

## Centrale Informatique MP 2003 — Corrigé

Ce corrigé est proposé par Samuel Mimram (ENS Lyon) ; il a été relu par Jean-Baptiste Rouquier (ENS Lyon) et Vincent Puyhaubert (Professeur en CPGE).

---

Le sujet traite du problème classique qui consiste à déterminer si un mot est bien parenthésé : étant donné une suite de parenthèses, on cherche à savoir si chaque parenthèse fermante correspond à une parenthèse préalablement ouverte et si toutes les parenthèses ouvrantes sont bien fermées. Il comporte trois parties, qui ne sont pas indépendantes, dont les questions sont de difficulté progressive :

- la première partie établit quelques propriétés des mots bien parenthésés, qui serviront par la suite ;
- la deuxième présente différents algorithmes qui permettent de trouver la parenthèse ouvrante associée à une parenthèse fermante (et vice versa) dans un mot bien parenthésé ;
- la troisième traite d'une extension du problème dans laquelle les mots sont constitués de parenthèses et de crochets.

Ce sujet contient quelques questions difficiles, en particulier l'algorithme de la question II.B.6 (qui requiert de l'intuition), et demande d'être précis et méticuleux. Le raisonnement par récurrence forte est abondamment utilisé et des connaissances de cours sur les langages, les expressions régulières et les automates sont nécessaires. Des implémentations de la plupart des algorithmes proposés sont demandées. Ce problème permet ainsi de réviser certaines techniques et propriétés fondamentales pour l'épreuve d'informatique des concours.

## INDICATIONS

- I.A.1 Montrer que le mot appartient à  $L_3$  en utilisant la définition des  $L_n$  (en particulier montrer que  $aabb \in L_2$ ).
- I.A.2 Montrer la propriété sur les  $L_n$  par récurrence sur  $n$ .
- I.A.3 Montrer la propriété sur les  $L_n$  par récurrence sur  $n$ . Pour le contre-exemple, considérer le mot  $abaabb$ .
- I.B.1 Utiliser le lemme de l'étoile.
- I.B.2 Construire l'automate produit de deux automates.
- I.B.3 Utiliser le langage défini par l'expression régulière  $a^*b^*$ .
- I.C.1 Montrer le résultat par double implication. Le sens direct se montre sur les  $L_n$  par récurrence sur  $n$ , l'autre sens par récurrence sur la longueur de  $w$ .
- I.C.2 Lire  $w$  de gauche à droite et stocker le nombre de  $a$  et le nombre de  $b$  rencontrés depuis le début. Utiliser la caractérisation de la question précédente, pour conclure.
- II.B.1 Montrer par l'absurde l'existence d'un représentant irréductible, en construisant une suite infinie de mots de longueurs décroissantes, puis montrer son unicité en « coloriant » les lettres ajoutées au mot irréductible de départ.
- II.B.2 Enlever le plus possible de facteurs  $()$  au concaténé de  $w_1$  et  $w_2$ .
- II.B.3 Montrer qu'un mot est bien parenthésé si et seulement si son représentant irréductible est  $\varepsilon$  en prouvant les deux sens de l'équivalence par récurrence.
- II.B.4 Déterminer le nombre de nœuds de l'arbre réduit en fonction du nombre de ses feuilles.
- II.B.6 Faire un algorithme en deux étapes. La première vise à trouver un sous-mot de  $w$  commençant par la parenthèse ouvrante qui contient la parenthèse fermante correspondante. Ceci se fait en ajoutant des sous-arbres à une liste  $F$  de sous-arbres de l'arbre réduit jusqu'à ce que le représentant irréductible du mot  $m(F)$  formé par les feuilles des arbres de  $F$  ne soit plus de la forme  $(^i$ . On choisira  $F$  de façon à ce que ses éléments soient « consécutifs », c'est-à-dire que l'ensemble de toutes leurs feuilles forment un facteur de  $w$ . Dans une seconde étape, réduire le dernier sous-arbre de  $F$  (en enlevant des feuilles « à droite »), de sorte que le représentant irréductible de  $m(F)$  soit  $\varepsilon$ .
- II.B.8 Il faut calculer les étages de l'arbre en parallèle, chaque étage étant calculé en temps  $O(1)$ .
- III.A S'inspirer de la définition de  $\mathcal{L}_P$ .
- III.B Raisonner comme à la question I.B.3. Pour la fonction, utiliser une pile comme à la question II.A.2 (on ne cherche pas à calculer la parenthèse fermante correspondante à une parenthèse ouvrante mais juste à vérifier qu'une parenthèse ouvrante n'est pas fermée par un crochet et vice versa).
- III.C Adapter la fonction de la question II.A.2.

