

# Aula Prática 1 - Análise Multivariada e Aprendizado Não-Supervisionado

Cibele Russo

15/10/2020

## Prática 1

A Análise de Componentes principais é uma ferramenta bastante útil para a redução de dimensionalidade e compressão de imagens. Uma aplicação vem do reconhecimento de dígitos em códigos de endereçamento postal (CEP, ou ZIP, em inglês). Os dados a seguir são descritos em Friedman, Jerome, Trevor Hastie, and Robert Tibshirani. The elements of statistical learning. Vol. 1. No. 10. New York: Springer series in statistics, 2001.

O objeto zip.train disponível na library ElemStatLearn ('<https://cran.r-project.org/src/contrib/Archive/ElemStatLearn/>') consiste em 7291 observações e 257 variáveis, sendo primeira coluna o dígito representado pelas demais colunas, que são os elementos de uma matriz de pixels  $16 \times 16$ .

1. Desenvolva a Análise de Componentes Principais para os dados disponíveis em zip.train. Observe que a primeira coluna indica o numeral representado pelas demais 256 colunas de cada observação.
2. Escolha o número de componentes principais e justifique a sua escolha.
3. Reproduza algumas imagens do banco de dados utilizando somente as componentes que achar necessárias. Utilize alguns dos comandos sugeridos a seguir e acrescente o que achar necessário.

```
#install.packages("ElemStatLearn", 'kableExtra', 'nnet')
library(ElemStatLearn)
library(kableExtra)
library(nnet)

findRows <- function(zip, n) {
  # Find n (random) rows with zip representing 0,1,2,...,9
  res <- vector(length=10, mode="list")
  names(res) <- 0:9
  ind <- zip[,1]
  for (j in 0:9) {
    res[[j+1]] <- sample(which(ind==j), n)
  }
  return(res)
}

# Making a plot like that on page 4:

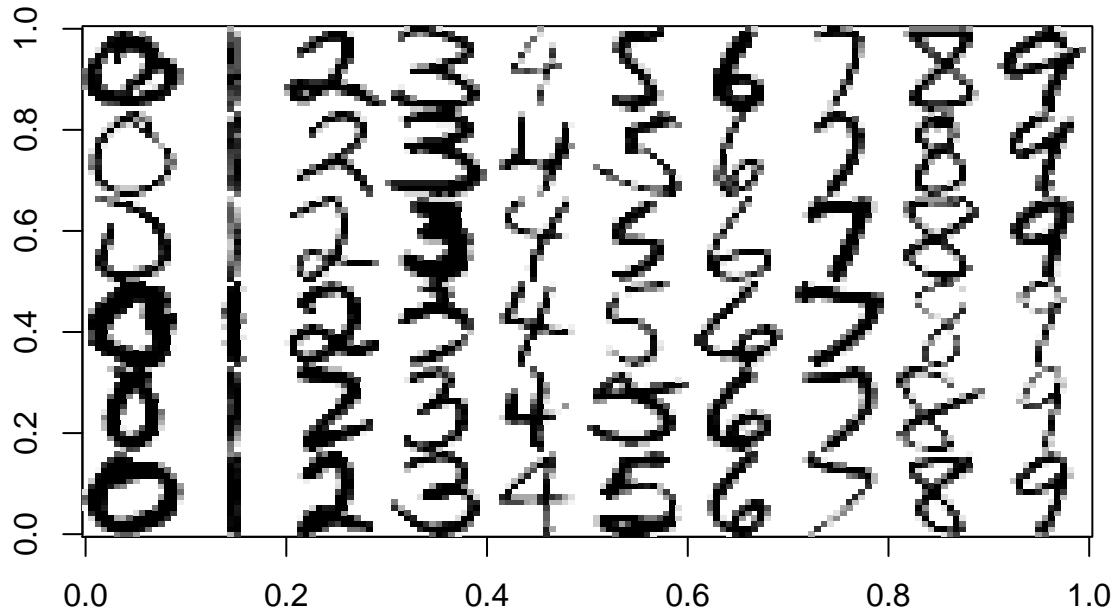
digits <- vector(length=10, mode="list")
names(digits) <- 0:9
rows <- findRows(zip.train, 6)
for (j in 0:9) {
  digits[[j+1]] <- do.call("cbind",
                            lapply(as.list(rows[[j+1]]),
                                  function(x) zip2image(zip.train, x)))
}
```



```

## [1] "digit 9 taken"
im <- do.call("rbind", digits)
image(im, col=gray(256:0/256), zlim=c(0,1), xlab="", ylab="" )

