

Redução de Dimensionalidade

- Permite reduzir a dimensionalidade
- Permite eliminar a correlação entre as variáveis
- Permite visualizar dados com alta dimensionalidade
- Permite identificar semelhanças ou disparidades entre os dados
- Permite identificar que variáveis fazem com que um grupo seja diferente dos outros
- Variáveis fortemente correlacionadas irão contribuir fortemente para o mesmo componente principal
- Cada componente tenta explicar o máximo de variância possível
- Todos os componentes são ortogonais
- Permite comprimir os dados

Vantagens e desvantagens

Vantagens

- Fácil de calcular
- Aumenta a eficiência dos outros algoritmos
- Minora os efeitos de dados com alta dimensionalidade

Desvantagens

- É difícil de interpretar os componentes principais
- Perde-se informação com a redução de dimensionalidade
- É sensível à escala das variáveis
- Não é robusto a outliers
- Só funciona quando há relação linear entre as variáveis
- Não deteta relações não lineares

Procedimentos de instalação

```
library(devtools)
install_github("vqv/ggbiplot")
library(ggbiplot)
```

Resultado do PCA sobre o dataset iris

```
names(iris) = c("SL", "SW", "PL", "PW", "Species")
PCA = iris[, -5] %>% prcomp(scale = TRUE)
PCA
```

```
Standard deviations (1, ..., p=4):
[1] 1.7083611 0.9560494 0.3830886 0.1439265
```

```
Rotation (n x k) = (4 x 4):
```

	PC1	PC2	PC3	PC4
SL	0.5210659	-0.37741762	0.7195664	0.2612863
SW	-0.2693474	-0.92329566	-0.2443818	-0.1235096
PL	0.5804131	-0.02449161	-0.1421264	-0.8014492
PW	0.5648565	-0.06694199	-0.6342727	0.5235971

```
PCA %>% summary
```

```
Importance of components:
```

	PC1	PC2	PC3	PC4
Standard deviation	1.7084	0.9560	0.38309	0.14393
Proportion of Variance	0.7296	0.2285	0.03669	0.00518
Cumulative Proportion	0.7296	0.9581	0.99482	1.00000

Correlação do dataset iris

```
iris[,-5] %>% cor %>% round(digits = 2)
```

	SL	SW	PL	PW
SL	1.00	-0.12	0.87	0.82
SW	-0.12	1.00	-0.43	-0.37
PL	0.87	-0.43	1.00	0.96
PW	0.82	-0.37	0.96	1.00

```
PCA %>% .$x %>% cor %>% round(digits = 2)
```

	PC1	PC2	PC3	PC4
PC1	1	0	0	0
PC2	0	1	0	0
PC3	0	0	1	0
PC4	0	0	0	1

Reconstrução dos dados

```
iris[,-5] %>% scale %>% head
```

	SL	SW	PL	PW
[1,]	-0.8976739	1.01560199	-1.335752	-1.311052
[2,]	-1.1392005	-0.13153881	-1.335752	-1.311052
[3,]	-1.3807271	0.32731751	-1.392399	-1.311052
[4,]	-1.5014904	0.09788935	-1.279104	-1.311052
[5,]	-1.0184372	1.24503015	-1.335752	-1.311052
[6,]	-0.5353840	1.93331463	-1.165809	-1.048667

```
head(PCA$x %*% t(PCA$rotation))
```

	SL	SW	PL	PW
[1,]	-0.8976739	1.01560199	-1.335752	-1.311052
[2,]	-1.1392005	-0.13153881	-1.335752	-1.311052
[3,]	-1.3807271	0.32731751	-1.392399	-1.311052
[4,]	-1.5014904	0.09788935	-1.279104	-1.311052
[5,]	-1.0184372	1.24503015	-1.335752	-1.311052
[6,]	-0.5353840	1.93331463	-1.165809	-1.048667

Previsão

```
scale(iris[1:4,-5], center = PCA$center, scale = PCA$scale) %*% PCA$rotation
```

