

## TP 2 : Loïs continues et analyse en composantes principales

### 1 Loïs usuelles continues

#### 1.1 Densités

Tracer la densité de la loi  $\mathcal{N}(0, 1)$ . Pour cela, on peut utiliser les commandes suivantes :

```
x <- seq(from=-4, to=4, by=0.01)
y <- dnorm(x, mean=0, sd=1)
plot(x, y, type='l')
```

Tracer de même la densité des loïs suivantes :

- les loïs normales  $\mathcal{N}(1, 2)$  (de moyenne 1 et variance 2) et  $\mathcal{N}(1, 0.5)$  (sur un même graphique) ;
- la loi exponentielle  $\mathcal{E}(1)$  (quelle est sa densité?) ;
- la loi de Cauchy de paramètres 0 et 1 (quelle est sa densité?) .

#### 1.2 Fonctions de répartition

Tracer la fonction de répartition des loïs  $\mathcal{N}(0, 1)$ ,  $\mathcal{N}(-2, 1)$  et  $\mathcal{E}(2)$ .

Pour  $X$  de loi  $\mathcal{N}(0, 1)$ , calculer  $P(X \leq 2)$ ,  $P(-1 \leq X \leq 0.5)$  et trouver  $u$  tel que  $P(X \leq u) = 0.9$ .

### 2 Analyse en composantes principales

On utilise le jeu de données `iris` inclus dans R. Cet échantillon décrit, pour 150 fleurs, la longueur et la largeur du sépale et du pétale, ainsi que l'espèce parmi trois possibles (lesquelles?). Un des buts de l'étude est de séparer les trois espèces d'iris.

- Visualisation préliminaire : `View(iris)` et `pairs(iris)`. Calculer le résumé numérique : `summary(iris)`. Tracer les *boxplots* par espèce avec : `boxplot(iris$Petal.Length ~ iris$Species)`.
- Évaluer les corrélations entre les quatre caractéristiques numériques (avec la fonction `cor`).
- Évaluer l'échantillon des variables centrées réduites associées aux quatre différentes caractéristiques quantitatives (on pourra convertir en matrice `A` le `data.frame` et utiliser la commande suivante : `apply(A, MARGIN=2, FUN=sd)`).
- Évaluer la covariance de ces variables centrées réduites (avec la fonction `cov`). Comparer au résultat de la commande `cor(iris[,1:4])`. Interpréter.
- Effectuer l'analyse en composantes principales. On rappelle qu'il faut :
  - trouver les valeurs propres de la matrices des corrélations `C` des variables. En déduire combien de composantes sont nécessaires pour capturer l'essentiel des données ;
  - trouver la matrice de passage `M` de la base initiale vers la base de diagonalisation de `C` (c'est la matrice dont les colonnes sont les vecteurs propres de `C`) ;
  - obtenir les données<sup>1</sup> dans la nouvelle base des composantes principales et tracer le nouveau nuage, si possible en trois couleurs (une par espèce ; option `col='green'` pour tracer en vert) ;
  - ceci fait, représenter par un nuage de points les deux composantes principales de l'ACP puis le cercle des corrélations<sup>2</sup> pour tracer le cercle. Quelles sont les variables de départ bien représentées par ces deux composantes ?
- Calculer de deux façons la variance empirique des deux composantes principales.





---

1. Rappel : agir sur les colonnes d'une matrice, c'est multiplier à droite par une matrice : par `M` ou par `M-1` ?  
2. Première méthode : importer une fois pour toutes le paquet `plotrix` (avec `library('plotrix')`) ; si nécessaire, l'installer avec `install.packages('plotrix')` ; dans le `plot` du nuage, ajouter l'option `asp=1` ; puis tracer le cercle (avec `draw.circle(0,0,1)`). On pourra aussi utiliser `points(cos(c(1:700)/100), sin(c(1:700)/100), type="l")`.

# 1 Lois usuelles continues



## 1.1 Densités

Esquisser les diagrammes (préciser l'échelle verticale; utiliser deux couleurs).



Ci-dessus,  $\sigma_0^2$  est choisi pour que  $\mathcal{N}(0,1)$  ait le même maximum que la loi de Cauchy :  $\sigma_0^2 = \dots\dots\dots$

## 1.2 Fonctions de répartition



Si  $X \sim \mathcal{N}(0,1)$ ,  $P(X \leq 2) = \dots\dots\dots$ ;  $P(-1 \leq X \leq 0,5) = \dots\dots\dots$ ;  $P(X \leq u) = 0,9$  si  $u = \dots\dots\dots$ .

# 2 Analyse en composantes principales

Remarques sur les *boxplots* :

corrélation empirique des variables initiales					covariance emp. des variables centrées réduites				
	lng sép	lrg sép	lng pét	lrg pét		lng sép	lrg sép	lng pét	lrg pét
lng sép					lng sép				
lrg sép					lrg sép				
lng pét					lng pét				
lrg pét					lrg pét				

Rôle de la fonction **cor** :

Valeurs propres de la matrice des corrélations :  $\lambda_1 \simeq \dots\dots\dots$ ;  $\lambda_2 \simeq \dots\dots\dots$ ;  $\lambda_3 \simeq \dots\dots\dots$ ;  $\lambda_4 \simeq \dots\dots\dots$ .

