

Chaînes de caractères : éditer une base bibliographique

J. Lobry & D. Chessel

 permet toutes les manipulations sur les chaînes de caractères. La fiche introduit aux recherches et substitutions avec des expressions régulières. L'illustration porte sur une bibliographie au format BibTex.

Table des matières

1	Introduction	2
2	Recherche de chaînes de caractères	4
2.1	Identifier les débuts de fiche	4
2.2	Trouver une chaîne de caractères	4
2.3	Rechercher les numéros manquants	4
3	Substituer une chaine de caractères à une autre	6
3.1	Rechercher un auteur	6
3.2	La distribution du nombre d'articles par auteur	6
3.3	La distribution du nombre d'auteurs par article	6
4	Pour faire des citations dans L^AT_EX	6
	Références	7

1 Introduction

Télécharger le fichier <http://pbil.univ-lyon1.fr/R/donnees/pco.bib>. Ouvrir ce fichier dans un éditeur de texte :

```
pco001,
Author = {Udalova, I.A. and Mott, R. and Field, D. and Kwiatkowski, D.},
Title = {Quantitative prediction of NF-[Kappa]B DNA-protein interactions},
Journal = {Proceedings of the National Academy of Sciences of the United
States of America},
Volume = {99},
Number = {12},
Pages = {8167-8172},
Year = {2002} }
```

...

Il contient des références bibliographiques au format BibTex :

<http://www.ecst.csuchico.edu/~jacobsd/bib/formats/bibtex.html>

De nombreux outils manipulent ce type de fichier, par exemple le déjà ancien BibEdit sous Windows :

<http://www.iui.se/staff/jonasb/bibedit/>

Le logiciel indique qu'il y a 234 références dans le fichier (figure 1). Pour placer le contenu intégral du fichier texte en mémoire dans un vecteur de chaînes de caractères :

```
rm(list = ls())
download.file("http://pbil.univ-lyon1.fr/R/donnees/pco.bib", "pco.bib",
  mode = "wb")
tmp <- readLines("pco.bib")
tmp[1:10]

[1] ""
[2] "@article{"
[3] "pco001,"
[4] "  Author = {Udalova, I.A. and Mott, R. and Field, D. and Kwiatkowski, D.},"
[5] "  Title = {Quantitative prediction of NF-[Kappa]B DNA-protein interactions},"
[6] "  Journal = {Proceedings of the National Academy of Sciences of the United States of America},"
[7] "  Volume = {99},"
[8] "  Number = {12},"
[9] "  Pages = {8167-8172},"
[10] " Year = {2002} }"

nlines <- length(tmp)

length(tmp)
is.vector(tmp)
mode(tmp)
```

Combien le fichier a-t-il de lignes ?