	PC1	PC2	PC3	PC4
1	-2.257141	-0.4784238	0.1272796	0.02408751
2	-2.074013	0.6718827	0.2338255	0.10266284
3	-2.356335	0.3407664	-0.0440539	0.02828231
4	-2.291707	0.5953999	-0.0909853	-0.06573534

```
predict(PCA, iris[1:4, -5])
```

	PC1	PC2	PC3	PC4
1	-2.257141	-0.4784238	0.1272796	0.02408751
2	-2.074013	0.6718827	0.2338255	0.10266284
3	-2.356335	0.3407664	-0.0440539	0.02828231
4	-2.291707	0.5953999	-0.0909853	-0.06573534


```
PCA$x[1:4,]
```

	PC1	PC2	PC3	PC4
[1,]	-2.257141	-0.4784238	0.1272796	0.02408751
[2,]	-2.074013	0.6718827	0.2338255	0.10266284
[3,]	-2.356335	0.3407664	-0.0440539	0.02828231
[4,]	-2.291707	0.5953999	-0.0909853	-0.06573534

Biplot

- Forma de apresentar resultados do PCA
- Pontos próximos correspondem a dados parecidos
- Eixos correspondem a variáveis
- Variáveis altamente correlacionadas correspondem a eixos com direções muito semelhantes
- Cada eixo é um vetor e a sua norma corresponde à sua contribuição para os componentes principais
- Direção de cada eixo corresponde a correlação positiva ou negativa

Biplot



```
PCA %>% ggbiplot
```

```
iris[, -5] %>% cor %>% round(digits = 2)
```

	SL	SW	PL	PW
SL	1.00	-0.12	0.87	0.82
SW	-0.12	1.00	-0.43	-0.37
PL	0.87	-0.43	1.00	0.96
PW	0.82	-0.37	0.96	1.00

Comentários


- PL e PW estão altamente correlacionados positivamente com PC1
- SL também está bastante correlacionado positivamente com PC1
- Podemos concluir que PL, PW e SL estão bastante correlacionados entre si
- SL está correlacionado positivamente com PC1 e negativamente com PC2
- SW está correlacionado negativamente com PC1 e PC2

Ordem das variáveis

```
ordem = PCA %>% .$rotation %>% .[,1] %>% order(decreasing = TRUE)
PCA %>% .$rotation %>% round(digits = 2) %>% .[ordem,]
```

	PC1	PC2	PC3	PC4
PL	0.58	-0.02	-0.14	-0.80
PW	0.56	-0.07	-0.63	0.52
SL	0.52	-0.38	0.72	0.26
SW	-0.27	-0.92	-0.24	-0.12


Biplot



Quando queremos perceber que exemplos estão relacionados

```
ggbiplot(PCA, labels = row.names(iris))
```

Biplot




```
ggbiplot(PCA, groups = iris$Species)
```

groups

- setosa
- versicolor
- virginica

Biplots




```
ggbiplot(PCA, groups=iris$Species,  
ellipse=T)
```

Conclusões

- Consegue-se separar setosa de virginica e versicolor usando PC1
- É mais complicado de separar virginica de versicolor
- virginica é caracterizado por PL, PW e SL

Mexendo a escala


```
ggbiplot(PCA, groups=iris$Species, obs.scale=1, var.scale=1, ellipse=T)
```



Previsão revisitada

```
grupo = sample(1:2, nrow(iris), replace = TRUE, prob=c(0.75, 0.25))
treino = iris[grupo == 1, -5]
teste = iris[grupo == 2, -5]
PCA = prcomp(treino, scale = TRUE)
previsao = predict(PCA, teste)
df.treino = cbind(PCA$x, data.frame(color = iris[grupo == 1, 5], tipo = "treino"))
df.teste = cbind(previsao, data.frame(color = iris[grupo == 2, 5], tipo="teste"))
data=rbind(df.treino, df.teste)
ggplot(data, aes(x=PC1, y=PC2, color = color, shape = tipo)) +
  geom_point(alpha = 0.75, size = 3)
```

