur  $A^*$  définie par  $u \bowtie v \iff (\forall x, y \in A^*, xuy \in L \iff xvy \in L)$

Montrez que :

- $\bowtie$  est une relation d'équivalence.
- Si  $u \bowtie v$  alors  $u \sim v$
- Si  $u \bowtie v$  et  $\bar{u} \bowtie \bar{v}$  alors  $u\bar{u} \bowtie v\bar{v}$
- $L$  est reconnaissable ssi le nombre de classes d'équivalences pour  $\bowtie$  est fini.
- S'il y a  $N$  classes d'équivalence pour  $\sim$ , combien au maximum y-en-t-il pour  $\bowtie$  ?

## 7 Transformation, construction d'automates.

$L$  est reconnu par l'automate  $A$ . Construire des automates reconnaissant :

- $miroir(L)$  =  $\{a_n a_{n-1} \dots a_3 a_2 a_1 \mid a_1 a_2 \dots a_n \in L\}$
- l'ensemble des mots obtenus à partir des mots de  $L$  en effaçant tous les  $a$ .
- l'ensemble des mots obtenus en effaçant un nombre pair de lettres d'un mot de  $L$
- le complémentaire de  $L$ , en supposant  $A$  déterministe.
- $L_1$  et  $L_2$  sont reconnus par les automates  $A_1$  et  $A_2$ .
- Construire un automate reconnaissant l'union  $L_1 + L_2$ .
- Si  $A_1$  et  $A_2$  n'ont pas d'épsilon transitions, peut-on construire facilement un automate sans epsilon-transitions pour l'union ?

On suppose que  $A_1$  et  $A_2$  sont déterministes complets.

- Donner un algorithme linéaire en  $|u|$  pour savoir si  $u \in L_1 \cap L_2$ .
- En déduire la construction d'un automate déterministe reconnaissant l'intersection.
- Construire également un automate déterministe reconnaissant l'union
- Les constructions précédentes s'adaptent-elles aux automates non complet ? non-déterministes ?

## 8 Clôture langages réguliers.

### 8.1 Cloture simple, sans morphisme

En utilisant les propriétés de clôture des langages rationnels et le fait que  $\{a^n b^n\}$  n'est pas rationnel, montrer que les langages suivants ne sont pas rationnels :

- $\{w \in (a+b)^* \mid |w|_a = |w|_b\}$
- $\{a^n b^p \mid n \neq p\}$
- $\{a^{2n} b^{2n} \mid n \geq 0\}$
- $\{a^n b^p \mid n \geq p\}$

Pour le dernier, vous pourrez utiliser deux méthodes : Une première qui établit une relation entre  $\{a^n b^p \mid n \geq p\}$  et  $\{a^n b^p \mid n > p\}$ . Une deuxième qui utilise la stabilité des reconnaissables par miroir.

### 8.2 Image inverse de morphisme

Soit  $\phi$  le morphisme défini par  $\phi(a) = a.b$ ,  $\phi(b) = a$ ,  $\phi(c) = b.a$  et  $\phi(d) = bbb$ .

Décrire  $\phi(abcd)$ ,  $\phi((ab)^*)$ ,  $\phi^{-1}(aba)$ ,  $\phi^{-1}((bba)^*)$ ,  $\phi^{-1}((ab)^*a)$ ,  $\phi^{-1}((bb)^*)$

### 8.3 Cloture avec Morphisme

Montrer que les langages suivants ne sont pas rationnels :

- $\{a^n b^n c^n \mid n \geq 0\}$
- $\{a^i b^j c^k \mid i + j = k \geq 0\}$
- $\{a^n b^{2n} \mid n \geq 0\}$
- $\{(ab)^{2n} (cd)^{2n} \mid n \geq 0\}$
- $\{a^n b a^n \mid n \geq 0\}$
- $\{w \in (a+b)^* \mid w \text{ est un palindrome} \}$

### 8.4 Optionnel

Soit  $f$  la fonction qui efface toutes les lettres en position paire.  $f(a_1 a_2 a_3 \dots) = a_1 a_3 a_5 \dots$

Exemple,  $f(abcdefghijklmn) = acegikm$ ,  
 $f(abbababba) = abbba$ .

