



UNIVERSITÉ
CÔTE D'AZUR

Les séquences : vecteurs

Algo & Prog avec R

A. Malapert, B. Martin, M. Pelleau, et J.-P. Roy

13 novembre 2023

Université Côte d'Azur, CNRS, I3S, France
`firstname.lastname@univ-cotedazur.fr`

Qu'est-ce qu'une séquence ?

Séquence

Une séquence est une suite finie de valeurs numérotées, distinctes ou pas, de n'importe quel type.

Vecteur

Un vecteur est une séquence d'éléments **du même type**.

```
> 1:6
[1] 1 2 3 4 5 6
> c('foo', 'bar')
[1] "foo" "bar"
```

Liste

Une liste est une séquence d'éléments **de type quelconque**.

```
> list(1:6, c('foo', 'bar'))
[[1]]
[1] 1 2 3 4 5 6

[[2]]
[1] "foo" "bar"
```

Mutabilité

Les listes et vecteurs sont mutables, i.e. on peut les modifier.

De l'utilité des séquences ...

Programmons la fonction `Diviseurs` qui retourne la liste des diviseurs non triviaux (distincts de 1 et n) d'un entier $n \geq 2$.

Ne connaissant pas à l'avance le nombre d'éléments du résultat, on utilise un vecteur, initialement vide, qu'on agrandit au fur et à mesure.

```
Diviseurs <- function(n) {  
  res <- numeric(0);  
  for(d in 2:(n-1)) {  
    if( n %% d == 0) res <- append(res, d);  
  }  
  return(res)  
}
```

`numeric` crée un vecteur numérique.

`append` ajoute un élément en queue d'un vecteur.

```
> Diviseurs(1000)  
[1] 2 4 5 8 10 20 25 40 50 100 125 200 250 500
```

Accès par rang aux éléments d'une séquence

L'accès par rang est commun aux vecteurs, listes, matrices, data frames.

- ▶ La notation indexée par crochets. Les indices commencent à 1.
- ▶ R supprime les éléments quand leurs indices sont négatifs.
- ▶ R vérifie la validité des arguments.

```
> vec <- 1:5
> vec[1] # Les indices commencent à 1.
[1] 1
> vec[2]
[1] 2
> vec[c(1,5)] # accéder simultanément à plusieurs éléments.
[1] 1 5
> vec[-3] # suppression d'éléments avec un index négatif
[1] 1 2 4 5
> vec[0] # Les indices commencent à 1 !
integer(0)
> vec[6] # valeur spéciale pour les éléments manquants.
[1] NA
```

Dans de nombreux langages, la fonction `index` permet de connaître le rang d'un élément dans une séquence donnée.

Elle n'existe pas en R et nous allons donc la programmer !

```
Index <- function(x, vec) {  
  for(i in seq_along(vec)) {  
    if( vec[i] == x) return(i)  
  }  
  return(NA)  
}
```

```
> Index(2, 1:5)  
[1] 2  
> Index(6, 1:5)  
[1] NA  
> Index("foo", c("foo", "bar"))  
[1] 1
```

La fonction `seq_along` renvoie le vecteur des indices du vecteur `vec` !

Défi

Programmer une fonction `positions(x,vec)` retournant le vecteur des indices `i` tels que `vec[i] == x`.

Autres fonctions d'accès par contenu

R ne dispose pas d'une fonction `index`, mais des fonctions plus puissantes et complexes : `match` et `which`.

