

Algorithmique TP 20 : Justification d'un texte en lignes

Le problème du formatage d'un texte en lignes¹, sous sa forme la plus simple, peut se formuler de la manière suivante : soit une suite de mots m_0, \dots, m_{n-1} que l'on désire découper en lignes de longueur L . On note $l(m)$ la longueur d'un mot m . Les mots sont séparés par des espaces dont la taille idéale est e , mais qui peuvent être étirés ou comprimés au besoin (sans toutefois provoquer de chevauchement de mots), de manière que la ligne $m_i m_{i+1} \dots m_j$ ait exactement la longueur L . Cependant, on attribue une pénalité d'étirement ou de compression égale à la valeur absolue totale des étirements ou des compressions subies par les blancs de la ligne. Autrement dit, le coût de la mise en forme de la ligne $m_i m_{i+1} \dots m_j$ est $|e' - e|$ où e' , la longueur réelle des espaces, est $\frac{(L - l(m_i) - \dots - l(m_j))}{(j-i)}$. Cependant, si $j = n - 1$ (on a atteint la dernière ligne), le coût est nul à moins que $e' < e$, puisqu'on n'a pas à jouer sur l'élasticité des espaces de cette dernière ligne. On veut formater un texte de façon à avoir un coût minimal.

Un algorithme dynamique de résolution de ce problème de formatage peut s'exprimer comme suit.

```

c[i] := ∞ pour i = 0, ..., n
c[n] := 0
Pour i entre n - 1 et 0
  c[i] := minj=i...n-1(cout(i, j) + c[j + 1])
  d[i] := le j correspondant au min précédent
i := 0
TantQue i < n
  Ecrire mi...md[i]
  i := d[i] + 1

```

où $c[i]$ est le coût minimum pour écrire les mots $m_i \dots m_{n-1}$ (avec m_i en début de ligne), $d[i]$ est l'indice du dernier mot de la première ligne pour ce coût minimum et $cout(i, j)$ est le coût de l'écriture des mots $m_i \dots m_j$ sur une même ligne (éventuellement ∞).

1. En utilisant le module `Lib20` (`lib20.mli`, `lib20.cmi` et `lib20.cmo` sous `/usr/local/serveur/PROG/algo`) implanter l'algorithme de formatage et afficher dans la fenêtre graphique. L'interface du module `lib20` est la suivante :

```

_____ lib20.mli _____
val infini : int
val espace : int
val longueur_mots : string array -> int -> int -> int
val cout_ligne : string array -> int -> int -> int -> int
val exemple : string array
exception Too_much

```

où

- `espace` est la valeur de l'espace idéal (e) entre deux mots ;
- `longueur_mots mots i j` calcule la somme des longueurs des mots d'indice $i, i+1, \dots, j$ du tableau `mots` ;
- `cout_ligne mots i j largeur` est le coût de formatage des mots d'indice $i, i+1, \dots, j$ du tableau `mots` dans une ligne de largeur `largeur` ; l'exception `Too_much` est levée si les mots ne tiennent pas sur la ligne ;
- `exemple` est un exemple de phrase à formater.

La fonction de formatage prend en argument un vecteur de mots et la largeur de la ligne :

```
justifie : string array -> int -> unit
```

Pour utiliser la fenêtre graphique (voir `The graphics library` dans la documentation), on devra utiliser les fonctions suivantes :

¹D'après Structure de données et algorithmes, A. Aho, J. Hopcroft & J. Ullman, page 352

- `open_graph: string -> unit` (à appeler avec l'argument "") pour ouvrir la fenêtre graphique;
- `moveto: int -> int -> unit` pour se déplacer à une position voulue :
- `draw_string string -> unit` pour afficher une chaîne de caractère à la position courante.

Pour compiler, utiliser la commande suivante :

```
ocamlc -o tp20 graphics.cma -I /usr/local/serveur/PROG/algo lib20.cmo tp20.ml
```