Montrez que si  $L$  est reconnaissable, alors  $f(L)$  aussi.

### 8.5 Démonstration d'égalité entre langage, utilisant les morphismes.

Soit  $L$  et  $M$  deux langages et soit  $\phi$  un homomorphisme. Montrer ou infirmer (en exhibant un contre-exemple) les propriétés suivantes :

1.  $\phi(L \cup M) = \phi(L) \cup \phi(M)$
2.  $\phi(L.M) = \phi(L).\phi(M)$
3.  $\phi(L \cap M) = \phi(L) \cap \phi(M)$
4.  $\phi^{-1}(L \cup M) = \phi^{-1}(L) \cup \phi^{-1}(M)$
5.  $\phi^{-1}(L \cap M) = \phi^{-1}(L) \cap \phi^{-1}(M)$
6.  $\phi^{-1}(\phi(L)) = L$

## 9 Le lemme de la pompe

### 9.1 Non pompabilité

Montrez, en utilisant le lemme de la pompe (version du cours) que les langages suivants ne sont pas reconnaissables

- $\{a^n b^{2n} | n \geq 0\}$
- $\{(ab)^n c^n | n \geq 0\}$
- $\{a^n b^n | n \geq 0\} + \{a^p b^q | p \neq q[7]\}$
- $\{a^n b^m | n \geq m \geq 0\}$
- $\{a^n b^m | m \geq n \geq 0\}$
- $\{a^n b^m | n \neq m\}$
- $\{a^p b^q | p = q[2]\} + \{ba^{p+r} b^p | p, r \geq 0\} + \{b^s a^p b^{p+r} | s \geq 2, p, r \geq 0\}$
- $\{a^p | p \text{ premier}\}$

### 9.2 Pompabilité

Montrez que le langage suivant est pompable mais pas reconnaissable itemize  $\{b^m a^n b^n | m > 0, n \geq 0\} \cup a(a+b)^*$

## 10 Grammaires hors contexte

### 10.1 De la grammaire vers le langage

Déterminer les langages engendrés par les grammaires dont les règles de production sont les suivantes :

1.  $S \rightarrow \epsilon \mid aaaS$
2.  $S \rightarrow ab \mid aSb$

3.  $S \rightarrow XY \mid Z; X \rightarrow Xa \mid a; Y \rightarrow aYb \mid \epsilon; Z \rightarrow aZb \mid W; W \rightarrow bW \mid b$
4.  $S \rightarrow SS \mid \epsilon \mid (S)$
5.  $S \rightarrow SS \mid () \mid [] \mid (S) \mid [S]$
6.  $S \rightarrow \epsilon \mid S \rightarrow a_i S a_i$  pour tout  $i, 1 \leq i \leq n$
7.  $S \rightarrow bS \mid aT; T \rightarrow aT \mid bU; U \rightarrow aV \mid bS; V \rightarrow aT \mid bU \mid \epsilon$

Ces grammaires sont-elles ambiguës? Si oui, pouvez-vous donner une grammaire non-ambiguë?

### 10.2 Du langage vers la grammaire

Trouver des grammaires pour les langages suivants.

