

TD 1 : Algorithmique du texte

Sèverine Bérard - Université de Montpellier, ISE-M

Severine.Berard@umontpellier.fr

1 Pour s'échauffer ...

Exercice 1 *Quel est l'alphabet de taille minimum qui permette d'écrire les mots allo, logo, algo et galop ?*

Exercice 2 *Mots d'un alphabet :*

1. *Quels sont tous les mots de taille 3 que l'on peut écrire avec l'alphabet $\{0, 1\}$?*
2. *Plus généralement, combien de mots de taille k peut-on écrire avec un alphabet de taille n ?*
3. *Combien de mots en tout peut-on écrire avec un alphabet de taille n ?*

Exercice 3 *Devinette :*

1. *Peut-on déterminer u et v , deux mots de l'alphabet $\{a, b, c\}$ sachant que :*
 - $|u| = |v| + 2$
 - $|u|_a = 2 * |v|_a$
 - $|u|_b = |v|_b = 1$
 - $|u.v| = 4$
2. *Et si on ajoute l'information que le mot cc n'est ni préfixe, ni suffixe de u ?*

2 À partir des mots

Exercice 4 (Chevauchement) *Deux mots se chevauchent si on peut les écrire l'un sous l'autre de manière à ce que les lettres se situant dans une même colonne soient identiques. Par exemple, les mots 010011 et 1100101 se chevauchent, tout comme les mots mobilité et playmobil. Ces deux chevauchements sont non triviaux. Les mots abcaacbacc et bca se chevauchent de manière triviale, la partie commune étant un des mots tout entier :*

010011	mobilité	abcaacbacc
1100101	playmobil	bca

En fonction des notions de préfixe, suffixe et/ou facteur que vous avez vues en cours, exprimez :

1. *la notion de chevauchement non trivial entre deux mots u et v*
2. *la notion de chevauchement entre deux mots u et v*

Exercice 5 *Soit Σ l'alphabet français à 26 lettres.*

1. *Trouvez un mot $u \in \Sigma^*$ tel que **ent** est un suffixe de u et **aiet** en est une sous-séquence.*
2. *Trouvez le mot $v \in \Sigma^*$ de longueur minimale répondant aux critères ci-dessus.*
3. *Trouvez un mot $w \in \Sigma^*$ tel que **ami** est un préfixe de w et **iti** en est un sous-mot.*
4. *Trouvez le mot $x \in \Sigma^*$ de longueur minimale répondant aux critères ci-dessus.*
5. *Trouvez un mot $y \in \Sigma^*$ tel que **iment** est un suffixe de y , **infi** en est un préfixe et **ii** en est une sous-séquence.*
6. *Trouvez le mot $z \in \Sigma^*$ de longueur minimale répondant aux critères ci-dessus.*
7. *Trouvez un mot $a \in \Sigma^*$ tel que **grb**, **iou** et **roi** en soient des sous-séquences.*
8. *Trouvez un mot $b \in \Sigma^*$ de longueur minimale répondant aux critères ci-dessus. Y a-t-il plusieurs mots b possibles ?*

Exercice 6 (Lemme de Lévi, 1994 (extrait)) Pour tous mots $x, y, z, t \in A^*$, $x.y = z.t$ implique qu'il existe un mot $u \in A^*$ tel que

- soit $x = z.u$ et $t = u.y$
- soit $z = x.u$ et $y = u.t$

Donnez une preuve de ce lemme, on pourra utiliser une preuve graphique.

3 Bords et périodes

On rappelle la proposition sur la caractérisation des périodes vue en cours :

Proposition 1 Soient x un mot non vide et p un entier tel que $0 < p \leq |x|$. Alors les 5 propriétés suivantes sont équivalentes :

1. L'entier p est une période de x
2. Il existe deux mots u et $v \neq \epsilon$ et un entier $k > 0$ tels que $x = (uv)^k u$ avec $|uv| = p$
3. Il existe un mot t et un entier $k > 0$ tels que x est un préfixe de t^k avec $|t| = p$
4. Il existe trois mots u, v et w tels que $x = uw = vw$ et $|u| = |v| = p$.
5. Il existe un mot t tel que x est préfixe de tx et $|t| = p$

Exercice 7 Démontrez la proposition ci-dessus.

Exercice 8 On rappelle qu'un mot w est dit sans bord si son seul bord est le mot vide, c'est-à-dire si $\text{period}(w) = |w|$. On suppose qu'un mot x a un bord de longueur minimale, non vide, u . Montrer que u est sans bord et qu'il existe un mot v tel que $x = uvu$.

Exercice 9 Soit w un mot non vide, u un bord de w , avec $u \neq \epsilon$, et v un bord de u , avec $v \neq \epsilon$.

Est-ce que la propriété suivante est vraie : $|w| > |u| + |v| + 1$? Si oui, la prouver, sinon donnez un contre-exemple.

Exercice 10 (Ordre lexicographique) On considère dans cet exercice l'ordre lexicographique, c'est-à-dire "l'ordre du dictionnaire", on le note $>_{\mathcal{L}}$. On a donc par exemple $\text{chien} >_{\mathcal{L}} \text{chat} >_{\mathcal{L}} \text{ch}$.

Pour un mot non vide x , on définit $\text{Maxsuf}(x)$ comme étant le suffixe maximal de x au sens de l'ordre lexicographique.

1. Donner $\text{Maxsuf}(x)$ pour $x = \text{abacabbac}$.
2. Soit x un mot non vide, et λ une lettre quelconque. On pose $u = \text{Maxsuf}(x)$ et on définit v tel que $v\lambda = \text{Maxsuf}(x\lambda)$ ¹. Montrer que soit $v = u$, soit v est un bord de u .

On rappelle le Lemme de périodicité faible :

Lemme 1 (Périodicité faible) Soient p et q deux périodes d'un mot x . Si $p + q \leq |x|$, alors $\text{pgcd}(p, q)$ est aussi une période de x .

Exercice 11 On veut démontrer ce lemme.

1. Traiter le cas $q = p$.
2. Si $p > q$, montrer que $\text{pgcd}(p, q) = \text{pgcd}(p - q, q)$.
3. Montrer que si $p > q$ et $p + q \leq |x|$ alors $p - q$ est une période de x .
4. Conclure en réalisant une récurrence sur $\max(p, q)$.

Exercice 12

1. Soit x un mot non vide. Soit u le plus petit mot tel que x est préfixe de ux . Montrer que $|u| = \text{period}(x)$.
2. Soit x un mot non vide. Montrer que les trois propositions suivantes sont équivalentes :
 - (a) $\text{period}(x^2) = |x|$,
 - (b) x est primitif, c'est-à-dire ne peut pas être écrit sous la forme u^k pour $k > 1$,
 - (c) x^2 contient seulement 2 occurrences de x .

1. $v\lambda$ est la concaténation du mot v avec la lettre λ , de même $x\lambda$ est la concaténation du mot x avec la lettre λ .