

# Análisis de Componentes Principales (ACP)

## La Selección Natural (en Gorriones)

Estudio R

Octubre de 2017

- Generalidades ACP

# Contenido

- Generalidades ACP
- Objetivos del ACP

# Contenido

- Generalidades ACP
- Objetivos del ACP
- Algunas aplicaciones

# Contenido

- Generalidades ACP
- Objetivos del ACP
- Algunas aplicaciones
- Interpretación geométrica

# Contenido

- Generalidades ACP
- Objetivos del ACP
- Algunas aplicaciones
- Interpretación geométrica
- Interpretación algebraica

# Contenido

- Generalidades ACP
- Objetivos del ACP
- Algunas aplicaciones
- Interpretación geométrica
- Interpretación algebraica
- Ejemplo e implementación en R

# Contenido

- Generalidades ACP
- Objetivos del ACP
- Algunas aplicaciones
- Interpretación geométrica
- Interpretación algebraica
- Ejemplo e implementación en R
- Datos de gorriones

# Contenido

- Generalidades ACP
- Objetivos del ACP
- Algunas aplicaciones
- Interpretación geométrica
- Interpretación algebraica
- Ejemplo e implementación en R
- Datos de gorriones
- Matriz de correlación

# Contenido

- Generalidades ACP
- Objetivos del ACP
- Algunas aplicaciones
- Interpretación geométrica
- Interpretación algebraica
- Ejemplo e implementación en R
- Datos de gorriones
- Matriz de correlación
- Estandarización

# Contenido

- Generalidades ACP
- Objetivos del ACP
- Algunas aplicaciones
- Interpretación geométrica
- Interpretación algebraica
- Ejemplo e implementación en R
- Datos de gorriones
- Matriz de correlación
- Estandarización
- Graficación (Biplot)

# Generalidades ACP

- El ACP se constituye como una técnica exploratoria, en etapas iniciales del análisis de los datos.

# Generalidades ACP

- El ACP se constituye como una técnica exploratoria, en etapas iniciales del análisis de los datos.
- Su propósito fundamental es reducir la dimensionalidad de un conjunto de datos.

# Generalidades ACP

- El ACP se constituye como una técnica exploratoria, en etapas iniciales del análisis de los datos.
- Su propósito fundamental es reducir la dimensionalidad de un conjunto de datos.
- Transforma las variables originales en un conjunto de variables más pequeñas, las cuales son combinaciones lineales de las variables originales y retienen la mayor parte de la variabilidad presente en las variables originales.

# Generalidades ACP

- El ACP se constituye como una técnica exploratoria, en etapas iniciales del análisis de los datos.
- Su propósito fundamental es reducir la dimensionalidad de un conjunto de datos.
- Transforma las variables originales en un conjunto de variables más pequeñas, las cuales son combinaciones lineales de las variables originales y retienen la mayor parte de la variabilidad presente en las variables originales.
- Convierte un conjunto de variables posiblemente correlacionadas, en un conjunto de variables sin correlación lineal, denominadas *Componentes Principales (CP)*.

# Objetivos del ACP

- Obtener nuevas variables (componentes principales) que expresen la información contenida en los datos originales.

# Objetivos del ACP

- Obtener nuevas variables (componentes principales) que expresen la información contenida en los datos originales.
- Reducir la dimensionalidad de los datos.

# Objetivos del ACP

- Obtener nuevas variables (componentes principales) que expresen la información contenida en los datos originales.
- Reducir la dimensionalidad de los datos.
- Eliminar variables (si existe la posibilidad) que tengan poco aporte al objetivo del estudio.

# Objetivos del ACP

- Obtener nuevas variables (componentes principales) que expresen la información contenida en los datos originales.
- Reducir la dimensionalidad de los datos.
- Eliminar variables (si existe la posibilidad) que tengan poco aporte al objetivo del estudio.
- Reconocer intuitivamente posibles patrones presentes en los datos.

# Objetivos del ACP

- Obtener nuevas variables (componentes principales) que expresen la información contenida en los datos originales.
- Reducir la dimensionalidad de los datos.
- Eliminar variables (si existe la posibilidad) que tengan poco aporte al objetivo del estudio.
- Reconocer intuitivamente posibles patrones presentes en los datos.
- Contribuir a la interpretación de la información que poseen los datos.