1.  $(a + (a + b)^*)(ab^*)^*$
2.  $\{a^n b^p \mid 0 < p < n\}$
3.  $\{a^n b^p \mid 0 \leq n \leq p + 1\}$
4.  $\{a^n b^n c^m d^m \mid n, m \in \mathcal{N}\}$
5.  $\{a^n b^m c^{n+m} \mid n, m \in \mathcal{N}\}$
6.  $\{a^n b^m c^p \mid n = m \text{ ou } m = p\}$
7. optionnel  $\{a^n b^m c^p d^q \mid n + q = m + p\}$
8. optionnel  $\{a^n b^m c^p d^q \mid n + p = m + q\}$

### 10.3 Desambiguer à la main

Soit  $F_1$  la grammaire

$$E \rightarrow E + E \mid E - E \mid (E) \mid id$$

et  $G_1$  la grammaire  $F_1$  plus les règles :

$$E \rightarrow E * E \mid E / E \mid E \wedge E$$

1. Donner tous les arbres de dérivations du mot  $id - id - id$ . Combien y en a-t-il? Correspondent-ils à des interprétations équivalentes?
2. Donner des grammaires  $F_2$  et  $G_2$  telles que  $L(F_1) = L(F_2)$ , que  $L(G_1) = L(G_2)$ , que chaque mot  $w$  possède une seule dérivation à partir du symbole initial de  $G_2$ , et que la décomposition en arbre corresponde aux règles usuelles de priorité.

## 11 Grammaire et compilation.

Faut avoir parlé d'analyse lexicale en cours.

## 11.1 Analyse lexicale

L'utilisation d'ocamllex n'est pas limitée à l'analyse lexicale des que l'on souhaite analyser un texte (chaîne, fichier, flux) sur la base d'expressions régulières, ocamllex est un outil de choix en particulier pour écrire des filtres, i.e. des programmes traduisant un langage dans un autre par des modifications locales et relativement simples.

Écrire un programme occamlex qui imprime un fichier en ayant préalablement enlevé toutes les lignes vides, et un autre qui compte les occurrences d'un mot dans un texte le mot et le nom du fichier texte sont passés en paramètres

## 11.2 Grammaire d'un Language de programmation

Considérons le petit programme suivant écrit en Pascal :

```

program calcul;
var
    T : array[1..10] of integer;
    S,I : integer;
begin
    S:=0; (* initialisation *)
    for I:= 1 to 10 do
    begin
        read(T[I]);
        S := S + T[I]
    end;
    writeln(S)
end.

```

L'analyseur lexical découpe ce programme en une liste des entités lexicales appelées token dont nous donnons le début. Chaque token est donné par une classe et sa valeur. Pour les identificateurs, la valeur sera l'adresse d'entrée dans une table des symboles. Par exemple, la classe est 1 pour les mots-clés, 2 pour les identificateurs.

La table des symboles est supposée découpée en une zone pour les mots-clés 0 à 50 et une zone pour les identificateurs à partir de 50. Cette table est composée d'un champ représentant la chaîne de caractères et d'un champ pouvant contenir différentes informations utiles à l'analyse sémantique.

On suppose les différentes entités rangées dans l'ordre de leur apparition, en fait les mots-clés sont en général rangés préalablement dans la table.

Les symboles ;, [], . sont associés dans l'ordre à des tokens de classe 11 à 16 comme il n'y a qu'une unité lexicale dans chacune de ces classes il n'est pas nécessaire de passer de valeurs.

|                  |                  |             |                |                  |              |             |              |           |
|------------------|------------------|-------------|----------------|------------------|--------------|-------------|--------------|-----------|
| program<br><1,0> | calcul<br><2,50> | ;<br><11>   |                |                  |              |             |              |           |
| var<br><1,1>     | T<br><2,51>      | ;<br><12>   | array<br><1,2> | [<br><13>        | 1<br><3,1>   | ..<br><8>   | 10<br><3,10> | ]<br><14> |
| S<br><2,52>      | ,<br><15>        | I<br><2,53> | ;<br><12>      | integer<br><1,4> | ;<br><11>    |             |              |           |
| begin<br><1,5>   | S<br><2,52>      | :=<br><6>   | 0<br><3,0>     | ;<br><11>        |              |             |              |           |
| for<br><1,6>     | I<br><2,53>      | :=<br><3,1> | 1<br><8>       | to<br><1,7>      | 10<br><3,10> | do<br><1,8> | ...<br>...   |           |

