

Gagner en passant à la corde



Jean-Christophe Filliâtre
CNRS

dixième édition du concours de programmation de l'ICFP
manipulation de l'ADN d'un extra-terrestre (7,5 millions de bases)

on n'allait pas loin avec de simples chaînes de caractères
(quel que soit le langage)

il a fallu réinventer la roue

Ropes : an Alternative to Strings

Hans-J. Boehm, Russ Atkinson et Michael Plass

Software—Practice and Experience, vol. 25(12), 1315–1330 (December 1995)

(contexte : le développement du langage Cedar à Xerox PARC)

- ① structure de corde
- ② plus loin avec les modules d'Ocaml

une bonne structure de chaînes de caractères :


- **immuable**
- **efficace**, notamment concaténation et extraction de sous-chaîne
- **sans limite de taille**, efficace sur les très longues chaînes
- un **fichier** doit pouvoir être considéré comme une chaîne de caractères

une bonne structure de chaînes de caractères :

- **immuable**
- **efficace**, notamment concaténation et extraction de sous-chaîne
- **sans limite de taille**, efficace sur les très longues chaînes
- un **fichier** doit pouvoir être considéré comme une chaîne de caractères

une **corde** est un arbre binaire dont

- les nœuds représentent des concaténations
- les feuilles sont des chaînes usuelles



```
type t =  
  | Str of string  
  | App of t × t
```

en pratique, on veut

- partager des sous-chaînes d'une même chaîne primitive
- obtenir la longueur en temps constant

```
type t =  
  | Str of string × int × int (* offset, length *)  
  | App of t × t × int        (* total length *)
```



```
type t =  
  | Str of string  
  | App of t × t
```

en pratique, on veut

- **partager des sous-chaînes** d'une même chaîne primitive
- obtenir la **longueur en temps constant**

```
type t =  
  | Str of string × int × int (* offset, length *)  
  | App of t × t × int (* total length *)
```

```
type t =  
  | Str of string  
  | App of t × t
```

en pratique, on veut

- **partager des sous-chaînes** d'une même chaîne primitive
- obtenir la **longueur en temps constant**

```
type t =  
  | Str of string × int × int (* offset, length *)  
  | App of t × t × int       (* total length *)
```

longueur

```
val length : t → int (* O(1) *)
```

i-ième caractère

```
val get : t → int → char
```

sous-chaîne

```
val sub : t → int → int → t
```

concaténation


```
val append : t → t → t (* O(1) *)
```

```
let append t1 t2 = App (t1, t2, length t1 + length t2)
```

en pratique

- on **concatène** effectivement les feuilles qui sont assez petites
- on cherche à **équilibrer** l'arbre

Concaténation des petites feuilles



```
let append r1 r2 = match r1, r2 with
| Str (s1, ofs1, len1), Str (s2, ofs2, len2)
  when len1 <= 256 && len2 <= 256 →
  Str (String.sub s1 ofs1 len1 ^ String.sub s2 ofs2 len2,
      0, len1 + len2)
| ...
```

on peut équilibrer les cordes pendant la construction
(AVL, arbres rouges et noirs, etc.)

l'article original privilégie un rééquilibrage *a posteriori*

- quand la hauteur devient trop grande, ou
- quand l'utilisateur le demande

Opérations de modification

immédiates :

```
let (++) = append
```

```
let delete t i = sub t 0 i ++ sub t (i+1) (length t-i-1)
```

```
let insert t i r = sub t 0 i ++ r ++ sub t i (length t - i)
```


```
let set t i c =  
  sub t 0 i ++ singleton c ++ sub t (i+1) (length t-i-1)
```

note : on peut optimiser avec une seule descente


(mentionnés dans l'article de Boehm, Atkinson & Plass)

idée : se positionner en un point de la chaîne pour y effectuer des **modifications locales**, moins coûteuses que sur l'intégralité de la chaîne