# Algunas aplicaciones

- Mecánica

# Algunas aplicaciones

- Mecánica
- Genómica

# Algunas aplicaciones

- Mecánica
- Genómica
- Inteligencia Artificial

# Algunas aplicaciones

- Mecánica
- Genómica
- Inteligencia Artificial
- Economía

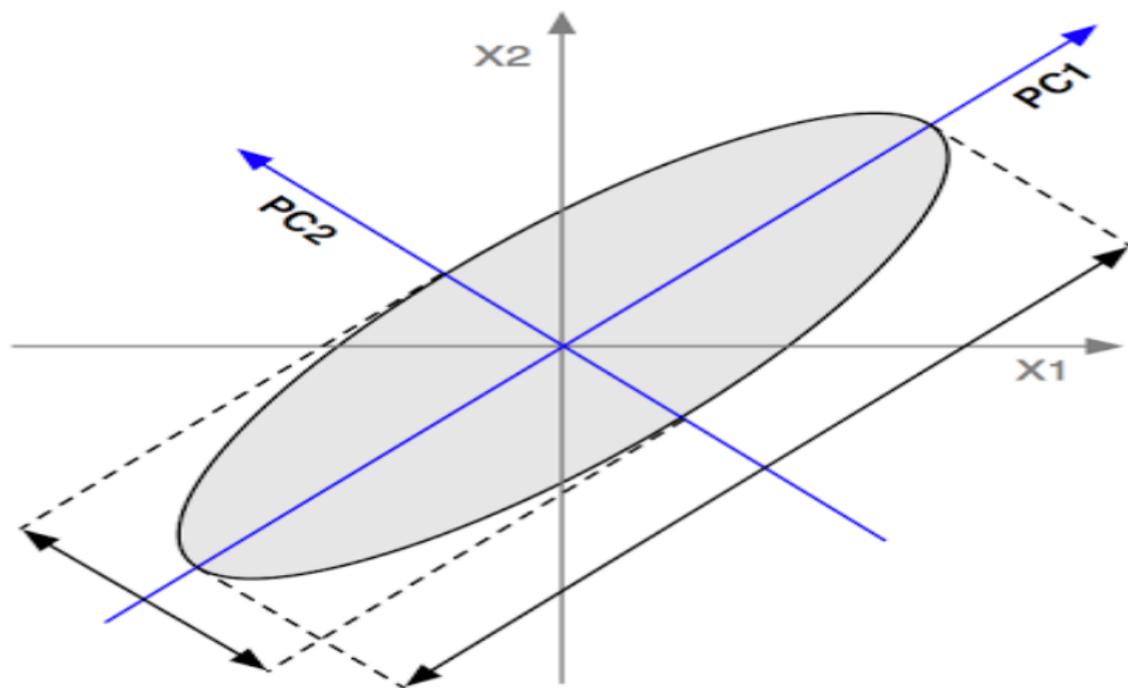
# Algunas aplicaciones

- Mecánica
- Genómica
- Inteligencia Artificial
- Economía
- Estudios sociales

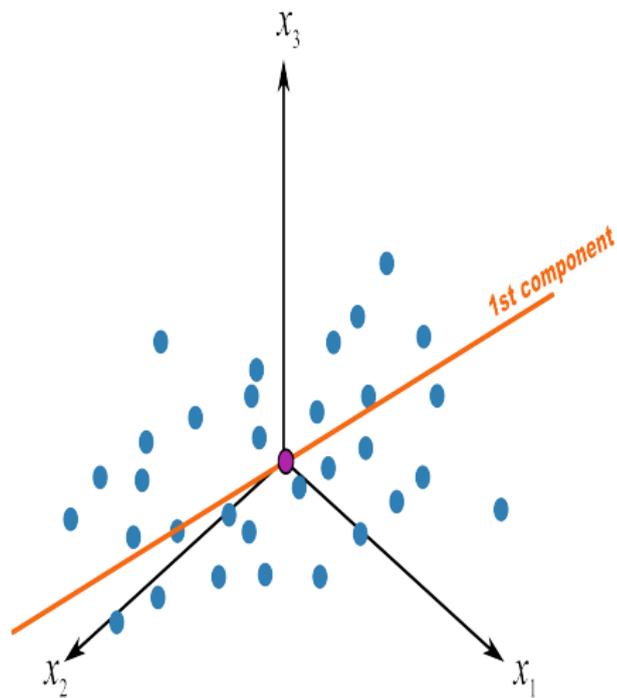
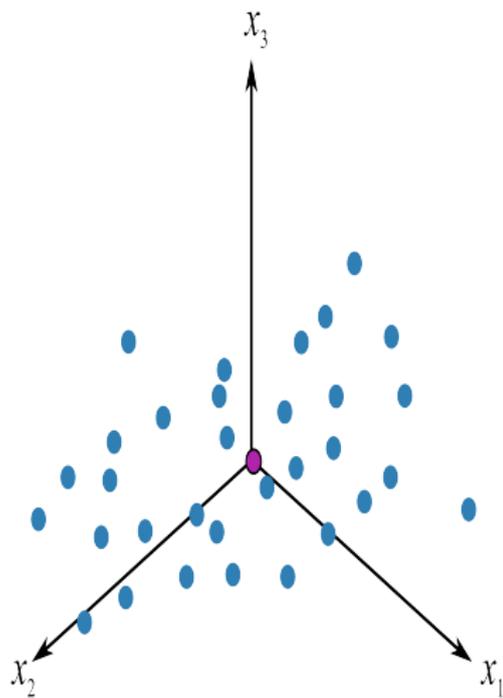
# Algunas aplicaciones

