



## Voir les données

D. Chessel

Notes de cours cssb2

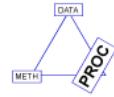
Faire des représentations graphiques de l'information fait partie de la fonction statistique : quelques exemples.

## Table des matières

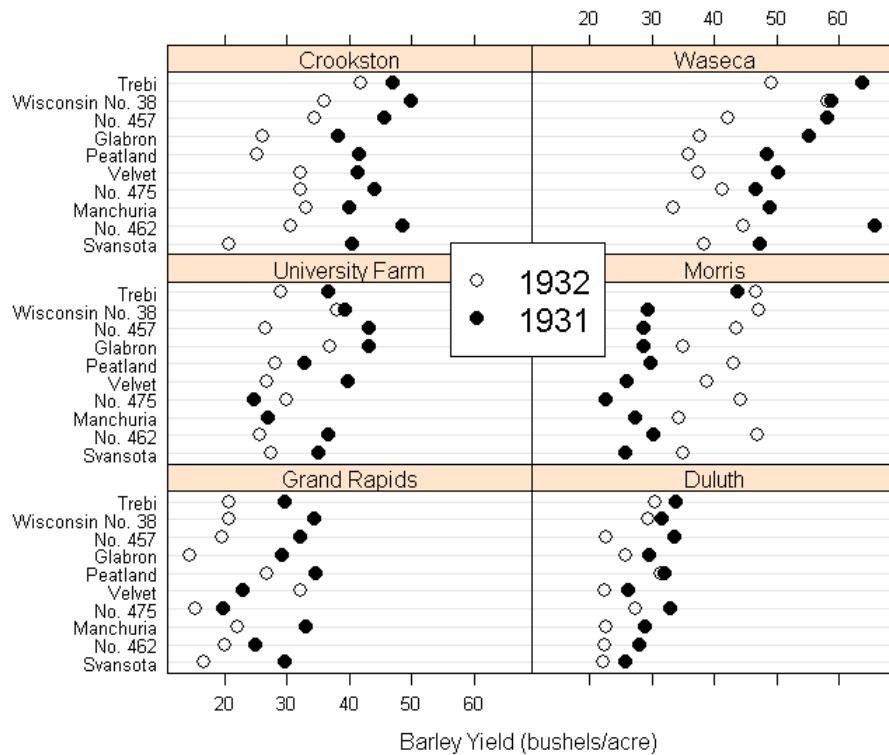
<b>1</b>	<b>Introduction</b>	<b>2</b>
<b>2</b>	<b>Représentation triangulaire</b>	<b>2</b>
<b>3</b>	<b>Courbes de niveaux</b>	<b>4</b>
<b>4</b>	<b>Tableaux</b>	<b>6</b>
<b>5</b>	<b>Tableaux de traits en codage flou</b>	<b>7</b>
<b>6</b>	<b>Tableaux de cartes</b>	<b>8</b>
<b>7</b>	<b>Phylogénies</b>	<b>9</b>
	<b>Références</b>	<b>10</b>

## 1 Introduction

Autant qu'il est possible, on cherchera à *voir* les données.



```
library(lattice)
data(barley)
dotchart(barley$yield)
dotplot(variety ~ yield | site, data = barley, groups = year, pch = c(1,
  19), cex = 1.25, col = "black", xlab = "Barley Yield (bushels/acre) ",
  aspect = 0.5, layout = c(2, 3), ylab = NULL)
legend(38, 80, pch = c(1, 19), cex = 1.5, legend = levels(barley$year),
  bg = "white")
```

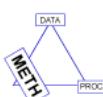


A *Trellis dotplot*, une grille de graphiques par points : la relation entre le rendement en orge (moyenne d'essai en blocs randomisés) et la variété est représentée, avec une fenêtre par site d'expérimentation et un symbole par année de mesure [4][p. 9]. Il faut lire le commentaire de B. Cleveland, l'inventeur de cette figure [3]. Où est le problème ?