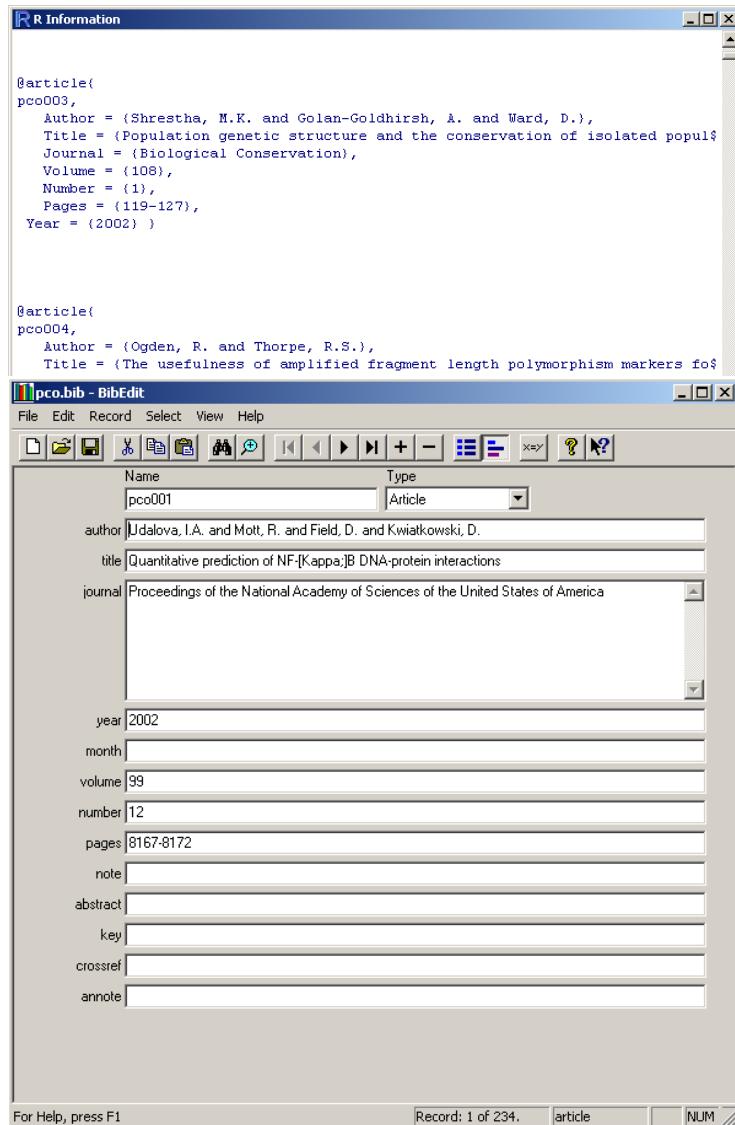


FIG. 1 – Le fichier pco.bib vu par la commande `show.file` et la première fiche vue dans le logiciel BibTex qui indique qu'il y a 234 références.

2 Recherche de chaînes de caractères

2.1 Identifier les débuts de fiche

Chaque fiche bibliographique commence par le caractère @. Identifier les numéros de lignes qui commencent par ce caractère. Noter la fonction `substr` (sous-chaîne / *sub-string*).

```
isEntryLine <- function(line) {
  substr(x = line, start = 1, stop = 1) == "@"
}
entryLines <- (1:nlines)[sapply(tmp, isEntryLine)] + 1
entryLines[1:20]
```

```
[1] 3 16 29 42 55 68 81 94 107 120 133 146 159 172 185 198 211 224 237 250
```

Récupérer les entrées :

```
entries <- sub(", ", "", tmp[entryLines])
entries[1:30]
```

```
[1] "pco001" "pco002" "pco003" "pco004" "pco005" "pco006" "pco007" "pco008" "pco009"
[10] "pco010" "pco011" "pco012" "pco013" "pco014" "pco015" "pco016" "pco017" "pco018"
[19] "pco019" "pco020" "pco021" "pco022" "pco023" "pco024" "pco025" "pco026" "pco027"
[28] "pco028" "pco029" "pco030"
```

Normalement ces entrées sont des clefs d'identification et doivent être uniques. Est-ce le cas ?

```
any(duplicated(entries))
which(duplicated(entries))
```

2.2 Trouver une chaîne de caractères

Sinon éditer les références qui ont une entrée multiple. Utiliser la fonction `grep` :

```
grep("pco152", tmp)
grep("pco154", tmp)
grep("pco354", tmp)
tmp[grep("pco154", tmp)]
tmp[1976:1990]
length(grep("Pages", tmp))
length(grep("@", tmp))
all(entryLines == grep("@", tmp) + 1)
```

Nous pouvons donc dire qu'il y a 234 entrées dans la base bibliographique, mais qu'il y a une étiquette présente deux fois. Il va falloir s'en débarasser.

2.3 Rechercher les numéros manquants

Quelle est la clef d'identification portée par la dernière fiche bibliographique ?

```
num <- grep("@", tmp) + 1
cle <- tmp[num]
cle[length(cle)]
```

Si il y a une clef utilisée deux fois, l'utilisation d'un codage naturel a laissé des clefs non utilisée. Pour chercher une chaîne de caractères, on peut utiliser cette chaîne exactement, mais rapidement se pose la question des jokers. C'est le domaine des expressions régulières. On ne fera pas le tour de la question ici, mais on indiquera juste que la fonction `grep` prend en premier argument des expressions régulières, c'est à dire des chaînes de caractères à jokers qui permettent de chercher ce qui commence par, finit par, contient ceci ou cela.