Previsão revisitada



mtcars %>% summary

mpg	cyl	disp	hp
Min. :10.40	Min. :4.000	Min. : 71.1	Min. : 52.0
1st Qu.:15.43	1st Qu.:4.000	1st Qu.:120.8	1st Qu.: 96.5
Median :19.20	Median :6.000	Median :196.3	Median :123.0
Mean :20.09	Mean :6.188	Mean :230.7	Mean :146.7
3rd Qu.:22.80	3rd Qu.:8.000	3rd Qu.:326.0	3rd Qu.:180.0
Max. :33.90	Max. :8.000	Max. :472.0	Max. :335.0

drat	wt	qsec	vs
Min. :2.760	Min. :1.513	Min. :14.50	Min. :0.0000
1st Qu.:3.080	1st Qu.:2.581	1st Qu.:16.89	1st Qu.:0.0000
Median :3.695	Median :3.325	Median :17.71	Median :0.0000
Mean :3.597	Mean :3.217	Mean :17.85	Mean :0.4375
3rd Qu.:3.920	3rd Qu.:3.610	3rd Qu.:18.90	3rd Qu.:1.0000
Max. :4.930	Max. :5.424	Max. :22.90	Max. :1.0000

am	gear	carb
Min. :0.0000	Min. :3.000	Min. :1.000
1st Qu.:0.0000	1st Qu.:3.000	1st Qu.:2.000
Median :0.0000	Median :4.000	Median :2.000
Mean :0.4062	Mean :3.688	Mean :2.812
3rd Qu.:1.0000	3rd Qu.:4.000	3rd Qu.:4.000
Max. :1.0000	Max. :5.000	Max. :8.000

mtcars sem variáveis categóricas

```
MT = mtcars[,-c(8,9)]  
MT %>% cor %>% round(digits = 2)
```

	mpg	cyl	disp	hp	drat	wt	qsec	gear	carb
mpg	1.00	-0.85	-0.85	-0.78	0.68	-0.87	0.42	0.48	-0.55
cyl	-0.85	1.00	0.90	0.83	-0.70	0.78	-0.59	-0.49	0.53
disp	-0.85	0.90	1.00	0.79	-0.71	0.89	-0.43	-0.56	0.39
hp	-0.78	0.83	0.79	1.00	-0.45	0.66	-0.71	-0.13	0.75
drat	0.68	-0.70	-0.71	-0.45	1.00	-0.71	0.09	0.70	-0.09
wt	-0.87	0.78	0.89	0.66	-0.71	1.00	-0.17	-0.58	0.43
qsec	0.42	-0.59	-0.43	-0.71	0.09	-0.17	1.00	-0.21	-0.66
gear	0.48	-0.49	-0.56	-0.13	0.70	-0.58	-0.21	1.00	0.27
carb	-0.55	0.53	0.39	0.75	-0.09	0.43	-0.66	0.27	1.00

PCA

```
PCA = MT %>% prcomp(scale = TRUE)
PCA %>% summary
```

Importance of components:


	PC1	PC2	PC3	PC4	PC5	PC6	PC7
Standard deviation	2.3782	1.4429	0.71008	0.51481	0.42797	0.35184	0.32413
Proportion of Variance	0.6284	0.2313	0.05602	0.02945	0.02035	0.01375	0.01167
Cumulative Proportion	0.6284	0.8598	0.91581	0.94525	0.96560	0.97936	0.99103

	PC8	PC9
Standard deviation	0.2419	0.14896
Proportion of Variance	0.0065	0.00247
Cumulative Proportion	0.9975	1.00000

- 86% da variância é explicada pelos dois primeiros componentes
- 4 primeiros componentes explicam quase 95% da variância
- PC1 explica 62.8% da variância
- PC2 explica 23.1%

PCA

```
pais=c(rep("JP", 3), rep("US",4), rep("EU", 7),rep("US",3), "EU",  
  rep("JP", 3), rep("US",4), rep("EU", 3), "US", rep("EU", 3))  
PCA %>% ggbiplot(group=pais, labels = row.names(mtcars),  
  obs.scale=1,var.scale=1)
```




groups

- a EU
- a JP
- a US

Questões sobre o PCA

- Que relação há entre os eixos?
- Que grupos são explicados por que variáveis?