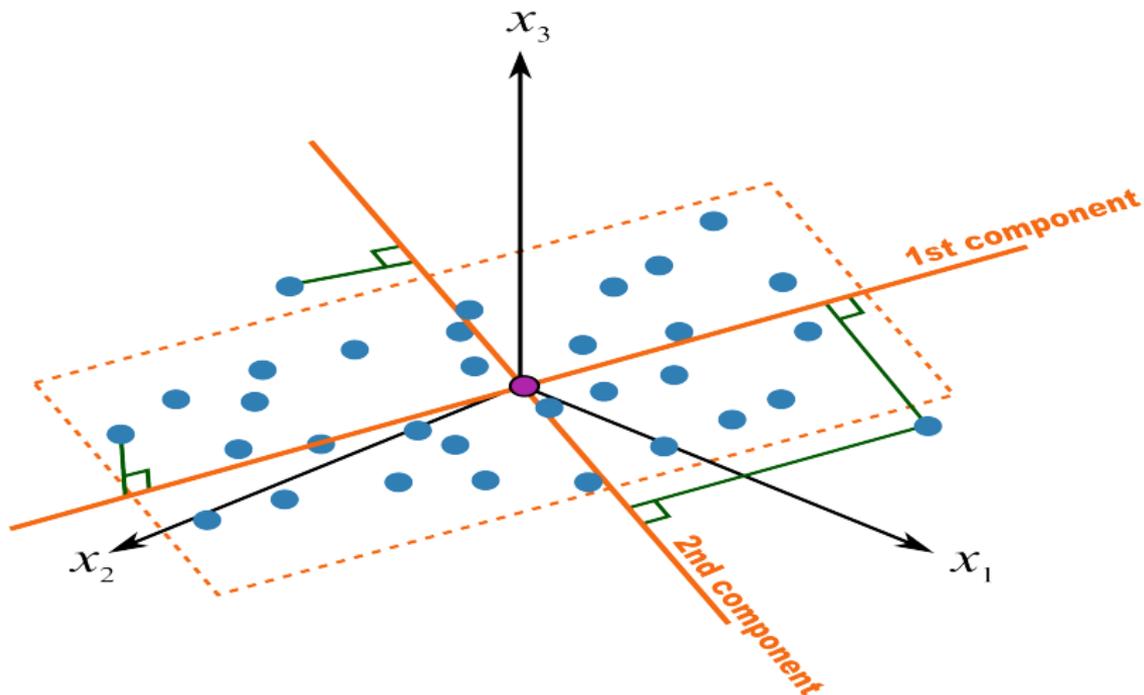
- Mecánica
- Genómica
- Inteligencia Artificial
- Economía
- Estudios sociales
- Análisis de imagen

# Interpretación geométrica



- Nuevo sistema de coordenadas.
- Obtención de direcciones ortogonales (o componentes principales) con máxima variabilidad.
- Las nuevas direcciones proporcionan una dispersión simple y parsimoniosa de la estructura de covarianza de los datos.
- Las *componentes principales* dependen de la matriz de varianzas-covarianzas o de la matriz de correlación.