`cle` contient un vecteur de chaînes de caractères :

```
[1] "pco001," "pco002," "pco003," "pco004," "pco005," "pco006,"
[7] "pco007," "pco008," "pco009," "pco010," "pco011," "pco012,"
[13] "pco013," "pco014," "pco015," "pco016," "pco017," "pco018,"
...
...
```

Repérer quelques commandes utiles dans cette liste.

```
cle[grep("pco118",cle)] donne les composantes qui contiennent pco118;
cle[grep("pco1.1",cle)] donne les composantes qui contiennent pco11 suivi
d'un caractère unique quelconque ;
cle[grep("pco00",cle)] donne les composantes qui commencent par pco00;
cle[grep("18,$",cle)] donne les composantes qui finissent par 18;
cle[grep("pco2*",cle)] donne les composantes qui contiennent pco suivi
d'une chaîne de 2 de longueur quelconque (éventuellement nulle), suivi de
, ;
cle[grep("2+",cle)] donne les composantes qui contiennent une chaîne de
2 de longueur au moins 1;
cle[grep("pco0.+0",cle)] donne les composantes qui contiennent pco suivie
d'une chaîne non vide quelconque, suivie de 0;
cle[grep("[7-9]",cle[1 :99])] donne, parmi les 99 premières, les compo-
santes qui contiennent les caractères de 7 à 9 .
```

Rechercher les numéros manquants :

```
w1 <- paste("pco00", 1:9, sep = "")
w2 <- paste("pco0", 10:99, sep = "")
w3 <- paste("pco", 100:235, sep = "")
w <- c(w1, w2, w3)
which(sapply(w, function(x) (length(grep(x, cle)) == 0)))
```

```
pco152 pco155
      152      155
```

```
which(sapply(as.character(1:235), function(x) (length(grep(x, cle)) ==
0)))
```

```
152 155
      152 155
```

3 Substituer une chaîne de caractères à une autre

Le 152 n'est pas utilisé, le 154 l'est deux fois. On rétablit l'unicité avec :

```
tmp[num[153]] <- "pco152"
num <- grep("@", tmp) + 1
clefs <- tmp[num]
any(duplicated(clefs))
```

[1] FALSE

Question : pourquoi ne fallait-il pas utiliser la fonction `tmp <- sub("pco154", "pco152", tmp)` ?

3.1 Rechercher un auteur

Retrouver tous les **Smith** :

```
w <- tmp[grep("Smith", tmp)]
w <- sub(".*\{\", \"", w)
w <- sub("\}.*", "", w)
w <- unlist(strsplit(w, " and "))
w <- w[grep("Smith", w)]
```

[1] "Smith, D.R." "Smith, R."
[4] "Smith-Ramirez, C." "Russell-Smith, J. J." "Smith, R.W."

3.2 La distribution du nombre d'articles par auteur

Donner la distribution du nombre d'articles par auteur :

```
w <- tmp[grep("Author", tmp)]
w <- sub(".*\{\", \"", w)
w <- sub("\}.*", "", w)
w <- unlist(strsplit(w, " and "))
table(table(w))
```

1 2 3 4 6 7
716 54 10 2 1 1

Quels sont ceux qui ont le plus grand nombre d'articles dans cette bibliographie ?

3.3 La distribution du nombre d'auteurs par article

Combien d'auteurs par articles ?

4 Pour faire des citations dans L^AT_EX

Un dernier exercice, pour les amateurs de L^AT_EX : citer les 25 premiers articles de cette bibliographie :

```
outfile <- file(description = "citations.tex", open = "w")
w <- sub(";", "", clefs)
for (i in 1:30) {
  line <- paste(w[i], " : ", "\\\cite{", w[i], "}", sep = "")
  if (i%%5 != 0)
    line <- paste(line, " & ")
  else line <- paste(line, "\\\\")
  writeLines(line, outfile)
}
close(outfile)
```

```
pco001 : [25]  pco002 : [22]  pco003 : [21]  pco004 : [16]  pco005 : [15]
pco006 : [14]  pco007 : [13]  pco008 : [12]  pco009 : [11]  pco010 : [10]
pco011 : [9]   pco012 : [8]   pco013 : [7]   pco014 : [6]   pco015 : [5]
pco016 : [4]   pco017 : [3]   pco018 : [2]   pco019 : [1]   pco020 : [30]
pco021 : [29]  pco022 : [28]  pco023 : [27]  pco024 : [26]  pco025 : [24]
pco026 : [23]  pco027 : [20]  pco028 : [19]  pco029 : [18]  pco030 : [17]
```

On retiendra de ces exercices les fonctions d'entrée-sortie sur des fichiers textes (`writeLines` `readLines`), le travail sur les vecteurs de chaînes de caractères (longueur par `nchar`, substitution par `sub`, recherche de sous-chaînes par `grep` et la présence des expressions régulières.