```



### Análise de Componentes Principais

```

pca<- prcomp(zip.train[,-1])
R<- pca$sdev

```

Autovalores e proporção da variância explicada dos componentes principais (CP) (Apresentamos as 15 primeiras CP).

```

v1<- round(R^2 / sum(R^2), 3) #proporção da variância explicada
v2<- cumsum((R^2 / sum(R^2)))
kable(data.frame(paste("CP", 1: 15), v1[1:15], v2[1:15]),
      col.names = c("CP", "Proporção Variância Explicada", "Acumulada"),
      align = "c") %>% kable_styling(position = "center", font_size = 12)

```

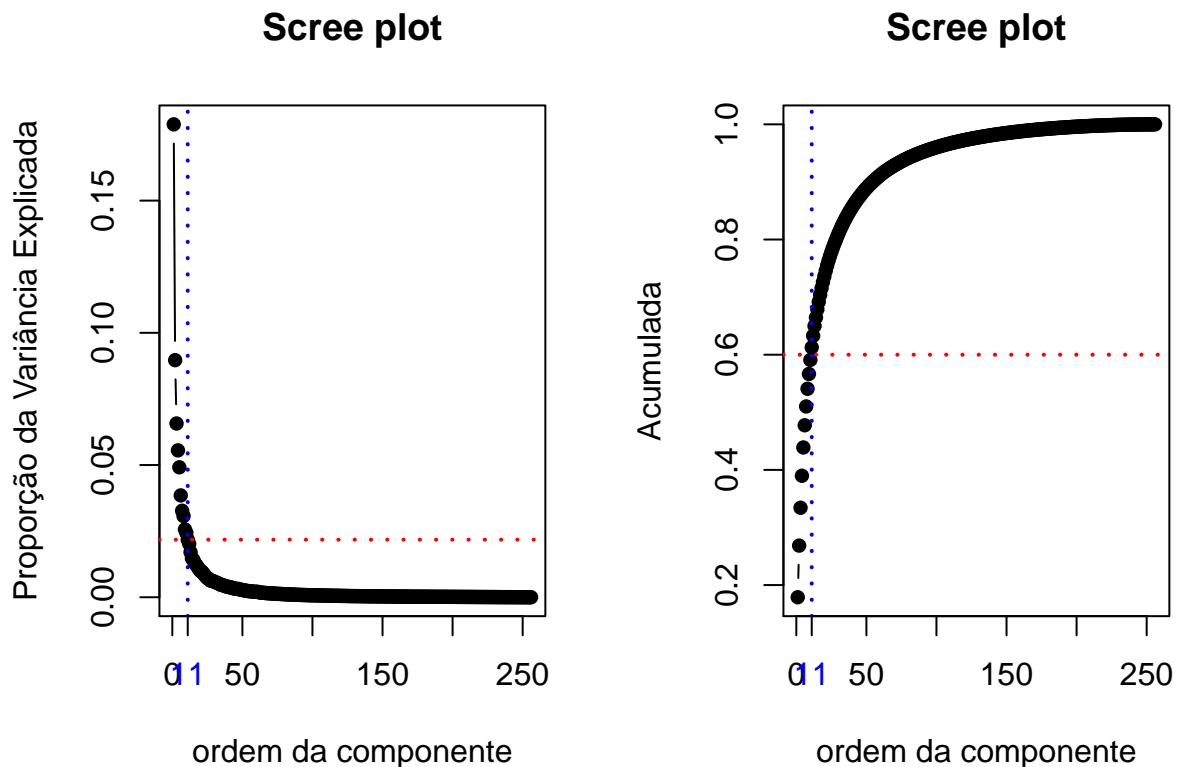
CP	Proporção Variância Explicada	Acumulada
CP 1	0.179	0.1788442
CP 2	0.090	0.2685146
CP 3	0.066	0.3342319
CP 4	0.056	0.3897774
CP 5	0.049	0.4389193
CP 6	0.039	0.4774385
CP 7	0.033	0.5101490
CP 8	0.031	0.5408593
CP 9	0.026	0.5665276
CP 10	0.024	0.5908946
CP 11	0.022	0.6126697
CP 12	0.020	0.6328776
CP 13	0.017	0.6499137
CP 14	0.015	0.6646049
CP 15	0.014	0.6787671