# Interpretación algebraica

- Las componentes principales son combinaciones lineales particulares de  $p$ – variables aleatorias  $X_1, X_2, \dots, X_p$  originales.
- Valores propios
- Vectores propios

## Ejemplo e implementación en R

**Descripción del conjunto de datos (Gorriones.csv):** " ... el 1 de febrero del presente año (1898), cuando, después de una tormenta extraordinariamente severa de nieve, lluvia y aguanieve, varios gorriones ingleses fueron llevados al Laboratorio Anatómico de la Universidad de Brown. Setenta y dos de estas aves revivieron; sesenta y cuatro perecieron; ... " " ... la tormenta fue de larga duración, y las aves fueron recogidas, no en una localidad, sino en varias localidades; ... ". **Este evento fue descrito por Hermon Bumpus (1898) como un ejemplo clásico de la selección natural en acción.**

## Descripción de variables

- Sexo: Machos (m) y hembras (f)
- Edad: Adulto (a) y joven (y)
- Sobrevivió: Sí (SI) y no (NO)
- Longitud total (mm): LongitudTotal (desdel la punta del pico hasta la punta de la cola)
- Extensión de las alas (mm): ExteAlas (de punta a punta de las alas extendidas)
- Peso (gr): peso del ave
- Longitud del pico y la cabeza (mm): LonPicoCabe
- Longitud del húmero (pulgadas): LonHumero
- Longitud del fémur (pulgadas): LonFemur
- Longitud de tibia-tarso (pulgadas): LonTibTarso
- Ancho del cráneo (pulgadas): AncCraneo
- Longitud de la quilla (pulgadas): LonQuilla

## Lectura de datos

```
datos <- read.csv(file = "Gorriones.csv", dec = ",")  
head(datos, n = 3)
```

```
##      Sexo Edad Sobrevivio LongitudTotal ExteAlas  
## 1      m   a           SI           154       241  
## 2      m   a           NO           165       240  
## 3      m   a           NO           160       245  
##      Peso LonPicoCabe LonHumero LonFemur LonTibTarso  
## 1 24.5           31.2      0.687      0.668      1.022  
## 2 26.5           31.0      0.738      0.704      1.095  
## 3 26.1           32.0      0.736      0.709      1.109  
##      AncCraneo LonQuilla  
## 1      0.587      0.830  
## 2      0.606      0.847  
## 3      0.611      0.842
```

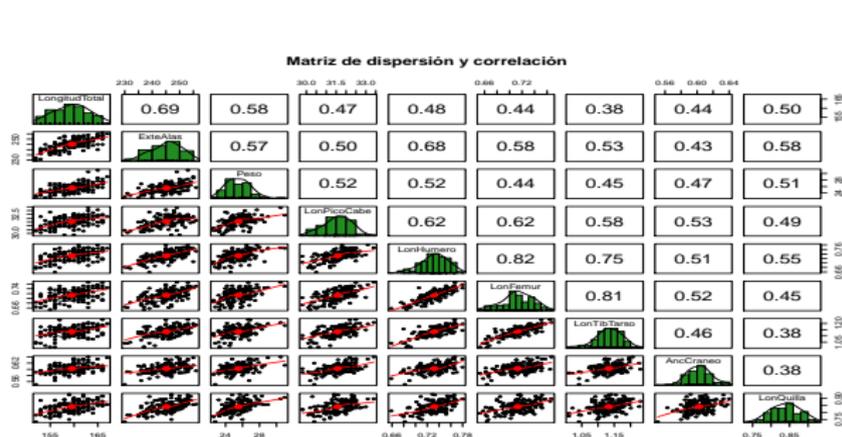
## Resumen de datos

```
summary(datos[, 4:12])
```

```
## LongitudTotal      ExteAlas      Peso
## Min.      :152.0    Min.      :230.0    Min.      :22.60
## 1st Qu.:157.0    1st Qu.:242.0    1st Qu.:24.57
## Median :160.0    Median :246.0    Median :25.55
## Mean   :159.5    Mean   :245.2    Mean   :25.52
## 3rd Qu.:162.0    3rd Qu.:249.0    3rd Qu.:26.50
## Max.   :167.0    Max.   :256.0    Max.   :31.00
## LonPicoCabe      LonHumero
## Min.      :29.80    Min.      :0.6590
## 1st Qu.:31.10    1st Qu.:0.7177
## Median :31.60    Median :0.7330
## Mean   :31.57    Mean   :0.7319
## 3rd Qu.:32.02    3rd Qu.:0.7482
## Max.   :33.40    Max.   :0.7800
```