Arithmétique des vecteurs

Opérations membre à membre

L'opération est appliquée sur les paires d'éléments à la même position.

```
> 1:3 + 3:1
[1] 4 4 4
> 1:3 * 3:1
[1] 3 4 3
```

```
> 1:3 / 1:3
[1] 1 1 1
> (1:3) ** (3:1)
[1] 1 4 3
```

Recyclage des éléments

Si deux vecteurs ont des longueurs différentes, les éléments du plus court sont recyclés.

```
> 1:4 + 1:2
[1] 2 4 4 6
> 1:5 + 1:2
[1] 2 4 4 6 6
Warning message:
In 1:5 + 1:2 :
  la taille d'un objet plus long n'est pas multiple de la
  taille d'un objet plus court
```

Construction d'une nouvelle séquence

Construction en extension

On utilise surtout la fonction `c`.

```
> c(2, 3, 5)
[1] 2 3 5
> c(TRUE, FALSE, TRUE, FALSE, FALSE)
[1] TRUE FALSE TRUE FALSE FALSE
```

Longueur d'un vecteur

La longueur d'un vecteur est retournée par la fonction `length`.

```
> length(c("aa", "bb", "cc", "dd", "ee"))
[1] 5
```

Concaténation de deux séquences

On peut coller côte à côte (concaténer) deux séquences pour construire une nouvelle séquence. Le vecteur numérique a été transformé (**coerced**) en chaînes de caractères pour la cohésion de type.

```
> c(1:3, c("foo", "bar"))
[1] "1" "2" "3" "foo" "bar"
```

Extraction d'une tranche de séquence

La notation des tranches (**slices**) est valide pour toute séquence. Elle permet d'extraire une sous-séquence à partir d'un **vecteur numérique d'indices**.

- ▶ Les indices peuvent être dupliqués.
- ▶ Les indices peuvent être dans n'importe quel ordre.

```
> vec <- 1:5
> vec[c(1,3,5)]
[1] 1 3 5
> vec[c(5,1,5)]
[1] 5 1 5
```


Extraction d'une tranche de séquence ...

La notation des tranches permet d'extraire une sous-séquence à partir d'un **vecteur logique d'indices**. Le booléen au rang k indique si le k -ème élément appartient à la sous-séquence.

- ▶ Les indices ne peuvent pas être dupliqués.
- ▶ Les indices ne peuvent pas être dans n'importe quel ordre.

```
> vec <- c("a", "b", "c", "d", "e")
> ind <- c(TRUE, TRUE, FALSE, FALSE, FALSE)
> vec[ind]
[1] "a" "b"
```

Recyclage du vecteur logique

```
> vec[c(TRUE, FALSE)]
[1] "a" "c" "e"
```

Extraction d'entête et de queue : head et tail

```
> head(vec, 3)
[1] "a" "b" "c"
```

```
> tail(vec, 3)
[1] "c" "d" "e"
```

```
> tail(vec, -3)
[1] "d" "e"
```

Pré-allocation de mémoire

Prévoir l'espace mémoire nécessaire avant l'exécution du programme, en spécifiant la quantité nécessaire dans le code source. Au chargement du programme en mémoire, juste avant l'exécution, l'espace réservé devient alors accessible.

Réécrivons 1:n avec ou sans préallocation de mémoire

```
Seq1 <- function(n) {  
  vec <- numeric(0) # sans  
  for(i in seq(n)) {  
    vec <- append(vec, i)  
  }  
  return(vec)  
}
```

```
Seq2 <- function(n) {  
  vec <- numeric(n) # avec  
  for(i in seq(n)) {  
    vec[i] <- i  
  }  
  return(vec)  
}
```

```
> system.time(replicate(5, Seq1(20000)))  
utilisateur      système      écoulé  
    1.373         0.017         1.393  
  
> system.time(replicate(5, Seq2(20000)))  
utilisateur      système      écoulé  
    0.013         0.000         0.012
```

Modification d'un vecteur

Les vecteurs et les listes sont mutables, avec l'opérateur crochet, la méthode `append` (en queue ou à un rang donné) ou les indices négatifs (supprime un ou plusieurs éléments).