La table des symboles après analyse ressemble à :

| adresse | chaîne  | information |
|---------|---------|-------------|
| 0       | program |             |
| 1       | var     |             |
| 2       | array   |             |
| 3       | of      |             |
| 4       | integer |             |
| 5       | begin   |             |
| 6       | for     |             |
| 7       | to      |             |
| 8       | do      |             |
| 9       | read    |             |
| 10      | end     |             |
| 11      | writeln |             |
| :       | :       |             |
| :       | :       |             |
| 50      | calcul  |             |
| 51      | T       |             |
| 52      | S       |             |
| 53      | I       |             |
| :       | :       |             |
| :       | :       |             |

1. Proposer une grammaire permettant d'engendrer le langage auquel ce programme appartient.
2. Donner l'arbre de dérivation syntaxique associé à ce programme pour la grammaire précédente. On n'est pas obligé de le dessiner en entier, car il est très grand.

## 12 Exercices optionnel, approfondissement grammaire

A ne faire que s'il reste du temps.

### 12.1 Nettoyage de grammaires

On veut nettoyer une grammaire, c'est à dire enlever :

- (1) Les non-terminaux impasse, c'est à dire qui ne produisent pas de mots sur  $A^*$

(2) les non-termianux inaccessibles , c'est à dire qui ne figurent dans aucune dérivation faite à partir de  $S$ .

Donner un algorithme permettant de repérer (et donc d'éliminer) les impasses

Donner un algorithme permettant de repérer (et donc d'éliminer) les inaccessibles

Quand on veut faire un nettoyage complet, l'ordre dans lequel on effectue ces deux opérations est-il indifférent ? Pourquoi ?

Nettoyer la grammaire :

$$\begin{aligned} S &\rightarrow X & X &\rightarrow Y & Z &\rightarrow W|eS \\ W &\rightarrow b|fX & Y &\rightarrow aT|TK \\ U &\rightarrow bdX|Y|dZ & K &\rightarrow cV|Z \\ X &\rightarrow abcY & W &\rightarrow U \\ T &\rightarrow aT|\epsilon|ef|aY & V &\rightarrow af \end{aligned}$$

## 12.2 Désambiguation difficile.

Soient  $D_1, D_2$  et  $D_3$  les langages suivants :

$$D_1 = \{w \in \{a, b\}^* \mid |w|_a = |w|_b\}$$

$$D_2 = \{w \in \{a, b\}^* \mid |w|_a = |w|_b \text{ et}$$

$$\forall v \text{ préfix de } w \mid |v|_a \geq |v|_b\}$$

$$D_3 = \{w^R \in \{a, b\}^* \mid w \in D_2\}$$

On veut donner une grammaire pour  $D_1$  non ambigu. Montrer comment obtenir  $D_1$  avec les opérations de concaténation et d'étoile à partir du langage  $D_2$  (Dyck d'ordre 1) et de son miroir  $D_3$ . Utiliser cette description et les résultats de clôture pour lui trouver une grammaire non-ambiguë.

## 12.3 Grammaire difficile à trouver

Donnez une grammaire pour  $\{w \in (a + b)^* \mid |w|_b = 2|w|_a\}$

## 12.4 Grammaires contextuelles

On considère l'ensemble de règles de réécriture suivant :

$$\begin{aligned} S &\rightarrow aTc & aT &\rightarrow aaTcT & cT &\rightarrow Tc & aT &\rightarrow \\ ab & & bT &\rightarrow bb \end{aligned}$$

Quel est l'ensemble des mots sur  $\{a, b, c\}^*$  dérivables à partir de  $S$  ?

## 13 Automates à pile

Dans la mesure du possible, donnez des automates à pile déterministe.