Même si l'énoncé ne le demande pas, il est très facile de fournir une implémentation des piles à l'aide de références sur des listes :

```
type 'a pile == 'a list ref;;

let creer_pile () = ref [];;

let empiler x p = p := x :: !p;;

let depiler p = let t::q = !p in p := q; t;;

let est_vider p = !p = [];;
```

Cela peut vous être utile pour tester vos fonctions.

Caml génère une alerte lors de l'évaluation de la définition de la fonction `depiler` qui correspond au fait qu'on ne gère pas le cas où on essaierait de dépiler un élément d'une pile vide. La gestion de tels cas n'est pas exigible en concours.

Pour les preuves, il faut utiliser la définition des mots bien parenthésés comme union des  $L_n$  et non la définition informelle de l'introduction.

## I. MOTS BIEN PARENTHÉSÉS

**I.A.1** Montrons que le mot  $abaabb$  est dans  $\mathcal{L}_P$ .

Le mot  $\varepsilon$  est dans  $L_0$  par définition. Or on a  $aL_0b \subseteq L_1$ , donc  $ab = a\varepsilon b$  est dans  $L_1$ . Pour les mêmes raisons,  $aabb = a(ab)b$  est dans  $L_2$  car  $ab$  est dans  $L_1$ . Enfin,  $L_1 \subseteq L_2$ , donc  $ab \in L_2$ , et  $L_2^2 \subseteq L_3$  donc  $abaabb$  qui est le concaténé de  $ab$  et de  $aabb$  est dans  $L_3$ . Ainsi,

$$abaabb \in \mathcal{L}_P$$

**I.A.2** Soit  $\mathcal{P}(n)$  la propriété « pour tout mot  $w$  de  $L_n$ , on a  $|w|_a = |w|_b$  et si  $w \neq \varepsilon$ , alors  $w$  commence par un  $a$  et se termine par un  $b$  ». Montrons qu'elle est vraie pour tout  $n \in \mathbb{N}$ .

- $\mathcal{P}(0)$  : par définition,  $L_0 = \{\varepsilon\}$  et la propriété est trivialement vérifiée.
- $\mathcal{P}(n) \implies \mathcal{P}(n+1)$  : soit  $w \in L_{n+1}$ . Par définition de  $L_{n+1}$ , il y a trois possibilités (non exclusives).
  - $w \in L_n$  : la propriété est vérifiée par hypothèse de récurrence.
  - $w \in L_n^2$  : il existe deux mots  $w_1$  et  $w_2$  dans  $L_n$  tels que  $w = w_1w_2$ . On peut supposer  $w_1$  et  $w_2$  différents du mot vide, sinon nous sommes dans le cas précédent. Par hypothèse de récurrence, on a  $|w_1|_a = |w_1|_b$  et  $|w_2|_a = |w_2|_b$  donc

$$|w|_a = |w_1|_a + |w_2|_a = |w_1|_b + |w_2|_b = |w|_b$$

Par hypothèse de récurrence, on sait aussi que  $w_1$  et  $w_2$  commencent par  $a$  et se terminent par  $b$ . Donc  $w$  commence lui aussi par  $a$  et se termine par  $b$ .

- $w \in aL_nb$ : il existe un mot  $w'$  de  $L_n$  tel que  $w = aw'b$ . Par hypothèse de récurrence, on sait que  $|w'|_a = |w'|_b$ . On en déduit

$$|w|_a = |w'|_a + 1 = |w'|_b + 1 = |w|_b$$

Il est de plus immédiat de constater que  $w$  est distinct de  $\varepsilon$ , commence par  $a$  et se termine par  $b$ .

La propriété  $\mathcal{P}(n)$  est donc vérifiée pour tout entier  $n$ .