- cyl, disp e wt estão altamente correlacionados com PC1
- mpg está altamente correlacionado negativamente com PC1
- drat também está correlacionado negativamente com PC1
- carb e gear são os mais correlacionados positivamente com PC2
- qsec é o mais correlacionado negativamente com PC2, e também está correlacionado negativamente com PC1
- Carros Americanos são caracterizados por valores altos de cyl, disp e wt
- Carros Japoneses são caracterizados por valores altos de mpg

- 1 Quantos componentes são necessários para explicar 90% da variância?
- 2 Que percentagem da variância é explicada pelos dois primeiros componentes?
- 3 Há separabilidade das duas classes pelos dois componentes?

Cachexia

```
url = "http://darwin.di.uminho.pt/dataAnalysisR/cachexia.csv"
cachexia = read.table(url, sep = ",", header = T, row.names = 1)
url = "http://darwin.di.uminho.pt/dataAnalysisR/meta_cachexia.csv"
meta_cachexia = read.table(url, sep = ",", header = T, row.names = 1)
pca_cach = cachexia %>% prcomp(scale = TRUE)
pca_cach %>% summary
```

Importance of components:

	PC1	PC2	PC3	PC4	PC5	PC6	PC7
Standard deviation	5.0467	2.2701	1.83311	1.74728	1.65906	1.6130	1.47304
Proportion of Variance	0.4043	0.0818	0.05334	0.04846	0.04369	0.0413	0.03444
Cumulative Proportion	0.4043	0.4861	0.53941	0.58787	0.63156	0.6729	0.70730
	PC8	PC9	PC10	PC11	PC12	PC13	PC14
Standard deviation	1.36403	1.24275	1.20650	1.1584	1.05503	1.03620	0.9914
Proportion of Variance	0.02953	0.02451	0.02311	0.0213	0.01767	0.01704	0.0156
Cumulative Proportion	0.73683	0.76135	0.78445	0.8057	0.82342	0.84046	0.8561
	PC15	PC16	PC17	PC18	PC19	PC20	PC21
Standard deviation	0.96773	0.89551	0.86788	0.83041	0.8133	0.73918	0.72112
Proportion of Variance	0.01487	0.01273	0.01196	0.01095	0.0105	0.00867	0.00825
Cumulative Proportion	0.87093	0.88366	0.89562	0.90656	0.9171	0.92573	0.93399
	PC22	PC23	PC24	PC25	PC26	PC27	PC28
Standard deviation	0.71053	0.64606	0.63389	0.5830	0.5442	0.50539	0.48743
Proportion of Variance	0.00801	0.00663	0.00638	0.0054	0.0047	0.00405	0.00377
Cumulative Proportion	0.94200	0.94863	0.95500	0.9604	0.9651	0.96916	0.97293
	PC29	PC30	PC31	PC32	PC33	PC34	PC35
Standard deviation	0.42674	0.42427	0.41483	0.38653	0.35092	0.32424	0.31646

Cachexia: Quantos componentes para explicar 90% da variância?

```
pca_cach %>% summary %>% .$importance %>% .[3,]
```

PC1	PC2	PC3	PC4	PC5	PC6	PC7	PC8	PC9	PC10
0.40427	0.48607	0.53941	0.58787	0.63156	0.67286	0.70730	0.73683	0.76135	0.78445
PC11	PC12	PC13	PC14	PC15	PC16	PC17	PC18	PC19	PC20
0.80575	0.82342	0.84046	0.85606	0.87093	0.88366	0.89562	0.90656	0.91706	0.92573
PC21	PC22	PC23	PC24	PC25	PC26	PC27	PC28	PC29	PC30
0.93399	0.94200	0.94863	0.95500	0.96040	0.96510	0.96916	0.97293	0.97582	0.97867
PC31	PC32	PC33	PC34	PC35	PC36	PC37	PC38	PC39	PC40
0.98141	0.98378	0.98573	0.98740	0.98899	0.99030	0.99158	0.99266	0.99368	0.99465
PC41	PC42	PC43	PC44	PC45	PC46	PC47	PC48	PC49	PC50
0.99541	0.99602	0.99659	0.99708	0.99753	0.99793	0.99830	0.99860	0.99888	0.99906
PC51	PC52	PC53	PC54	PC55	PC56	PC57	PC58	PC59	PC60
0.99923	0.99939	0.99951	0.99962	0.99972	0.99979	0.99985	0.99990	0.99994	0.99997
PC61	PC62	PC63							
0.99998	0.99999	1.00000							

```
pca_cach %>% summary %>% .$importance %>% .[3,] %>%  
  map_lgl(~ .x > 0.9) %>% which %>% min
```


```
[1] 18
```

```
min(which(summary(pca_cach)$importance[3,] > 0.9))
```

```
[1] 18
```