Scree-plot para auxiliar determinar quantas CP serão selecionadas

```
par(mfrow=c(1,2))

aux<- R^2 / sum(R^2)
plot(aux, type="b", pch=16, main="Scree plot", ylab="Proporção da Variância Explicada",
     xlab="ordem da componente")
abline(h = aux[11], v = 11, col=c("red","blue"), lwd=2, lty= 3)
axis(1, at= 11, labels=11, col.axis="blue")

plot(cumsum(R^2 / sum(R^2)), type="b", pch=16,
      main="Scree plot", ylab="Acumulada", xlab="ordem da componente")
abline(h = 0.6, v = 11, col=c("red","blue"), lwd=2, lty= 3)
axis(1, at= 11, labels=11, col.axis="blue")
```



```
pca1<- prcomp(zip.train[,-1], rank. = 11)
#round(cor(pca1$x)) # cp são não correlacionados
```

Escores das componentes para a base de treino

```
new <- predict(pca1, zip.train[,-1])
new <- data.frame(num=zip.train[,1], new)
```

Classificação via modelo multinomial via redes neurais com matriz de confusão (Exercício)

```
modelo<- multinom(num~, data=new)
```

```
## # weights: 130 (108 variable)
## initial value 16788.147913
## iter 10 value 3409.221249
## iter 20 value 3005.782809
## iter 30 value 2849.235523
## iter 40 value 2658.968795
## iter 50 value 2581.380623
## iter 60 value 2518.023414
## iter 70 value 2446.482745
## iter 80 value 2422.956867
## iter 90 value 2404.252720
## iter 100 value 2389.102190
## final value 2389.102190
## stopped after 100 iterations
```

```

p<- predict(modelo, new)

##
##   0   1   2   3   4   5   6   7   8   9
## 0 1138 0 14 2 2 18 8 1 4 3
## 1 1002 0 1 0 5 0 4 0 4 5
## 2 13 0 638 9 15 8 26 5 9 0
## 3 4 0 11 584 0 30 0 0 15 2
## 4 4 0 28 1 559 15 3 3 9 25
## 5 18 1 6 34 2 440 4 4 21 8
## 6 13 0 14 0 16 15 615 0 2 0
## 7 0 0 5 2 2 0 0 594 2 40
## 8 4 2 14 23 9 19 3 5 469 5
## 9 0 0 0 3 42 11 1 33 7 556

```

Na diagonal principal são apresentados o número de acertos e fora da diagonal principal os elementos com classificações incorretas.

Comparação da imagem original com a imagem comprimida usando 11 componentes principais.

