

2.1 Comment implanter en C un reconnaisseur de mots ?

Par groupe de 4, envoyez par email votre programme à `michael.perin@imag.fr` et `eric.gascard@imag.fr`. Votre programme doit être conforme à la spécification. Ensuite, pour avoir une chance de gagner : il doit être lisible, le plus clair et le plus simple possible, être facile à maintenir et à faire évoluer, être efficace et enfin être élégant.

a) Donnez un programme C qui accepte un mot écrit sur l'alphabet $\{a, b\}$, entré au clavier, s'il appartient au langage L_1 des mots formés d'une succession d'un nombre pairs de a entrecoupées d'un nombre quelconque de b . Par exemple, les mots $\{\epsilon, b, aa, bb, aab, baa, bbb, aabb, baab, bbaa, bbbb\}$ doivent être reconnu mais pas les mots $\{a, ab, ba, aba, bab, abab, baba\}$.

b) Donnez un programme C qui accepte un mot s'il appartient au langage $L_1.\{(ab)^n \mid n \in \mathbb{N}\}$

2.1.1 Une première implantation en C d'un reconnaisseur de mots

Solution du a) L'automate qui reconnaît L_1 est codé sous la forme d'un tableau

Aut	q_0	q_1
ACCEPT	<i>true</i>	<i>false</i>
'a'	q_1	q_0
'b'	q_0	

où l'état initial est l'état et les états accepteurs sont indiqués par *true* sur la ligne du symbole réservé ACCEPT. Ainsi q_i est accepteur *si et seulement si* $\text{Aut}[q_i][\text{ACCEPT}] = \text{true}$. L'implantation en C est présenté en Figure 1.

Solution du b)

- Soit on construit sur papier l'automate déterministe qui reconnaît le langage L et on le code sous forme d'un tableau **Aut**.
- Soit on code l'automate qui reconnaît L_1 sous la forme d'un tableau **Aut1**. On code l'automate qui reconnaît $\{(ab)^n \mid n \in \mathbb{N}\}$ sous la forme d'un tableau **Aut2**.

Aut2	q'_0	q'_1
ACCEPT	<i>true</i>	<i>false</i>
'a'	q'_1	
'b'		q'_0

Ensuite on construit **Aut** à l'aide des opérations d'une bibliothèque sur les automates.

```

#include <stdio.h>

#define ENTER 10 // La touche ENTER porte le numéro 10
#define ACCEPT 'a'-1 // pour que ACCEPT corresponde à la ligne 0 du tableau Aut
#define NE 6 // nombre d'états
#define NS 3 // nombre de symboles de l'alphabet + le symbole réservé ACCEPT

// codage des automates

int Aut1[NS][NE] = { // automate de la question a)
    {1, 0}, // codage des états accepteurs
    {1, 0}, // transitions sur 'a'
    {0,-1} // transitions sur 'b': l'absence de transition est indiqué par -1
};

int Aut[NS][NE] = { // automate de la question b)
    { 1, 0, 1, 0, 1, 0 }, // codage des états accepteurs
    { 1, 2, 3, 2, 5, -1 }, // transitions sur 'a'
    { 2,-1, 4, 4,-1, 4 } // transitions sur 'b'
};

// Fonctionnement d'un automate (1 ligne !)

int transition(int ec, char c, int Aut[NS][NE]){
    return Aut[ 1+ c-'a' ][ec];
}

// Exemple d'utilisation : reconnaissance d'un mot entré au clavier

int main(){
    char c;
    int q;


    q = 0;
    c = getchar();
    while(c!=ENTER && q>=0){
        q = transition(q,c,Aut);
        c = getchar();
    }

    if ( c==ENTER && transition(q,ACCEPT,Aut)==1 )
        printf(":accept\n");
    else
        printf(":reject\n");

    return 0 ;
}

