

## Option Informatique en Spé MP et MP\*

### Plus long sous-mot commun : ce qu'il faut savoir

►  $\Sigma$  désigne un alphabet contenant au moins deux lettres  $a$  et  $b$ .

**Définition :** un mot  $x$  est un *sous-mot* d'un mot  $y$  (ce que l'on notera  $x \sqsubseteq y$ ) si, notant  $m = |x|$  et  $n = |y|$ , il existe une injection croissante  $s$  de  $\llbracket 1, m \rrbracket$  dans  $\llbracket 1, n \rrbracket$  telle que  $x_i = y_{s(i)}$  pour tout  $i \in \llbracket 1, m \rrbracket$ . Ceci revient à dire que  $x$  peut se déduire de  $y$  en *supprimant* certains caractères ; ou, inversement, que  $y$  peut se déduire de  $x$  en *insérant* des caractères. Ainsi, *corne* est un sous-mot de *recouvrante*.

► On notera que, si  $x$  est facteur de  $y$ , alors  $x$  est un sous-mot de  $y$  ; mais la réciproque n'est vraie si  $|\Sigma| = 1$ .

**Question :** de quelle célébrité le nom apparaît-il comme sous-mot du mot *découvrable* ?

**Proposition :** la relation  $\sqsubseteq$  est un ordre, compatible avec la concaténation : si  $x \sqsubseteq y$ , alors  $xz \sqsubseteq yz$  et  $zx \sqsubseteq zy$ .

**Preuve**

• **Réflexivité :** l'identité  $I$  est une injection croissante de  $\llbracket 1, m \rrbracket$  dans lui-même telle que  $x_{I(i)} = x_i$  pour tout  $i \in \llbracket 1, m \rrbracket$ .

• **Antisymétrie :** soient  $x$  et  $y$  vérifiant  $x \sqsubseteq y$  et  $y \sqsubseteq x$ . Soient  $s$  une injection croissante de  $\llbracket 1, m \rrbracket$  dans  $\llbracket 1, n \rrbracket$  telle que  $y_{s(i)} = x_i$  pour tout  $i \in \llbracket 1, m \rrbracket$ , et  $t$  une injection croissante de  $\llbracket 1, n \rrbracket$  dans  $\llbracket 1, m \rrbracket$  telle que  $x_{t(j)} = y_j$  pour tout  $j \in \llbracket 1, n \rrbracket$ . On a nécessairement  $n = m$  ; puis  $s$ , injection croissante de  $\llbracket 1, m \rrbracket$  dans lui-même est l'application identique, si bien que  $y = x$ .

• **Transitivité :** soient  $x$ ,  $y$  et  $z$  vérifiant  $x \sqsubseteq y$  et  $y \sqsubseteq z$ . Notons  $p = |z|$ ,  $s$  une injection croissante de  $\llbracket 1, m \rrbracket$  dans  $\llbracket 1, n \rrbracket$  telle que  $y_{s(i)} = x_i$  pour tout  $i \in \llbracket 1, m \rrbracket$ , et  $t$  une injection croissante de  $\llbracket 1, n \rrbracket$  dans  $\llbracket 1, p \rrbracket$  telle que  $z_{t(j)} = y_j$  pour tout  $j \in \llbracket 1, n \rrbracket$ . Alors  $z_{(t \circ s)(i)} = x_i$  pour tout  $i \in \llbracket 1, m \rrbracket$ , et  $t \circ s$  est une injection croissante. Ainsi  $x \sqsubseteq z$ .

• **Compatibilité avec la concaténation :** supposons  $x \sqsubseteq y$ , et soit  $s$  une injection croissante de  $\llbracket 1, m \rrbracket$  dans  $\llbracket 1, n \rrbracket$  adaptée. Soit  $z$  de longueur  $p$  ; alors  $t : \llbracket 1, m+p \rrbracket \mapsto \llbracket 1, n+p \rrbracket$  définie par  $t(i) = i$  pour  $i \in \llbracket 1, p \rrbracket$  et  $t(i) = s(i-p) + p$  pour  $i \in \llbracket p+1, m+p \rrbracket$  est une injection croissante de  $\llbracket 1, m+p \rrbracket$  dans  $\llbracket 1, n+p \rrbracket$ , vérifiant  $(zx)_{t(i)} = (zy)_i$  pour tout  $i \in \llbracket 1, m+p \rrbracket$ , ce qui montre que  $zx \sqsubseteq zy$ . Pour montrer  $xz \sqsubseteq yz$ , on utilisera  $u$  définie par  $u(i) = s(i)$  si  $i \in \llbracket 1, m \rrbracket$  et  $u(i) = i - m$  si  $i \in \llbracket m+1, m+p \rrbracket$ .

► Par programmation dynamique, on peut trouver un *plus long sous-mot commun* à deux mots  $u$  et  $v$  pour un coût  $\mathcal{O}(|u| \times |v|)$ . En revanche, la recherche d'un mot  $v$  de longueur minimale et admettant chacun des mots  $u_1, \dots, u_n$  comme sous-mots est un problème NP-complet, n'admettant même pas d'algorithme d'approximation.

**Définition :** une *antichaîne* d'un ensemble ordonné  $(E, \preceq)$  est un ensemble d'éléments de  $E$  deux à deux incomparables.

**Exemples :** dans  $\mathcal{P}(E)$  muni de l'inclusion, les singletons forment une anti-chaîne. Dans  $\mathbb{N}$  muni de la relation «divise», les nombres premiers forment une anti-chaîne. Dans un langage  $L$ , l'ensemble des mots de longueur minimale forment une anti-chaîne pour la relation  $\sqsubseteq$  comme pour la relation «est facteur de».

**Théorème (Higman) :** il n'existe pas d'antichaîne infinie pour l'ordre  $\sqsubseteq$  sur un alphabet fini.

**Preuve :** voir le *Handbook of Formal Languages*.

FIN