## 2 Représentation triangulaire

C'est la plus simple des représentations d'une donnée à trois composantes dont la somme est fixée (il y a alors deux dimensions, ce qui suffit sur une feuille de papier). Ce procédé graphique introduit au schéma général de l'analyse des données (cartes factorielles, biplot). Pour une approche précise, voir :

<http://pbil.univ-lyon1.fr/R/fichestd/ter1.pdf>



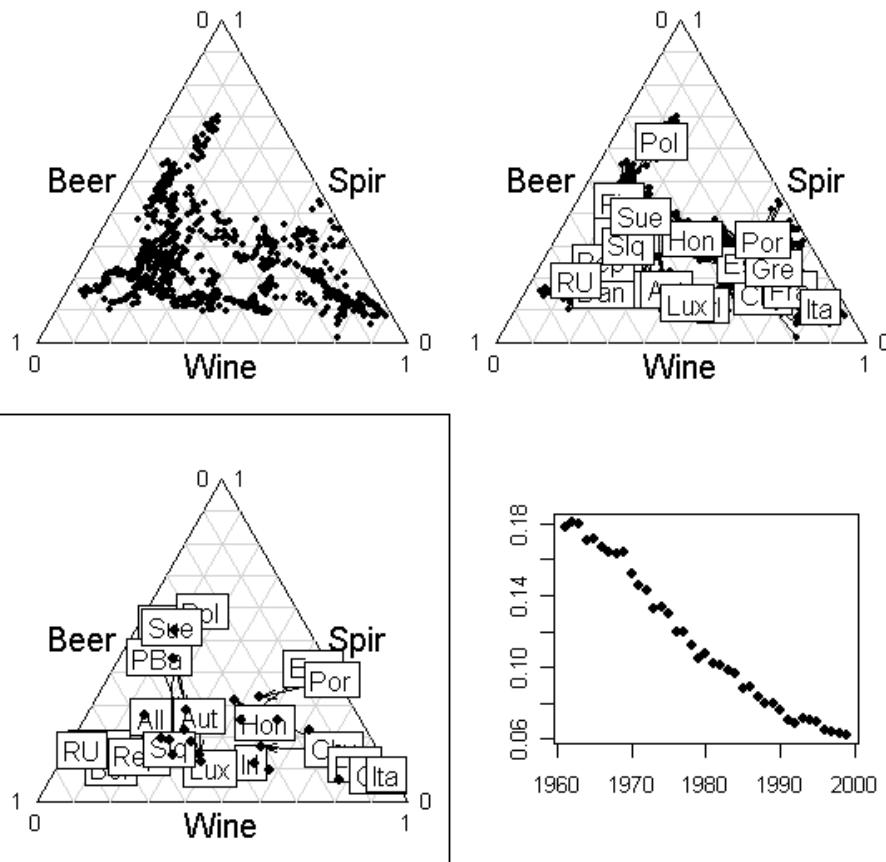
Pour un aperçu sémantique, on utilise

<http://pbil.univ-lyon1.fr/R/pps/pps066.pdf>



```

library(ade4)
load(url("http://pbil.univ-lyon1.fr/R/pps/pps066.rda"))
w <- cbind.data.frame(as.numeric(pps066$beer), as.numeric(pps066$wine),
                      as.numeric(pps066$spir))
names(w) <- c("Beer", "Wine", "Spir")
par(mfrow = c(2, 2))
xy <- as.data.frame(triangle.plot(w, show = FALSE, clab = 0))
pays <- dimnames(pps066$wine)[[1]]
pays <- rep(pays, 39)
ans <- dimnames(pps066$wine)[[2]]
ans.q <- as.numeric(ans)
ans <- rep(ans, rep(20, 39))
triangle.class(w, as.factor(pays), show = F, clab = 1.5)
triangle.plot(w, clab = 0, cpoi = 0, show = F)
s.match(xy[ans == "1961", ], xy[ans == "1999", ], clab = 0, add.p = T)
s.label(xy[ans == "1961", ], clab = 1.5, add.p = T, lab = pays[1:20])
s.label(xy[ans == "1999", ], clab = 0, add.p = T, cpoi = 2)
varprofi <- unlist(lapply(split(xy, as.factor(ans)), function(x) sum(diag(var(x)))))
plot(ans.q, varprofi, pch = 20, cex = 1.5, xlab = "", ylab = "")
  
```

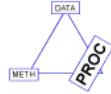


On commenterai la notion d'inertie ou variance généralisée apparue dans le script.  
Et quand il y a 4, 5, 10, 50, ..., 500 catégories, on fait quoi ?