```

FIG. 1 – Implantation en C d'un AEF par un table de transitions



Détails de la déterminisation

Aut	$\{q_0\}$ q''_0	$\{q_1\}$ q''_1	$\{q_0, q'_0\}$ q''_2	$\{q_1, q'_1\}$ q''_3	$\{q'_0\}$ q''_4	$\{q'_1\}$ q''_5
ACCEPT	<i>true</i>	<i>false</i>	<i>true</i>	<i>false</i>	<i>true</i>	<i>false</i>
'a'	$\{q_1\} = q''_1$	$\{q_0, q'_0\} = q''_2$	$\{q_1, q'_1\} = q''_3$	$\{q_0, q'_0\} = q''_2$	$\{q'_1\} = q''_5$	
'b'	$\{q_0, q'_0\} = q''_2$		$\{q'_0\} = q''_4$	$\{q'_0\} = q''_4$		$\{q'_0\} = q''_4$

On obtient l'automate déterministe minimal **Aut** représenté par le tableau :

Aut	q''_0	q''_1	q''_2	q''_3	q''_4	q''_5
ACCEPT	<i>true</i>	<i>false</i>	<i>true</i>	<i>false</i>	<i>true</i>	<i>false</i>
'a'	q''_1	q''_2	q''_3	q''_2	q''_5	
'b'	q''_2		q''_4	q''_4		q''_4

On réutilise l'implantation de la Figure 1 avec le tableau **Aut** ainsi obtenu.

2.2 Autre implantation en C d'un reconnaisseur de mots

On présente une autre solution qui représente l'ensembles des états courants d'un automate non-déterministe par un vecteur de booléens. La Figure 2 présente l'implantation en C de l'exercices (b).

Principe : Considérons un automate non-déterministe à quatre états $\{q_1, \dots, q_4\}$ et supposons qu'il ait atteint l'ensemble d'états $\{q_1, q_3\}$, on représente cette situation par le vecteur de booléens : $\langle o_1, o_2, o_3, o_4 \rangle = \langle \underbrace{1}_{\text{en } q_1?}, \underbrace{0}_{\text{en } q_2?}, \underbrace{1}_{\text{en } q_3?}, \underbrace{0}_{\text{en } q_4?} \rangle$ qui indique les états occupés :

$o_i = \text{vrai}$ si et seulement si l'automate est dans l'état q_i . Plusieurs booléens peuvent être à *vrai* simultanément puisqu'un automate non déterministe peut être dans plusieurs états à la fois.

- À chaque transition de l'automate on met à jour le vecteur de booléens. Soit **carlu** la variable qui correspond à la lettre courante. On passe dans l'état q_j (autrement dit o_j passe à *vrai*) si **carlu** correspond à une transition qui mène en q_j et si on était

L'implantation utilise deux vecteurs de booléens :

- $\langle o'_0, \dots, o'_N \rangle$ qui représente les états occupés avant la transition
 - $\langle o_0, \dots, o_N \rangle$ qui représente les états courants, c'est-à-dire ceux occupés après la transition
- Pour représenter ces vecteurs on utilise un tableau O de taille $2 \times N$ et un booléen c qui indique sur quelle ligne est le vecteur courant (l'autre ligne correspond au vecteur avant la transition). L'utilisation du booléen c évite la recopie des N booléens o_i dans les o'_i avant la mise à jour ; en effet, il suffit de faire $c := !c$ pour échanger les valeurs anciennes avec les valeurs courantes.