c'est un **zipper** !




```
type path =  
  | Top  
  | Left of path × t  
  | Right of t × path  
type cursor = {  
  rpos : int;      (* relative position in the leaf *)  
  lofs : int;      (* absolute position of the leaf *)  
  leaf : t;        (* the leaf Str (str,ofs,len) *)  
  path : path;     (* context = zipper *)  
}
```



```
{ rpos = 4;  
  lofs = ...;  
  leaf = Str ("abcdwxyz", 0, 8);  
  path = Left (Left (Right (... , Top),  
                    ...),  
              ...)  
}
```

l'article contient également

- des détails concernant la réalisation dans Cedar
- des tests de performance

plus loin avec les modules d'Ocaml

Foncteur naturel

```
module type STRING = sig
  type t
  type char
  val length : t → int
  val empty : t
  val singleton : char → t
  val get : t → int → char
  val append : t → t → t
  val sub : t → int → int → t
end
```

```
module Rope(S : STRING) : STRING with type char = S.char
```

peu importe le type `char`

Une infinité de structures de données

```
module R1 = Rope(String)
```

⇒ des nœuds Str aux feuilles

```
module R2 = Rope(R1)
```

⇒ des nœuds Str à deux niveaux différents

```
module R3 = Rope(R2)
```

⇒ ...

Tableaux redimensionnables

```
module Arr(T : sig type t end) = struct
  type char = T.t
  type t = char array
  let empty = [| |]
  let singleton x = [|x|]
  include Array
end
```

```
module R = Rope(Arr(T))
```

```
type vector = R.t ref
```

Autre application : fonctions vues comme des chaînes

dans l'article original, les feuilles peuvent aussi être des **fonctions** (pour représenter la lecture dans un fichier, typiquement)

```
module SorF = struct
  type char = Char.t
  type t = S of string | F of int × (int → char)

  let length = function S s → String.length s | F (n,_) → n

  let get t i = match t with S s → s.[i] | F (_,f) → f i

  let sub t ofs len = match t with
    | S s → S (String.sub s ofs len)
    | F (n, f) → F (len, fun i → f (i - ofs))
  ...
end

module SF = Rope(SorF)
```

Autre application : fonctions vues comme des chaînes

dans l'article original, les feuilles peuvent aussi être des **fonctions** (pour représenter la lecture dans un fichier, typiquement)

```
module SorF = struct
  type char = Char.t
  type t = S of string | F of int × (int → char)

  let length = function S s → String.length s | F (n,_) → n

  let get t i = match t with S s → s.[i] | F (_,f) → f i

  let sub t ofs len = match t with
    | S s → S (String.sub s ofs len)
    | F (n, f) → F (len, fun i → f (i - ofs))
  ...
end

module SF = Rope(SorF)
```


Dernière application : éditeur de texte

on veut écrire un éditeur de texte capable de supporter de **très gros** fichiers et/ou de **très grandes** lignes

idée : une corde de lignes pour le fichier, et une corde de caractères pour chaque ligne

bonus : la persistance de la structure de données facilite le retour en arrière (*undo*)

```
(* ligne = corde de caractères *)  
module Line = Rope(String)  
  
(* texte = corde de lignes *)  
module Text = Rope(Arr(Line))  
  
(* le texte en cours d'édition *)  
let text = ref Text.empty
```

```
let insert_char l ofs c =  
  let line = Text.get !text l in  
  let line' = Line.insert line ofs c in  
  text := Text.set !text l line'
```

```
let insert_newline l ofs =  
  let line = Text.get !text l in  
  let prefix = Line.sub line 0 ofs in  
  let suffix = Line.sub line ofs (Line.length line - ofs) in  
  let r = Text.insert !text l prefix in  
  text := Text.set r (l + 1) suffix
```

```
let insert_char l ofs c =  
  let line = Text.get !text l in  
  let line' = Line.insert line ofs c in  
  text := Text.set !text l line'
```

```
let insert_newline l ofs =  
  let line = Text.get !text l in  
  let prefix = Line.sub line 0 ofs in  
  let suffix = Line.sub line ofs (Line.length line - ofs) in  
  let r = Text.insert !text l prefix in  
  text := Text.set r (l + 1) suffix
```

Graphisme	68	Idc
Modèle	55	Idc
Vue	54	Idc
Contrôleur	86	Idc
total	263	Idc

`http://www.lri.fr/~filliatr/software.en.html`