1. Construire un automate à pile qui reconnaît par état final  $\{a^n b^n \mid n \geq 1\}$ , puis  $\{a^n b^n \mid n \geq 0\}$ .
2. Construire un automate à pile qui reconnaît le langage  $\{a^p b^n c^q \mid p \geq 0, q \geq 1, n = p + q\}$  par pile vide.
3. Construire un automate à pile qui reconnaît le langage des mots de Dyck sur 1 puis sur 2 types de parenthèses.
4. Construire un automate à pile qui reconnaît le langage des mots qui ont autant de a que de b (deux solutions : la première n'utilise qu'un état, la seconde qu'un seul symbole de pile) Dans chaque case on met les membre droit possibles, on constate qu'il ny' a qu'un choix donc pas de conflit.
5. Construire un automate à pile qui reconnaît le langage des palindromes.
6. Cherchez des automates a pile qui reconnaissent  $\{a^n b^n c^n \mid n \geq 0\}$  et  $\{a^n b^m a^n b^m \mid n, m \geq 0\}$ .

## 14 Analyse Syntaxique.

### 14.1 Fonctionnement de l'automate a pile non déterministe

Le cours d'analyse syntaxique ascendente sera fait la semaine prochaine, néanmoins le TD introduit gentiment un exemple concret sur ce thème. De cette façon, les notions du cours, plus abstraites, seront plus facilement comprises. Soit la grammaire suivante :

$$\begin{array}{l|l} E & ::= E + T \\ T & ::= T * F \\ F & ::= id \end{array} \quad \begin{array}{l|l} E & ::= T \\ T & ::= F \\ F & ::= cte \end{array}$$

1. Que reconnaît t'elle ? est elle ambiguë ?
2. Utiliser la grammaire pour générer la chaîne  $id^*id+cte$  par une dérivation gauche.
3. Ecrire l'automate à pile qui permet de reconnaître le langage associé à cette grammaire en utilisant la méthode vue en cours.

- Utiliser l'automate de la question précédente pour reconnaître la chaîne  $id*id+cte$
- Cet automate n'est pas déterministe, préciser pourquoi :
- Est ce que c'est gênant ?
- Ben KesKiFautfaire alors ?
- Un peu d'introspection, vous-même, quelle stratégie avez vous suivi pour orienter vos choix d'expansion de S, lorsque vous avez utilisé l'automate à la main.
- L'analyse LR(1) autorise un automate a pile à consulter quelle est la prochaine lettre du mot à lire, sans pour autant la "consommer" Mais alors, quelle sera cette lettre, lorsqu'on sera arrivé au bout du mot ?

## 14.2 Calcul premiers et suivants

Soit la grammaire :

$$\begin{array}{l|l} S & ::= AaB \\ A & ::= CB \\ A & ::= \epsilon \\ B & ::= b \\ C & ::= c \end{array} \quad \begin{array}{l} A ::= CBb \\ A ::= CA \\ C ::= \epsilon \end{array}$$

- Pour chaque non terminal  $X$  calculer  $\text{premier}(X)$  (commencer par écrire les équations)
- Pour chaque non terminal  $X$  calculer  $\text{suivant}(X)$  (commencer par écrire les équations)

## 14.3 Exemple simple d'automate SLR(1), avec exécution de l'automate LR

Soient les grammaires :

$$\begin{array}{l} S ::= L \\ L ::= L;A \mid A \\ A ::= a \end{array}$$

$$\begin{array}{l} S ::= L \\ L ::= A;L \mid A \\ A ::= a \end{array}$$

$$\begin{array}{l} S ::= L \\ L ::= L;L \mid A \\ A ::= a \end{array}$$

- Montrer que ces grammaires engendrent le même langage.
- Pour chaque grammaire si elle est LR(0), si nécessaire construire l'automate d'item et identifiez les conflits, puis essayer de les résoudre en utilisant l'automate SLR(1).

- Faire tourner l'automate et comparer la taille de la pile lors de l'analyse ascendante du mot  $a; a; a$  par les deux premières grammaires. Quelle remarque peut-on faire ?