Ajout d'éléments

```
> v <- 1:5
> v[1] <- 5
> v
[1] 5 2 3 4 5
```

```
> append(v,6)
[1] 5 2 3 4 5 6
> append(v,c(6,7))
[1] 5 2 3 4 5 6 7
```

```
> append(v,6,2)
[1] 5 2 6 3 4 5
> append(v,c(6,7),2)
[1] 5 2 6 7 3 4 5
```

Suppression d'éléments

```
> v[-3]
[1] 1 2 4 5
> v[c(-2, -3)]
[1] 1 4 5
```

Rappel sur les chaînes

- ▶ Les chaînes sont immutables.
- ▶ Ce ne sont pas des séquences.

```
> str <- "foo"
> str[1]
[1] "foo"
```

Conditions et tests vectorisés !

Opérations de comparaison vectorisées

Tous les opérateurs de comparaison sont vectorisés.

```
> vec <- 1:5
> vec == 2
[1] FALSE TRUE FALSE FALSE FALSE
> vec > 3
[1] FALSE FALSE FALSE TRUE TRUE
```

Attention aux opérations logiques vectorisées

Attention, les opérateurs & et && sont très différents pour un vecteur !

```
> vec %% 2 == 0 & vec > 2
[1] FALSE FALSE FALSE TRUE FALSE
> vec %% 2 == 0 && vec > 2
[1] FALSE
```

les opérateurs | et || sont tout aussi différents

Recherche des bornes d'un vecteur

Recherche du plus petit/grand élément

```
> min(c(2, 3, 1, 5, 4))  
[1] 1
```

```
> max(c(2, 3, 1, 5, 4))  
[1] 5
```

Recherche du rang du plus petit/grand élément

```
> which.min(c(2, 3, 1, 5, 4))  
[1] 3
```

```
> which.max(c(2, 3, 1, 5, 4))  
[1] 4
```

Recherche du plus petit et du plus grand élément

```
> range(c(2, 3, 1, 5, 4))  
[1] 1 5
```

Le cas du NA : cela ne marche plus, supprimons-les

```
> min(c(2, 3, 1, 5, 4, NA))  
[1] NA  
> min(c(2, 3, 1, 5, 4, NA), na.rm = TRUE)  
[1] 1
```

Recherche dans un vecteur : which

La fonction `which` renvoie un vecteur numérique d'indices dont les éléments respectent la condition.

```
> vec <- 1:5
> vec == 2
[1] FALSE TRUE FALSE FALSE FALSE
> vec %% 2 == 0 & vec > 2
[1] FALSE FALSE FALSE TRUE FALSE
> which(vec == 2)
[1] 2
> which(vec %% 2 == 0)
[1] 2 4
> which(vec %% 2 == 0 & vec > 2)
[1] 4
> which(vec %% 2 == 0 && vec > 2)
integer(0)
```

Recherche dans un vecteur : match

La fonction `match` renvoie un vecteur numérique d'indices du premier élément de son premier argument contenu dans le second.

```
> match(1:5, 2)
[1] NA 1 NA NA NA
> 1:5 %in% 2
[1] FALSE TRUE FALSE FALSE FALSE
> which(1:5 %in% 2)
[1] 2
> match( 1:5, c(2,6,3))
[1] NA 1 3 NA NA
> match( 1:5, c(2,6,3), nomatch=0)
[1] 0 1 3 0 0
```

Fonctions all et any sur un vecteur logique

all renvoie TRUE si tous les éléments sont TRUE.

```
> all(c(TRUE, TRUE))
[1] TRUE
> all(c(FALSE, TRUE))
[1] FALSE
> all(c(TRUE, TRUE, NA))
[1] NA
> all(c(TRUE, TRUE, NA), na.rm=TRUE)
[1] TRUE
> all(1:10 > 1)
[1] FALSE
```

any renvoie TRUE si au moins un élément est TRUE.

```
> any(c(FALSE, FALSE))
[1] FALSE
> any(c(FALSE, TRUE))
[1] TRUE
> any(1:10 < 2)
[1] TRUE
```