### 3 Courbes de niveaux

C'est un procédé de modélisation graphique très simple. On trouvera des détails pratiques dans :

<http://pbil.univ-lyon1.fr/R/fichesstd/tdr26.pdf>



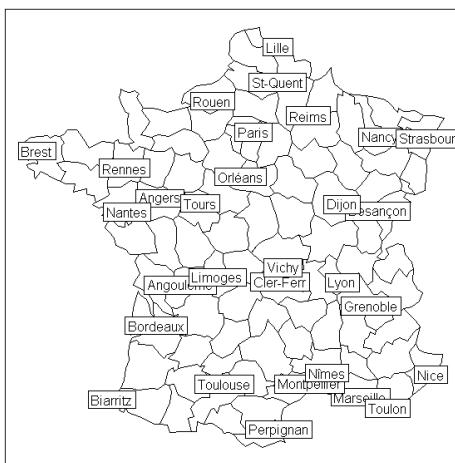
On exemple qui ne manque pas de sel. On a 30 villes :

```

library(splancs)

Le chargement a nécessité le package : sp
Spatial Point Pattern Analysis Code in S-Plus
Version 2 - Spatial and Space-Time analysis

data(t3012)
data(elec88)
area.plot(elec88$area)
s.label(t3012$xy, add.plot = T)
  
```



Le tableau de données contient les températures minimales moyennes par mois.

```

par(mfrow = c(4, 3))
for (k in 1:12) {
  w <- scalewt(t3012$temp[, k])
  s.value(t3012$xy, w, sub = names(t3012$temp)[k], csub = 3, cleg = 0,
          csize = 1.5, include.ori = F, addaxes = F, contour = elec88$contour)
  s.image(t3012$xy, w, kgrid = 3, image.plot = FALSE, add.plot = T)
}
  
```

Que voit-on (figure 1) ?

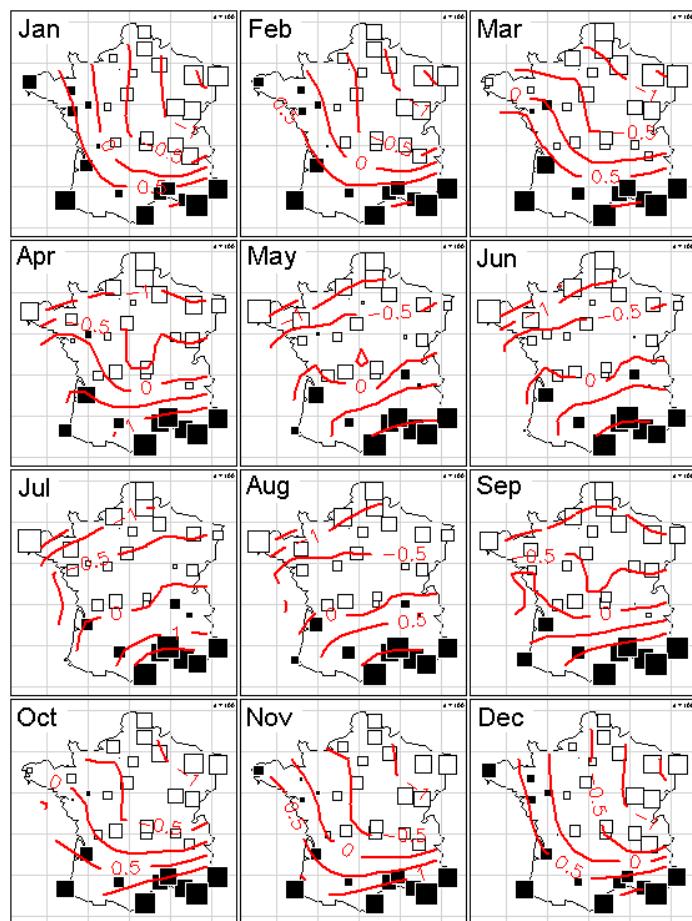
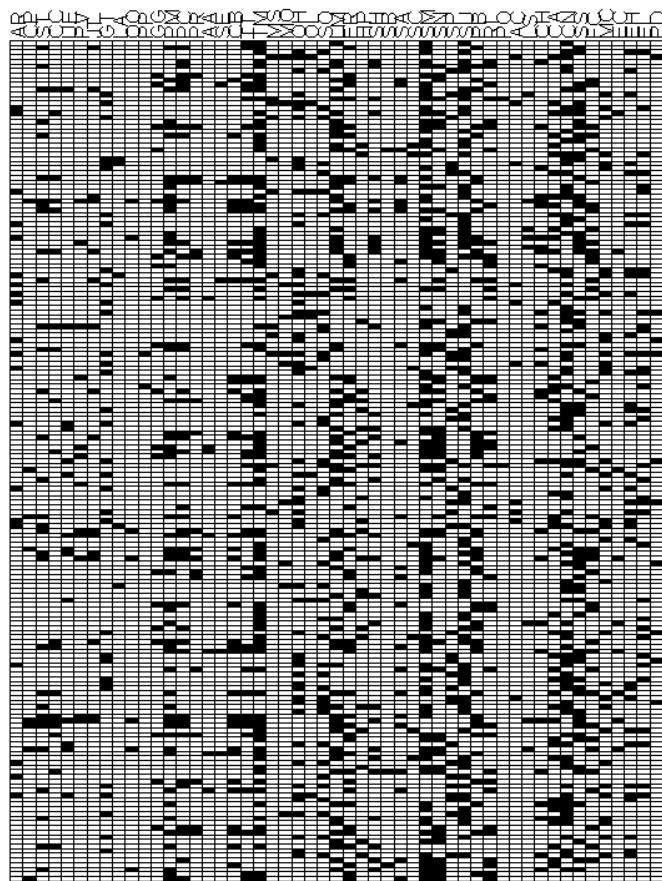