## 14.4 Autre exemple d'analyseur LR

$$\begin{array}{l} S ::= E \# \\ E ::= id \\ E ::= id(E) \\ E ::= E + id \end{array}$$

Construisez l'automate LR(0) permettant de faire l'analyse ascendante Cet automate présente un conflit, indiquer l'état ou il se trouve, et entre quoi et quoi il y a conflit Expliquer comment résoudre ce conflit

## 14.5 Exemple un peu plus difficile, ou l'analyse SLR(1) ne marche pas, donné en Examen.

On se donne un langage de types permettant de décrire le type des entiers ou celui de fonctions à valeur entière, prenant en argument des entiers ou d'autres fonctions de même nature. Un type est donc soit la constante `int` soit de la forme  $\tau_1 * \dots * \tau_n \rightarrow \text{int}$  avec  $\tau_i$  des types. Pour reconnaître ce langage de types, on se donne la grammaire suivante avec comme ensemble de terminaux  $\{\#, \rightarrow, *, \text{int}\}$  et comme ensemble de non-terminaux  $\{S, A, T\}$  avec  $S$  le symbole de départ :

$$\begin{array}{l} S ::= T \# \\ T ::= \text{int} \\ T ::= A \rightarrow \text{int} \\ A ::= T \\ A ::= T * A \end{array}$$

- Calculer l'ensemble des suivants de  $T$  et de  $A$ .
- Construire la table d'analyse SLR(1) de cette grammaire en indiquant en cas de conflit les différentes actions possibles. Cette grammaire est-elle SLR(1) ?
- Expliquer la nature du conflit obtenu en donnant un exemple d'entrée où ce conflit se produit. La grammaire donnée est-elle ambiguë ?
- Que suggérez-vous pour remédier à ce problème ?



## 15 Clotures algébriques

Les langages suivants sont-ils algébriques ?

1.  $\{a^{n^2} \mid n \in \mathcal{N}\}$
2.  $\{a^n b^m a^n b^m \mid n, m \in \mathcal{N}\}$
3.  $\{a^p b^q c^r \mid p \leq q \leq r\}$
4.  $\{a^p b^q c^r d^s e^t f^u \mid (p, q, r, s, t, u) \text{ croit ou décroît}\}$
5.  $\{a^n b^m \mid m \neq n \text{ et } m \neq 2n\}$
6.  $\{uu \mid u \in A^*\}$
7. Le complémentaire du précédent.
8.  $\{u \mid |u|_a + 3|u|_b = 2|u|_c\}$
9.  $\{u \mid |u|_a = |u|_b = |u|_c\}$
10.  $\{u \mid |u|_a = 3|u|_b = 2|u|_c\}$
11.  $\{u.\tilde{u}.\$.u.\tilde{u} \mid u \in A^*\}$
12.  $\{a^n b^n a^n b^n \mid n \geq 0\}$
13.  $\{a^n b^n (ab)^n \mid n \geq 0\}$
14.  $\{f(y) \mid y \in Y\}$  où  $Y$  est algébrique et où  $f(a_1 a_2 a_3 a_4 a_5 \dots) = a_1 a_3 a_5 \dots$  ( $f$  efface les lettres qui sont à une position paire)

## 16 Machine de Turing

Décrire une Machine de Turing pour les différentes tâches suivantes :

- ajoute 1 à une séquence de 1
- ajoute 1 à un nombre écrit en binaire.
- qui reconnaît le langage  $\{a^{2^n} \mid n \in \mathbb{N}\}$
- qui duplique le mot en entrée
- qui reconnaît le langage  $\{ww, w \in \{0, 1\}^*\}$ .

## 17 Decidabilité

### 17.1 Decidabilité problème du mot

Soit  $H$  une grammaire et  $u = u_1 u_2 \dots u_{|u|}$  un mot. On voudrait savoir si le mot  $u$  est dans le langage engendré par  $H$ . Pour cela, on met d'abord  $h$  sous forme normale de Chomsky, (Rappel les règles sont de la forme  $M \rightarrow \epsilon; X \rightarrow YZ; X \rightarrow x; )$  puis on remplit un tableau  $T$  de type `array[0..|u|, 0..|u|]` of `subset de NT` (où `NT` est l'ensemble des non terminaux de  $H$ ) avec  $M$  dans  $T[i, j]$  pour  $j \geq i$  ssi  $M \rightarrow^* u_{i+1} u_{i+2} \dots u_j$ . ( $T[i, j]$  pour  $j < i$  est sans signification). Comment calculer les valeurs de ce tableau ? Comment déduire de ce tableau le fait que  $u$  est dans le langage ou non ?