Références

- [1] M. Ahmad. Assessment of genomic diversity among wheat genotypes as determined by simple sequence repeats. *Genome / National Research Council Canada = Genome / Conseil National de Recherches Canada*, 45(4) :646–651, 2002.
- [2] P. Ajmone-Marsan, R. Negrini, E. Milanesi, R. Bozzi, I.J. Nijman, J.B. Buntjer, A. Valentini, and J.A. Lenstra. Genetic distances within and across cattle breeds as indicated by biallelic afip markers. *Animal Genetics*, 33(4) :280–286, 2002.
- [3] G. Birmeta, H. Nybom, and E. Bekele. Rapd analysis of genetic diversity among clones of the ethiopian crop plant ensete ventricosum. *Euphytica*, 124(3) :315–325, 2002.
- [4] Daniel Borcard and Pierre Legendre. All-scale spatial analysis of ecological data by means of principal coordinates of neighbour matrices. *Ecological Modelling*, 153(1-2) :51–68, 2002.
- [5] M.C.J. Bottini, A. De Bustos, N. Jouve, and L. Poggio. Afip characterization of natural populations of berberis (berberidaceae) in patagonia, argentina. *Plant Systematics and Evolution*, 231(1-4) :133–142, 2002.
- [6] C.K. Boyce and A.H. Knoll. Evolution of developmental potential and the multiple independent origins of leaves in paleozoic vascular plants. *Paleobiology*, 28(1) :70–100, 2002.
- [7] J.B. Buntjer, M. Otsen, I.J. Nijman, M.T.R. Kuiper, and J.A. Lenstra. Phylogeny of bovine species based on afip fingerprinting. *Heredity*, 88(1) :46–51, 2002.
- [8] K.L. Burgher, A.R. Jamieson, and X. Lu. Genetic relationships among lowbush blueberry genotypes as determined by randomly amplified polymorphic dna analysis. *Journal of the American Society for Horticultural Science*, 127(1) :98–103, 2002.
- [9] K.Y. Ho, J.C. Yang, and J.Y. Hsiao. An assessment of genetic diversity and documentation of hybridization of casuarina grown in taiwan using rapd markers. *International Journal of Plant Sciences*, 163(5) :831–836, 2002.

- [10] S.Y. Hwang, Y.T. Tseng, and H.F. Lo. Application of simple sequence repeats in determining the genetic relationships of cultivars used in sweet potato polycross breeding in taiwan. *Scientia Horticulturae*, 93(3-4) :215–224, 2002.
- [11] S. Jarraud, C. Mougel, J. Thioulouse, G. Lina, H. Meugnier, F. Forey, X. Nesme, J. Etienne, and F. Vandenesch. Relationships between staphylococcus aureus genetic background, virulence factors, agr groups (alleles), and human disease. *Infection and Immunity*, 70(2) :631–641, 2002.
- [12] G. Khoo, K.F. Lim, D.K.Y. Gan, F. Chen, W.-K. Chan, T.M. Lim, and V.P.E. Phang. Genetic diversity within and among feral populations and domesticated strains of the guppy (*poecilia reticulata*) in singapore. *Marine Biotechnology*, 4(4) :367–378, 2002.
- [13] A.A. Linos, P.J. Bebeli, and P.J. Kaltsikes. Cultivar identification in upland cotton using rapd markers. *Australian Journal of Agricultural Research*, 53(6) :637–642, 2002.
- [14] F. Liu, G.-L. Sun, B. Salomon, and R. Von Bothmer. Characterization of genetic diversity in core collection accessions of wild barley, *hordeum vulgare* ssp. *spontaneum*. *Hereditas*, 136(1) :67–73, 2002.
- [15] G. Nieto Feliner, J. Fuertes Aguilar, and J.A. Rossello. Reticulation or divergence : The origin of a rare serpentine endemic assessed with chloroplast, nuclear and rapd markers. *Plant Systematics and Evolution*, 231(1-4) :19–38, 2002.
- [16] R. Ogden and R.S. Thorpe. The usefulness of amplified fragment length polymorphism markers for taxon discrimination across graduated fine evolutionary levels in caribbean anolis lizards. *Molecular Ecology*, 11(3) :437–445, 2002.
- [17] M.C. Sawkins, B.L. Maass, B.C. Pengelly, H.J. Newbury, B.V. Ford-Lloyd, N. Maxted, and R. Smith. Geographical patterns of genetic variation in two species of stylosanthes sw. using amplified fragment length polymorphism. *Molecular Ecology*, 10(8) :1947–1958, 2001.
- [18] G. Schmalisch, M. Schmidt, and B. Foitzik. Novel technique to average breathing loops for infant respiratory function testing. *Medical and Biological Engineering and Computing*, 39(6) :688–693, 2001.
- [19] F. Sebastiani, R. Meiswinkel, L.M. Gomulski, C.R. Guglielmino, P.S. Mellor, A.R. Malacrida, and G. Gasperi. Molecular differentiation of the old world culicoides imicola species complex (diptera, ceratopogonidae), inferred using random amplified polymorphic dna markers. *Molecular Ecology*, 10(7) :1773–1786, 2001.
- [20] G.E.C. Sheridan, J.R. Claxton, J.M. Clarkson, and D. Blakesley. Genetic diversity within commercial populations of watercress (*rorippa nasturtium-aquaticum*), and between allied brassicaceae inferred from rapd-pcr. *Euphytica*, 122(2) :319–325, 2001.