# Matriz de correlación (gráfico)

```
color <- c("darkblue", "darkred")
library(psych)
pairs.panels(datos[,4:12], bg = color[datos$Sexo],
             hist.col = "forestgreen", density = TRUE,
             main = "Matriz de dispersión y correlación")
```



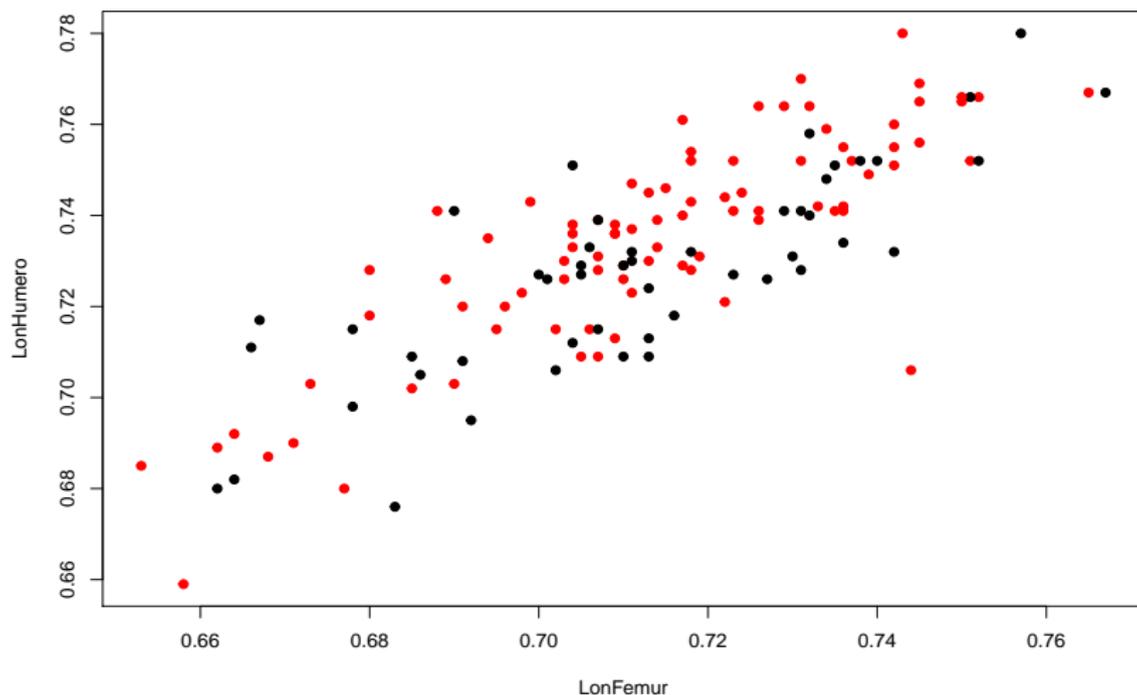
## Matriz de correlaciones

```
cor(datos[, 4:12])
```

```
##           LongitudTotal  ExteAlas      Peso
## LongitudTotal    1.0000000 0.6909709 0.5838648
## ExteAlas         0.6909709 1.0000000 0.5686500
## Peso             0.5838648 0.5686500 1.0000000
## LonPicoCabe      0.4694466 0.4990738 0.5192088
## LonHumero        0.4846190 0.6779536 0.5188943
## LonFemur         0.4447051 0.5782836 0.4441451
## LonTibTarso     0.3776146 0.5316798 0.4544589
## AncCraneo        0.4355363 0.4338913 0.4714846
## LonQuilla        0.5008898 0.5801525 0.5126353
##           LonPicoCabe LonHumero  LonFemur
## LongitudTotal    0.4694466 0.4846190 0.4447051
## ExteAlas         0.4990738 0.6779536 0.5782836
## Peso             0.5192088 0.5188943 0.4441451
```