Soit  $w$  un mot appartenant à  $\mathcal{L}_P = \bigcup_{n \in \mathbb{N}} L_n$ . Il existe un entier  $n$  tel que  $w$  soit dans  $L_n$ . En appliquant la propriété précédente, on en déduit

$$|w|_a = |w|_b \text{ et si } w \neq \varepsilon \text{ alors } w \text{ commence par un } a \text{ et se termine par un } b.$$

Le langage  $\mathcal{L}_P$  est défini comme l'union des langages  $L_n$ . Pour montrer une propriété sur un langage défini de la sorte, il faut penser qu'il suffit de montrer la propriété sur tous les langages  $L_n$ .

**I.A.3** On suppose que l'indice de la première lettre d'un mot est 0 (pour être en accord avec les conventions utilisées par Caml). Soit  $\mathcal{P}(n)$  la propriété « pour tout mot  $w$  de  $L_n$ , pour tout  $i$  tel que  $w_i = a$ , il existe  $j > i$  tel que  $w[i \dots j] \in \mathcal{L}_P$  ». Montrons qu'elle est vraie pour tout entier  $n$ .

- $\mathcal{P}(0)$ : on a  $L_0 = \{\varepsilon\}$  et la propriété est trivialement vérifiée car si  $w \in L_0$  alors  $w = \varepsilon$  et il n'y a aucun entier  $i$  tel que  $w_i = a$ .
- $\mathcal{P}(n) \implies \mathcal{P}(n+1)$ : soient  $w$  un mot de  $L_{n+1}$  et  $i$  un entier tel que  $w_i = a$ . Par définition de  $L_{n+1}$ , il y a trois possibilités (non exclusives).
  - $w \in L_n$ : la propriété est vérifiée par hypothèse de récurrence.
  - $w \in L_n^2$ : il existe deux mots  $w_1$  et  $w_2$ , que l'on peut supposer différents de  $\varepsilon$ , dans  $L_n$ , tels que  $w = w_1w_2$ . Si  $i < |w_1|$  ( $w_i$  est une lettre de  $w_1$ ), alors, par hypothèse de récurrence, il existe  $j > i$  tel que  $w_1[i \dots j]$  soit dans  $\mathcal{L}_P$ . Dans ce cas,  $w[i \dots j] = w_1[i \dots j]$  est un mot de  $\mathcal{L}_P$ . Sinon, on a  $i \geq |w_1|$  et  $w_i$  est une lettre de  $w_2$  d'indice  $i - |w_1|$  dans  $w_2$ . Par hypothèse de récurrence, il existe  $j' > i - |w_1|$  tel que  $w_2[i - |w_1| \dots j']$  soit dans  $\mathcal{L}_P$  et, en posant  $j = j' + |w_1|$ , on a  $w[i \dots j] = w_2[i - |w_1| \dots j']$  qui est un mot de  $\mathcal{L}_P$ .
  - $w \in aL_nb$ : il existe un mot  $w'$  de  $L_n$  tel que  $w = aw'b$ . Si  $i = 0$  alors  $j = |w| - 1$  convient, car le mot  $w[i \dots j]$ , qui est égal à  $w$ , est dans  $L_{n+1}$  donc dans  $\mathcal{L}_P$ . On ne peut avoir  $i = |w| - 1$ , car  $w_{|w|-1} = b$ . Sinon, on a  $0 < i < |w| - 1$  et  $w_i$  est une lettre de  $w'$  d'indice  $i - 1$  dans  $w'$ . Par hypothèse de récurrence, on sait qu'il existe  $j' > i - 1$  tel que  $w'[i - 1 \dots j']$  soit dans  $\mathcal{L}_P$ . Ce mot est aussi un sous-mot de  $w$  car, en posant  $j = j' + 1$ , on a  $w[i \dots j] = w'[i - 1 \dots j']$ .

La propriété  $\mathcal{P}(n)$  est donc vérifiée pour tout entier  $n$ .

Soient  $w$  un mot appartenant à  $\mathcal{L}_P = \bigcup_{n \in \mathbb{N}} L_n$  et  $i$  un entier tel que  $w_i = a$ .

Il existe un entier  $n$  tel que  $w$  soit dans  $L_n$ . En appliquant la propriété précédente, on en déduit :

$$\text{Il existe } j > i \text{ tel que } w[i \dots j] \text{ soit dans } \mathcal{L}_P.$$