Tri d'un vecteur : sort

Dans un ordre donné

```
> x <- sample(10)
> sort(x)
[1] 1 2 3 4 5 6 7 8 9 10
> sort(x, decreasing=TRUE)
[1] 10 9 8 7 6 5 4 3 2 1
```

En retournant éventuellement les indices

```
> x
[1] 9 3 10 1 4 8 5 7 6 2
> sort(x, index.return = TRUE)
$x
[1] 1 2 3 4 5 6 7 8 9 10
$ix
[1] 4 10 2 5 7 9 8 6 1 3
```

De n'importe quel type

```
> sort(head(letters, 10), decreasing=TRUE)
[1] "j" "i" "h" "g" "f" "e" "d" "c" "b" "a"
```

Consultez notre superbe [reference card](#) !

Extraction des nombres pairs d'un vecteur

Méthode classique

Facilement transportable dans d'autres langages de programmation.

```
ExtractionNombresPairs <- function(x) {  
  res <- numeric(0);  
  for(v in x) {  
    if( v %% 2 == 0) res <- append(res, v);  
  }  
  return(res)  
}
```

```
> x <- 1:10  
> ExtractionNombresPairs(x)  
[1] 2 4 6 8 10
```

Méthodes plus courtes, mais spécifiques à R

```
> x[ x %% 2 == 0]  
> x[ which(x %% 2 == 0)]  
> Filter(function(n) n %% 2 == 0, x)
```

Retour sur les chaînes de caractères

On ne peut pas itérer sur les caractères d'une chaîne, mais on peut la transformer en un vecteur de code de caractères, et on peut itérer sur un vecteur.

Transformation des chiffres en '?'

```
Cacher <- function(str) {  
  chars <- utf8ToInt(str)  
  c0 <- utf8ToInt('0')  
  c9 <- utf8ToInt('9')  
  acc <- ""  
  for(ci in chars) {  
    if(ci >=c0 && ci <=c9) {  
      acc <- paste(acc,"?", sep = "")  
    } else {  
      acc <- paste(acc, intToUtf8(ci),  
                  sep = "")  
    }  
  }  
  return(acc)  
}
```

```
> Cacher("324DAC75")  
[1] "???DAC??"
```

Vectorisation de chaîne de caractères

Une chaîne de caractères n'est pas mutable, mais on peut la transformer en un vecteur de code de caractères, et on peut modifier un vecteur, puis le rebasculer dans une chaîne !

```
Cacher <- function(str) {  
  chars <- utf8ToInt(str)  
  c0 <- utf8ToInt('0')  
  c9 <- utf8ToInt('9')  
  digits <- which(chars >= c0 & chars <= c9)  
  chars[digits] <- utf8ToInt('??')  
  return(intToUtf8(chars))  
}
```

Substitution d'expression régulière dans une chaîne

La solution la plus simple et robuste reste l'appel à une fonction prédéfinie pour la substitution d'expression régulière.

```
Cacher <- function(str) gsub("\\d", "?", str)
```

En bonus, la fonction Cacher est elle-même vectorisée.

```
> Cacher(c("234DAC75", "BCD302GE"))  
[1] "???" "DAC???" "BCD???" "GE"
```

Évaluation des performances

Le protocole expérimental consiste à cacher 2000 mots aléatoires de différentes longueurs avec les trois versions.

Version I accumulation dans une chaîne de caractères.

Version II vectorisation dans un vecteur de codes.

Version III substitution d'expression régulière dans une chaîne.

```
> alphabet <- c(letters, seq(0,9))
> GenerateWord <- function(n) paste(sample(alphabet, size =
  n, replace = TRUE), collapse = "")
> words <- replicate(2000, GenerateWord(100))
> system.time(sapply(words, Cacher))
```

n	version I	version II	version III
10^2	0.67	0.03	0.03
10^3	8.42	0.07	0.08
10^4	269.62	0.51	0.60

Table 1: Durée du traitement en secondes.

Questions?

Retrouvez ce cours sur le site web

www.i3s.unice.fr/~malapert/R