# Longitud Húmero vs Longitud Fémur

```
with(datos, plot(LonFemur, LonHumero, pch = 19, col = Sexo))
```



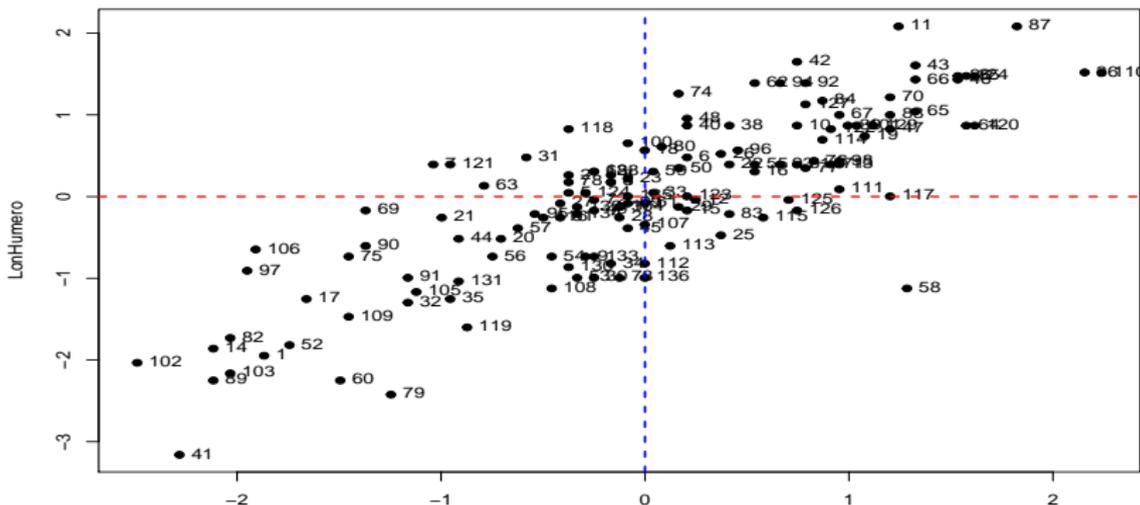
## Estandarización de variables

```
datosstd <- data.frame(scale(datos[, 4:12]))  
head(datosstd, n = 3)
```

```
##      LongitudTotal      ExteAlas      Peso LonPicoCabe  
## 1      -1.5569728 -0.7591304 -0.6948140  -0.5328548  
## 2       1.5321934 -0.9402562  0.6609206  -0.8176024  
## 3       0.1280269 -0.0346270  0.3897737   0.6061354  
##      LonHumero      LonFemur LonTibTarso  AncCraneo  
## 1 -1.9473421 -1.8674102  -2.7381900 -1.0321527  
## 2  0.2625343 -0.3744578  -0.9465370  0.2348699  
## 3  0.1758725 -0.1671033  -0.6029324  0.5682969  
##      LonQuilla  
## 1 -0.25054259  
## 2  0.17821720  
## 3  0.05211138
```

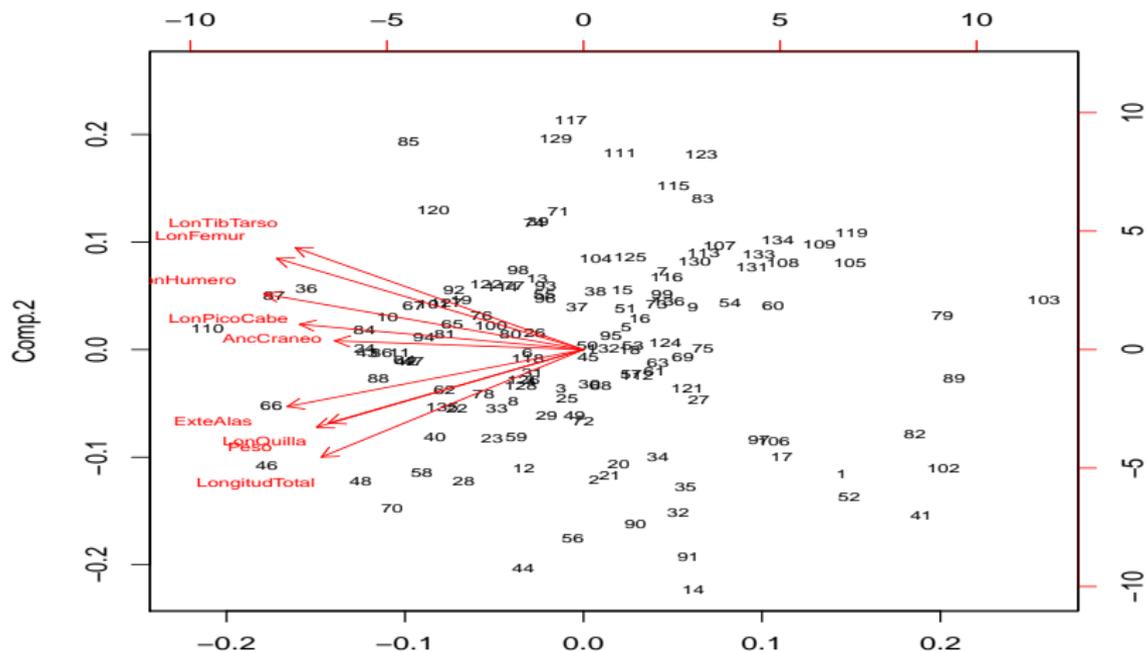
# Longitud Húmero vs Longitud Fémur (estandarizadas)

```
with(datosstd, plot(LonFemur, LonHumero, pch = 19))  
with(datosstd, text(LonFemur, LonHumero,  
                    rownames(datosstd), pos = 4))  
abline(h = 0, col = "red", lty = 2, lwd = 2)  
abline(v = 0, col = "blue", lty = 2, lwd = 2)
```