FIG. 1 – Structure spatiale de la température mensuelle moyenne sur 30 villes.

## 4 Tableaux

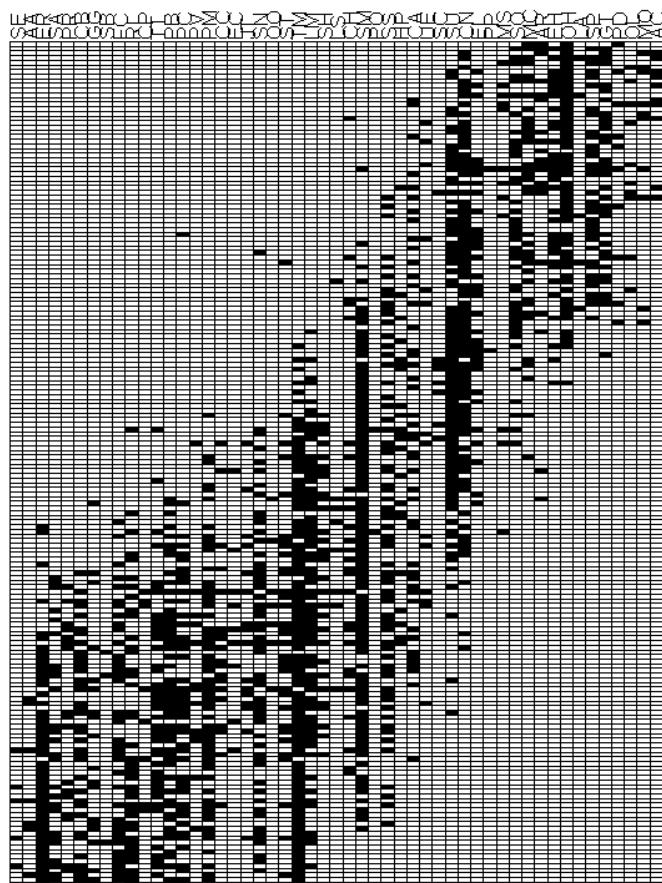
Le pionnier de la graphique scientifique est J. Bertin ([1, 2]). Peut-on voir les tableaux ? 182 relevés d'avifaune pour 51 espèces sont étudiés dans [5]. Dans un ordre quelconque :

```
data(rpjdl)
table.paint(rpjdl$fau, y = sample(1:182), clabel.r = 0, cleg = 0)
```



Question : comment ordonner les relevés pour que la structure apparaisse ?

```
w <- dudi.coa(rpjdl$fau, scann = F)
table.paint(rpjdl$fau, x = w$co[, 1], y = w$li[, 1], clabel.r = 0,
           cleg = 0)
```



A consulter Bertin Graphique sur Google Images et :

[http://www.sciences-po.fr/cartographie/seonio/graphique\\_bertin2001](http://www.sciences-po.fr/cartographie/seonio/graphique_bertin2001)

## 5 Tableaux de traits en codage flou

Une structure de données très particulière est associée au codage flou. Un exemple [6] dans :