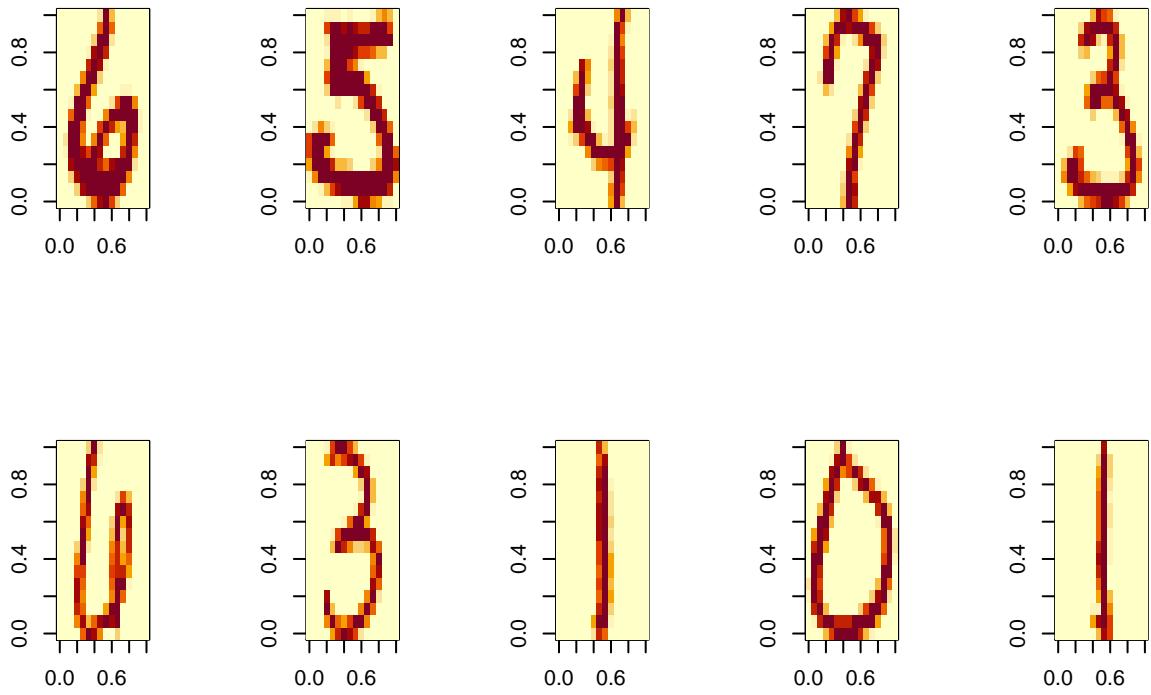
```

pca<- prcomp(zip.train[,-1])
pred <- pca$x[,1:11] %*% t(pca$rotation[,1:11])

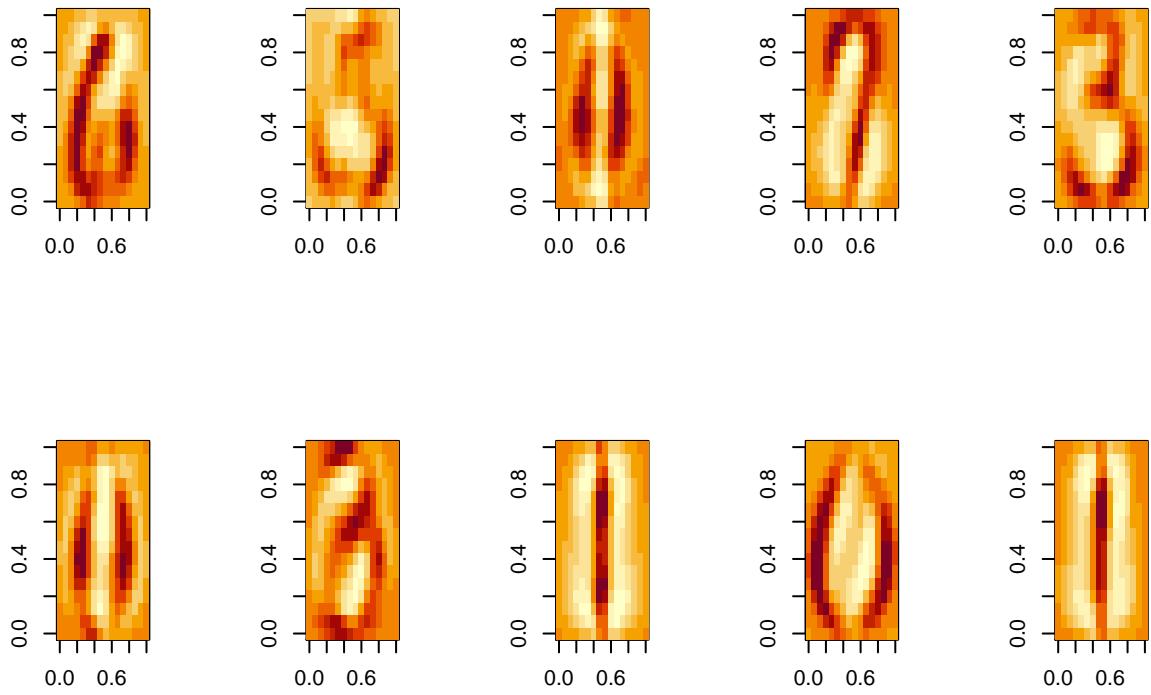
par(mfrow= c(2,5))

for (i in 1:10){
  im <- zip.train[i,-1]
  im <- t(matrix(im, 16, 16, byrow = TRUE))
  im <- im[, 16:1]
  image(im)
}

```



```
for (i in 1:10){  
  im <- t(matrix(pred[i,], 16, 16, byrow = TRUE))  
  im <- im[, 16:1]  
  image(im)  
}
```



O objeto zip.test contém 2007 observações que não foram utilizadas para a ACP. Faça a previsão para essas observações utilizando a ACP.