Cachexia

```
ggbiplot(pca_cach, groups=meta_cachexia[,1], var.axes=FALSE, obs.scale=1, var.scale=1)
```



Compressão de imagens




Compressão de imagens

```
library(jpeg)
gato=readJPEG('gato.jpg')
dim(gato)
```


```
[1] 1666 2500    3
```

```
pca.gato=lapply(1:3, function(i)prcomp(gato[,i], center = FALSE))
pcs = 12
img = sapply(pca.gato, function(j) {j$x[,1:pcs] %*% t(j$rotation[,1:pcs])},
             simplify = "array")
writeJPEG(img, "gato12.jpg")
```


Gato com 12 componentes



Gato com 24 componentes



Gato com 48 componentes



Gato com 128 componentes



Gato com 256 componentes



Gato com 512 componentes



- 1 Use os dados de expressão ALL
- 2 Filtre os genes para só ter aqueles cujo rácio entre máximo e mínimo seja de 2
- 3 Não se esqueça que os pacientes é que possuem os metadados
- 4 Quantos componentes são necessários para explicar pelo menos 90% da variância?
- 5 Consegue uma boa separação para a classe mol.biol?
- 6 E para a classe BT? (Neste caso só nos interessa a primeira letra)

ALL

```
library(ALL)
data(ALL)
exp = exprs(ALL)
maximos = apply(exp,1,max)
minimos = apply(exp,1,min)
v1 = maximos/minimos > 2
ALLm2=ALL[v1,]
exp_m2 = exprs(ALLm2)
exp_pca = t(exp_m2)
dim(exp_pca)
```


```
[1] 128 1023
```

```
pca_all = prcomp(exp_pca, scale = TRUE)
min(which(summary(pca_all)$importance[3,]>0.9))
```

```
[1] 68
```


ALL

```
ggbiplot(pca_all, groups = ALL$mol.biol, var.axes = FALSE,  
obs.scale=1,var.scale=1, ellipse=T)
```



ALL

```
BT = sapply(ALL$BT, function(x)x %>% as.character %>% substr(1,1))  
ggbiplot(pca_all, groups = BT, var.axes = FALSE,  
  obs.scale=1,var.scale=1)
```



- Método algébrico de fatorização de matrizes
- Pode ser usado em análise de dados para reduzir a dimensionalidade
- Pode ser usado para identificar variáveis dependentes de outras, que podem ser removidas no processo de análise de dados
- Consiste na fatorização de uma matriz M de dimensões $n \times m$ em $U \cdot D \cdot V^T$
 - ▶ U é uma matriz $n \times n$, V é uma matriz $m \times m$, D tem dimensões $n \times m$;
 - ▶ $U \cdot U^T = I$ e $V \cdot V^T = I$
 - ▶ As colunas de U são os vetores **singulares esquerdos** e as de V os vetores **singulares direitos**
 - ▶ A matriz D é uma matriz diagonal com os **valores singulares** de M

- Através da função *svd*
- O principal argumento é a matriz de dados M
- O resultado é uma lista com três campos:
 - ▶ d : matriz diagonal D
 - ▶ u : matriz U
 - ▶ v : matriz V
- As colunas de v são equivalentes aos loadings resultantes da PCA (se os dados para esta forem normalizados)

Exemplo

```
iris[,-5] %>% scale %>% svd %>% .$v
```

	[,1]	[,2]	[,3]	[,4]
[1,]	0.5210659	-0.37741762	0.7195664	0.2612863
[2,]	-0.2693474	-0.92329566	-0.2443818	-0.1235096
[3,]	0.5804131	-0.02449161	-0.1421264	-0.8014492
[4,]	0.5648565	-0.06694199	-0.6342727	0.5235971


```
prcomp(iris[,-5], scale = TRUE)$rotation
```