- [21] M.K. Shrestha, A. Golan-Goldhirsh, and D. Ward. Population genetic structure and the conservation of isolated populations of acacia raddiana in the negev desert. *Biological Conservation*, 108(1) :119–127, 2002.
- [22] J.-C. Svenning and F. Skov. Mesoscale distribution of understorey plants in temperate forest (kalo, denmark) : The importance of environment and dispersal. *Plant Ecology*, 160(2) :169–185, 2002.
- [23] P.W. Sweeney and R.A. Price. A multivariate morphological analysis of the cardamine concatenata alliance (brassicaceae). *Brittonia*, 53(1) :82–95, 2001.
- [24] L. Triest. Hybridization in staminate and pistillate salix alba and s. fragilis (salicaceae) : Morphology versus rapds. *Plant Systematics and Evolution*, 226(3-4) :143–154, 2001.
- [25] I.A. Udalova, R. Mott, D. Field, and D. Kwiatkowski. Quantitative prediction of nf-[kappa];b dna-protein interactions. *Proceedings of the National Academy of Sciences of the United States of America*, 99(12) :8167–8172, 2002.
- [26] Jean K. Whelan, Lorraine Eglinton, Mahlon C. Kennicutt, II, and Yaorong Qian. Short-time-scale (year) variations of petroleum fluids from the u.s. gulf coast. *Geochimica et Cosmochimica Acta*, 65(20) :3529–3555, 2001.
- [27] J.K. Whelan, L. Eglinton, M.C. Kennicutt II, and Y. Qian. Short-time-scale (year) variations of petroleum fluids from the u.s. gulf coast. *Geochimica et Cosmochimica Acta*, 65(20) :3529–3555, 2001.
- [28] C.D. Wilkinson and D.R. Edds. Spatial pattern and environmental correlates of a midwestern stream fish community : Including spatial autocorrelation as a factor in community analyses. *American Midland Naturalist*, 146(2) :271–289, 2001.
- [29] B. Yacoubi Loveslati, A. Sanchez-Mazas, H. Ennafaa, R. Marrakchi, J.-M. Dugoujon, M.-P. Lefranc, and A. Ben Ammar Elgaaied. A study of gm allotypes and immunoglobulin heavy gamma ighg genes in berbers, arabs and sub-saharan africans from jerba island, tunisia. *European Journal of Immunogenetics*, 28(5) :531–538, 2001.
- [30] S. Zhou, D.R. Smith, and G.R. Stanosz. Differentiation of botryosphaeria species and related anamorphic fungi using inter simple or short sequence repeat (issr) fingerprinting. *Mycological Research*, 105(8) :919–926, 2001.