[pbil.univ-lyon1.fr/R/querep/pps029.pdf](http://pbil.univ-lyon1.fr/R/querep/pps029.pdf)

```

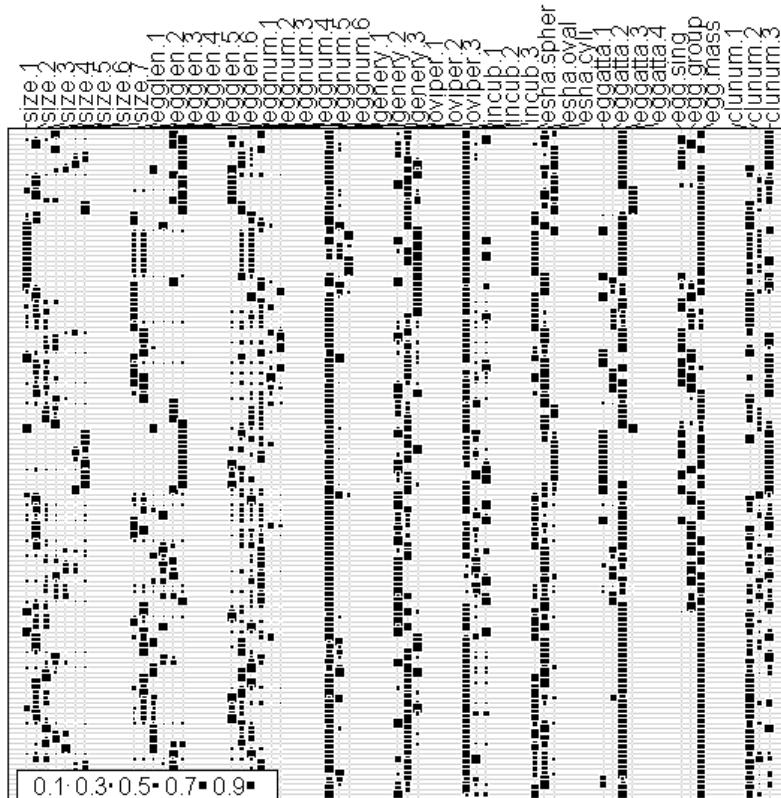
data(bsetal97)
w = bsetal97$biol.blo
ww1 = 1:sum(w)
ww0 = seq(from = 0, by = 4, len = length(w))
ww0 = rep(ww0, w) + ww1
biol.fuzzy = prep.fuzzy.var(bsetal97$biol, bsetal97$biol.blo)

17 missing data found in block 1
14 missing data found in block 2
28 missing data found in block 3
8 missing data found in block 4
5 missing data found in block 5
19 missing data found in block 6
10 missing data found in block 7
  
```



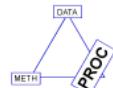
```
5 missing data found in block 8
2 missing data found in block 9
12 missing data found in block 10
```

```
table.value(biol.fuzzy, x = ww0, csi = 0.2, clabel.row = 0)
```



La figure vaut sans doute plus qu'un long discours pour poser le problème de ce type de données. Voir quelques précisions dans :

[pbil.univ-lyon1.fr/R/querep/qr9.pdf](http://pbil.univ-lyon1.fr/R/querep/qr9.pdf)