	PC1	PC2	PC3	PC4
SL	0.5210659	-0.37741762	0.7195664	0.2612863
SW	-0.2693474	-0.92329566	-0.2443818	-0.1235096
PL	0.5804131	-0.02449161	-0.1421264	-0.8014492
PW	0.5648565	-0.06694199	-0.6342727	0.5235971

Compressão de imagens com svd

```
svd.gato = lapply(1:3, function(i)svd(gato[, ,i]))
j = 48
a=sapply(svd.gato, function(i) {
  i$u[,1:j] %*% diag(i$d[1:j]) %*% t(i$v[,1:j])
}, simplify = 'array')
writeJPEG(a, "gato_svg48.jpg")
```

Compressão de imagens com svd




Análise Multi Dimensional - MDS

- Multi-Dimensional Scaling (MDS) é uma técnica de visualização de informação
- Dada uma matriz de distâncias entre objetos
- Tenta colocar cada um dos objetos num espaço de n dimensões de forma a preservar o melhor possível a sua distância original.
- Se $n = 2$ podemos visualizar os pontos a 2 dimensões
- Existem várias variantes de MDS incluindo algoritmos ditos métricos e não métricos

MDS métrico

```
iris.sc = scale(iris[-5])  
dist.iris = dist(iris.sc, method = "euclidean")  
cmd.mds <- cmdscale(dist.iris, 3, eig = TRUE)  
# Proporção da variância explicada  
var.pc1 = sum(cmd.mds$eig[1])/sum(abs(cmd.mds$eig)) * 100  
var.pc2 = sum(cmd.mds$eig[2])/sum(abs(cmd.mds$eig)) * 100  
var.pc3 = sum(cmd.mds$eig[3])/sum(abs(cmd.mds$eig)) * 100  
lab.pc1 = paste("Coordinate 1", sprintf("(var.%.3f", var.pc1), "%")  
lab.pc2 = paste("Coordinate 2", sprintf("(var.%.3f", var.pc2), "%")  
plot(cmd.mds$points[,c(1,2)], xlab=lab.pc1, ylab=lab.pc2, main="")
```



MDS não métrico

```
library(MASS)
# Necessário mudar matriz de distâncias pois há uma réplica perfeita nos dados
dist.iris[dist.iris==0] = 0.00001
ord = isoMDS(dist.iris, k=3) # for 3 dimensions
```


```
initial value 0.757426
iter 5 value 0.639512
final value 0.634255
converged
```

MDS não métrico

```
mcols = rep("gray", length(iris[,5]))  
mcols[iris[,5]=="setosa"] = "blue"  
mcols[iris[,5]=="versicolor"] = "red"  
mcols[iris[,5]=="virginica"] = "green"
```

```
plot(cmd.mds$points[,c(1,2)],xlab=lab.pc1,ylab=lab.pc2,  
     col= mcols, pch = 19, main="métrico")  
plot(ord$points[,c(1,2)],xlab=lab.pc1,ylab=lab.pc2,  
     main="não métrico", col= mcols, pch = 19)
```

MDS métrico vs não métrico



T-SNE t-Distributed Stochastic Neighbor Embedding

- Técnica alternativa e mais recente ao PCA e ao MDS para realizar a redução de dimensionalidade e mais voltada para a visualização de dados em 2D ou 3D
- Bastante utilizada para visualização de dados em projetos de Aprendizagem Máquina e Deep Learning
- É uma técnica não linear e que tal como o MDS se baseia na preservação de distâncias em pares de pontos, mas usando técnicas de otimização e funções objetivo distintas

Exemplo

```
install.packages("Rtsne")  
library(Rtsne)  
# Erro porque há duplicados  
Rtsne(iris[1:4])
```

```
iris_nd = iris[!duplicated(iris),]  
dim(iris_nd)
```

```
[1] 149    5
```

```
res_tnse = Rtsne(iris_nd[1:4])  
plot(res_tnse$Y, col = iris_nd$Species, pch = 19)
```