## Cálculo de las *componentes principales*

```
acp <- princomp(datosstd, cor = TRUE)
biplot(acp, cex = 0.7)
```



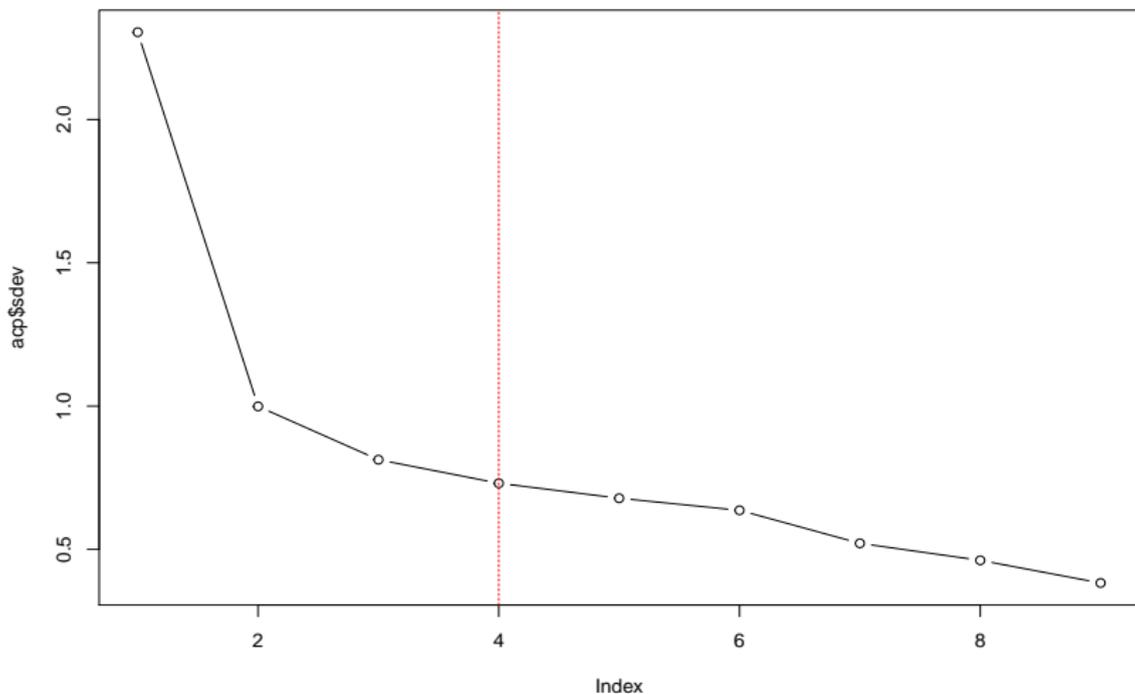
# Valores propios

```
summary(acp)
```

```
## Importance of components:
```

```
##           Comp.1      Comp.2
## Standard deviation  2.3046882 0.9988978
## Proportion of Variance 0.5901764 0.1108663
## Cumulative Proportion 0.5901764 0.7010427
##           Comp.3      Comp.4
## Standard deviation  0.81280426 0.73068317
## Proportion of Variance 0.07340564 0.05932199
## Cumulative Proportion 0.77444838 0.83377037
##           Comp.5      Comp.6
## Standard deviation  0.67837980 0.63624854
## Proportion of Variance 0.05113324 0.04497913
## Cumulative Proportion 0.88490361 0.92988274
##           Comp.7      Comp.8
```

```
plot(acp$sdev, type="b")  
abline(v = 4, col = "red", lty = 2, lwd = 0.5)
```