Quelle est la complexité de cet algorithme ?

On considérera l'exemple où la grammaire est  $S \rightarrow \epsilon; S \rightarrow aSb$  qui génère  $\{a^n, b^n\}$  On souhaite montrer que  $aabb$  est dans le langage, on indexe les lettres  $a_1 a_2 b_3 b_4$  et on réécrit dans chaque case le sous mot associé à la case.

### 17.2 Indécidabilité problème de Post

Définition problème de Post : Les données du problème sont deux listes finies  $\alpha_1, \dots, \alpha_N$  et  $\beta_1, \dots, \beta_N$  de mots d'un alphabet  $A$  ayant au moins deux symboles. Une solution du problème est une suite d'indices  $(i_k)_{1 \leq k \leq K}$  avec  $K \geq 1$  et  $1 \leq i_k \leq N$  pour tous les  $k$ , telle que les concaténations  $\alpha_{i_1} \dots \alpha_{i_K}$  et  $\beta_{i_1} \dots \beta_{i_K}$  soient égales.

Le problème de correspondance de Post (PCP) consiste à déterminer si une solution existe ou non.

Résoudre ce problème pour les deux exemples suivants :

- $(\alpha_1, \alpha_2, \alpha_3) = (a, ab, bba)$  et  $(\beta_1, \beta_2, \beta_3) = (baa, aa, bb)$
- $(bb, ab, c)$  et  $(b, ba, bc)$
- Sur ce pb, on donne les paires  $(\alpha_i, \beta_i)$  :  $(\#, \#p0000000\#)$ ,  $(0, 0)$ ,  $(1, 1)$ ,  $(\#, \#)$ ,  $(p0, 0p)$ ,  $(p\#, q\#)$ ,  $(0q, 1p)$ ,  $(1q, q0)$ ,  $(\#q0, \#q)$ ,  $(\#q\#, \#)$

### 17.3 Indécidabilité de l'ambiguïté

A un problème de Post  $(u_i, v_i)_{i \in \{1, \dots, N\}}$  sur l'alphabet  $A = a, \dots, z$ , associons les grammaires suivantes :

$S2 \rightarrow \$ \mid \#S2 \mid T$

$T \rightarrow T\# \mid U$

$U \rightarrow aS2 \ a \mid \dots \mid zS2z$

$S1 \rightarrow u1 \ \# \ S1 \ \# \ \text{miroir}(v1)$

$\rightarrow u2 \ \# \ S1 \ \# \ \text{miroir}(v2)$

....

$\rightarrow uN \ \# \ S1 \ \# \ \text{miroir}(vN)$

$\rightarrow u1 \ \# \ \$ \ \# \ \text{miroir}(v1)$

$\rightarrow u2 \ \# \ \$ \ \# \ \text{miroir}(v2)$

...

$\rightarrow uN \ \# \ \$ \ \# \ \text{miroir}(vN)$

$S \rightarrow S1 \mid S2$

— Que génère la grammaire  $S2$

- Que génère la grammaire  $S_1$
- A quelle condition la grammaire avec l'axiome  $S$  est elle ambiguë
- Donner un exemple de grammaire ambiguë en utilisant les système de post donnés en exemple.
- En déduire que le problème de savoir si une grammaire est ambiguë est indécidable .

#### **17.4 Indécidabilité de l'intersection.**

Considérons le problème suivant : soit  $G_1, G_2$  deux grammaires, peut on décider si l'intersection des langages qu'elles génère est non vide ?