	0	1	...	n
$O[!c]$	o'_0	o'_1	...	o'_n
$O[c]$	o_0	o_1	...	o_n

```
#include <stdio.h>

#define ENTER 10
#define N 4

int non_bloque(int O[2][N], int c){
    // l'automate est non bloqué si l'un des états de l'automate est occupé.
    int i, s=0;
    for(i=0 ; i<N ; i++){ s = s || O[c][i] ; }
    return s;
}

int main(){
    int O[2][N] = {0} ;
    int c=0;
    char carlu;

    O[c][0]=1; // Au départ l'automate occupe l'état initial q0
    O[c][2] = O[c][2] || O[c][0]; // traitement des epsilon-transitions

    carlu=getchar();

    while( carlu!=ENTER && non_bloque(O,c) ){
        c=!c; // les valeurs courantes deviennent les anciennes valeurs

        // spécification de l'automate sous forme d'équations booléennes
        O[c][0] = (O[!c][0] && carlu=='b') || (O[!c][1] && carlu=='a') ;
        O[c][1] = (O[!c][0] && carlu=='a') ;
        O[c][2] = (O[!c][3] && carlu=='b') ;
        O[c][3] = (O[!c][2] && carlu=='a') ;

        O[c][2] = O[c][2] || O[c][0]; // traitement des epsilon-transitions
        carlu = getchar(); // lecture d'une lettre
    }

    if (carlu==ENTER && O[c][2] ) // O[c][2] est l'état accepteur
        { printf(":accept\n") ; }
    else
        { printf(":reject\n") ; }

    return 0;
}
```

FIG. 2 – Implantation en C d'un AEF par des équations booléennes

précédemment dans l'état source de la transition.

Par exemple, considérons l'automate de la question (b) et toutes les transitions qui amènent dans l'état q_0 : $q_0 \xrightarrow{b} q_0$ et $q_1 \xrightarrow{a} q_0$. La lettre courante **carlu** fait passer dans l'état q_0 (autrement dit o_0 passe à *vrai*) si on emprunte l'une de ces 2 transitions. Les booléens o'_0 et o'_1 désignent les valeurs des booléens avant la transition.

$$o_0 := \left(\underbrace{o'_0}_{\text{on était en } q_0} \wedge \text{carlu} = b \right) \vee \left(\underbrace{o'_1}_{\text{on était en } q_1} \wedge \text{carlu} = a \right)$$

- Une ϵ -transition telle que $q_0 \xrightarrow{\epsilon} q_2$ permet d'aller en q_2 dès qu'on est en q_0 sans lire de lettre. Pour en rendre compte, il faut ajouter l'équation $o_2 := o_2 \vee o_0$. Autrement dit, on conserve le résultat du calcul précédent auquel on ajoute la nouvelle possibilité due à l' ϵ -transition.
- On indique que l'exécution de l'automate commence dans son état initial q_i en assignant au booléen o_i la valeur *vrai*.
- L'automate est bloqué si tous les booléens o_i valent *faux*.
- Le mot est accepté si lorsqu'on a consommé toutes ses lettres, on se trouve sur un état accepteur (c'est-à-dire que l'un des booléens du vecteur qui correspond à un état accepteur vaut *vrai*).

Avantage / inconvénient de cette implantation

- ⊕ Cette implantation permet d'exécuter un automate non-déterministe – sans qu'on ait besoin de le déterminer, ni d'éliminer les ϵ -transitions. Les ensembles d'états sont codés par le vecteur de booléens $\langle o_1, \dots, o_n \rangle$ où le booléen o_i indique si l'automate est dans l'état q_i .
 n (ou $2n$) booléens suffisent pour coder l'état d'un automate non-déterministe tandis qu'avec l'implantation précédente il faut déterminer l'automate et l'on sait que cette opération peut conduire à un automate à 2^n états.

n	5	10	15	20	25	30	35	...
2^n	32	1024	32768	1048576	33554432	1073741824	34359738368	...

- ⊖ À chaque transition de l'automate on lit une lettre et on met à jour le vecteur de booléens, ce qui nécessite n (ou $2n$) affectation, tandis que la précédente implantation nécessitait seulement une affectation.

2.2.1 Conclusion : quelle implantation choisir ?

Considérons un automate non-déterministe à N états.

- Si sa version déterministe comporte un petit nombre d'états (de l'ordre de N), on préfère la première implantation pour son efficacité (1 affectation par transition) malgré sa représentation (consomatrice de mémoire).
- Si la version déterministe comporte un nombre d'états très supérieure à N et que la mémoire disponible est limitée, on préfère la seconde implantation pour sa représentation compacte (N booléens) malgré son manque d'efficacité (N affectations par transition).