# Vectores propios

```
loadings(acp)[,1:9]
```

```
##           Comp.1      Comp.2      Comp.3
## LongitudTotal -0.3100651 -0.48676787 -0.05636978
## ExteAlas      -0.3505712 -0.25833261 -0.33786910
## Peso          -0.3155630 -0.35142457  0.19791968
## LonPicoCabe   -0.3358877  0.11469994  0.29286266
## LonHumero     -0.3779134  0.25196559 -0.22209147
## LonFemur      -0.3628170  0.41308546 -0.14264156
## LonTibTarso   -0.3408942  0.46175891 -0.15231419
## AncCraneo     -0.2946541  0.03996533  0.78349062
## LonQuilla     -0.3017853 -0.33274799 -0.22582687
##           Comp.4      Comp.5      Comp.6
## LongitudTotal  0.45377621  0.1326996  0.36031440
## ExteAlas       0.25610634  0.2419548  0.02384397
## Peso           0.07935593 -0.7038798 -0.46084211
```

# Puntajes

```
head(acp$scores, n = 3)
```

```
##           Comp.1      Comp.2      Comp.3      Comp.4
## [1,]  3.8880757 -1.3522616  0.4160354 -1.1326393
## [2,]  0.1575123 -1.4096787  0.4072278  0.4664938
## [3,] -0.3388752 -0.4201252  0.7720830 -0.2187090
##           Comp.5      Comp.6      Comp.7      Comp.8
## [1,] -0.09606579  0.3027823 -0.9560481  0.1354796
## [2,]  0.09095160 -0.3538219  1.1263744  1.2205056
## [3,] -0.07081691  0.2364849 -0.3398357  0.4256793
##           Comp.9
## [1,]  0.61889581
## [2,] -0.53167046
## [3,] -0.03965116
```

## Concatenando resultados (por CP1)

```
datos2 <- data.frame(datos, acp$scores[, c(1, 2, 3)])  
a <- datos2[order(acp$scores[, 1], decreasing = TRUE), ]  
head(a, n = 3)
```

```
##      Sexo Edad Sobrevivio LongitudTotal ExteAlas  
## 103    f      NO          152          230  
## 89     f      NO          153          231  
## 102    m     y     SI          155          237  
##      Peso LonPicoCabe LonHumero LonFemur  
## 103 22.8          30.4    0.682    0.664  
## 89 23.9          30.1    0.680    0.662  
## 102 23.3          30.2    0.685    0.653  
##      LonTibTarso AncCraneo LonQuilla  Comp.1  
## 103      1.042      0.551      0.734 6.930919  
## 89      1.042      0.592      0.781 5.583038  
## 102      1.011      0.587      0.794 5.420028
```

## CP1 vs CP2 (código\_1...)

```
color <- c("magenta4", "#66A61E")
simbolos <- c(15, 17)
with(datos2, plot(Comp.1, Comp.2, col = color[Sexo],
                 pch = simbolos[Sobrevivio],
                 cex = 1.5, xlab = "CP1",
                 ylab = "CP2",
                 main = "Grupo de aves sobre las componentes principales"))
```

## CP1 vs CP2 (código\_2...)

```
legend("topleft",
      legend = c("Hembra", "Macho"),
      col = color,
      cex = 1,
      lty =1,
      lwd =2)

legend("topright",
      legend = c("Murió", "Sobrevivió"),
      pch = simbolos,
      col = "black",
      cex = 1)

abline(h = 0, col = "red")
abline(v = 0, col = "red")
```

## CP1 vs CP2 (código\_3)

```
arrows(0, 0,  
       acp$loadings[, 1]*5,  
       acp$loadings[, 2]*5,  
       col = "red",  
       lwd = 2.5)  
text(acp$loadings[, 1]*5.2,  
     acp$loadings[, 2]*5.2,  
     row.names(acp$loadings),  
     cex = 1.3)
```

# Aves proyectadas sobre las componentes principales 1 y 2