## 6 Tableaux de cartes

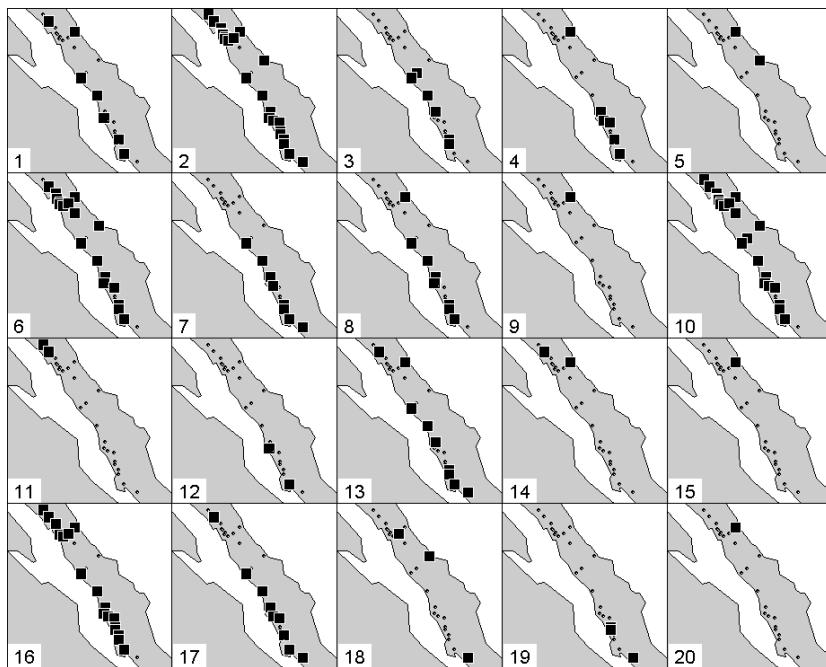
Reprendre l'exemple `cortes`.

```
par(mfrow = c(4, 5))
for (k in 1:20) {
  bkgnd()
  s.value(xy, liz[, k], add.p = T, cleg = 0, sub = as.character(k),
          csub = 3, possub = "bottomleft")
}
```

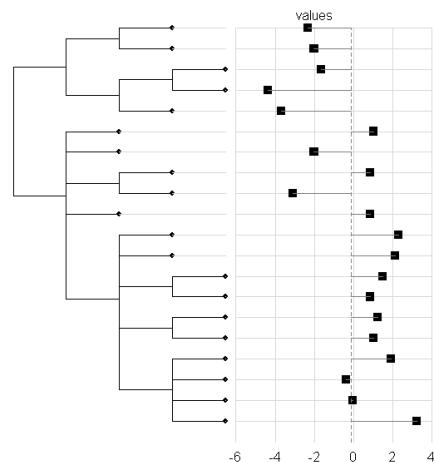
Pour poser les questions :

- ★ Y a-t-il une structure ?
- ★ Qu'est-ce qu'on doit voir ?

★ C'est significatif?



## 7 Phylogénies



Reprendre l'exemple galabiose. Représenter un arbre et un trait biologique.

```

phy1 <- newick2phylog(galabiose$tre)
n <- galabiose$rep$oui + galabiose$rep$non
trait <- galabiose$rep$oui/n
p0 <- sum(galabiose$rep$oui)/sum(galabiose$rep)
trait <- (trait - p0)/sqrt(p0 * (1 - p0)/n)
dotchart.phylog(phy1, trait, scal = F, cdot = 1.5)

```

Expliquer le calcul. Pour poser les mêmes questions !

- ★ Y a-t-il une structure ?
- ★ Qu'est-ce qu'on doit voir ?
- ★ C'est significatif ?

Pourquoi l'article cité [7] ne comporte aucune p-value ?  
On a vu quelques exemples. On en trouvera d'autres dans :

<http://pbil.univ-lyon1.fr/R/stage/stage9.pdf>

Faire des représentations de l'information fait partie de la fonction statistique.  
Ce qui permet d'exécuter ou de comprendre ces représentations fait partie des données à traiter.

## Références

- [1] J. Bertin. *Semiologie graphique : Les diagrammes-Les réseaux-Les cartes.* Gauthier-Villars, Paris, 1967.
- [2] J. Bertin. *La graphique et le traitement graphique de l'information.* Flammarion, Paris, 1973.
- [3] W.S. Cleveland. *Visualizing data.* Hobart Press, Summit, New Jersey, 1993.
- [4] P. Murrell. *R Graphics.* Computer Science & Data Analysis. Chapman & Hall/CRC, New York, 2006.
- [5] R. Prodon and J.D. Lebreton. Breeding avifauna of a mediterranean succession : the holm oak and cork oak series in the eastern pyrénées. 1 : Analysis and modelling of the structure gradient. *Oikos*, 37 :21–38, 1981.
- [6] B. Statzner, K. Hoppenhaus, M.-F. Arens, and Ph. Richoux. Reproductive traits, habitat use and template theory : a synthesis of world-wide data on aquatic insects. *Freshwater Biology*, 38 :109–135, 1997.
- [7] Noriko Suzuki, Jr. Laskowski, Michael, and Yuan C. Lee. Phylogenetic expression of galactosidase 1 on avian glycoproteins : Glycan differentiation inscribed in the early history of modern birds. *PNAS*, 101(24) :9023–9028, 2004.