



**ANÁLISE DE COMPONENTES PRINCIPAIS, ANÁLISE FATORIAL:
 Exemplos em STATA.**

Prof. Dr. Evandro Marcos Saidel Ribeiro
RESUMO

A1 – Análise de Componentes Principais

Atualmente, pesquisadores defrontam-se com dezenas ou centenas de variáveis diferentes em suas análises. É frequente haver redundância entre diversas dimensões, levando a problemas de multicolinearidade.

A análise de componentes principais é um método que explora a interdependência em dados multivariados. Se houver redundância substancial no conjunto de dados, pode ser possível explicar a maior parte das informações num conjunto menor de dimensões.

A1.1 Covariância e Correlação

Matriz de Covariância

Organize os dados na forma de matriz, por exemplo, na coluna 1 liste as 5 observações da variável x_1 e na coluna 2 liste as 5 observações da variável x_2 :

$$\mathbf{X} = \begin{bmatrix} 2 & 1 \\ 9 & 8 \\ 7 & 5 \\ 3 & 4 \\ 4 & 2 \end{bmatrix}. \quad (1)$$

Calcule as médias das variáveis:

$$\bar{x}_1 = 5 \quad \bar{x}_2 = 4. \quad (2)$$

Utilize a matriz obtida em (1) e, para cada coluna subtraia a média, obtendo a matriz de desvios \mathbf{X}_{desv} :

$$\mathbf{X}_{desv} = \begin{bmatrix} 2 & 1 \\ 9 & 8 \\ 7 & 5 \\ 3 & 4 \\ 4 & 2 \end{bmatrix} - \begin{bmatrix} 5 & 4 \\ 5 & 4 \\ 5 & 4 \\ 5 & 4 \\ 5 & 4 \end{bmatrix} = \begin{bmatrix} -3 & -3 \\ 4 & 4 \\ 2 & 1 \\ -2 & 0 \\ -1 & -2 \end{bmatrix}. \quad (3)$$

A matriz de covariância, \mathbf{S} , é obtida pela expressão:

$$\mathbf{S} = \frac{1}{n-1} \mathbf{X}'_{desv} \mathbf{X}_{desv} \quad (4)$$

- n é o número de observações, que no nosso exemplo é igual a 5;

- \mathbf{X}'_{desv} é a matriz transposta da matriz obtida em (3). Então, para o exemplo dado a matriz \mathbf{S} é:

$$\mathbf{S} = \frac{1}{4} \begin{bmatrix} -3 & 4 & 2 & -2 & -1 \\ -3 & 4 & 1 & 0 & -2 \end{bmatrix} \begin{bmatrix} -3 & -3 \\ 4 & 4 \\ 2 & 1 \\ -2 & 0 \\ -1 & -2 \end{bmatrix},$$

que leva a: $\mathbf{S} = \frac{1}{4} \begin{bmatrix} 34 & 29 \\ 29 & 30 \end{bmatrix}$, ou seja

$$\mathbf{S} = \begin{bmatrix} 8,50 & 7,25 \\ 7,25 & 7,50 \end{bmatrix}. \quad (5)$$

Note que para duas variáveis a matriz de covariância será 2x2:

$$\mathbf{S} = \begin{bmatrix} S_{11} & S_{12} \\ S_{21} & S_{22} \end{bmatrix}. \quad (6)$$

Matriz de correlação

A matriz de correlação é escrita na forma:

$$\mathbf{R} = \begin{bmatrix} 1 & r_{12} & \dots & r_{1k} \\ r_{21} & 1 & \dots & r_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ r_{k1} & r_{k2} & \dots & 1 \end{bmatrix}. \quad (7)$$

O cálculo de cada elemento desta matriz pode ser obtido da matriz \mathbf{S} por:

$$r_{ij} = \frac{S_{ij}}{\sqrt{S_{ii}} \sqrt{S_{jj}}}. \quad (8)$$

A matriz \mathbf{R} também é simétrica, ou seja, $r_{ij} = r_{ji}$.

Para matrizes 2x2:

$$\mathbf{R} = \begin{bmatrix} 1 & \frac{S_{12}}{\sqrt{S_{11}}\sqrt{S_{22}}} \\ \frac{S_{12}}{\sqrt{S_{11}}\sqrt{S_{22}}} & 1 \end{bmatrix}. \quad (9)$$

No exemplo, considerando (1) e (5), a matriz de correlação será:

$$\mathbf{R} = \begin{bmatrix} 1 & 0,908025 \\ 0,908025 & 1 \end{bmatrix}. \quad (10)$$

A1.2 Autovalores e Autovetores

1º passo: Determinar autovalores. Para a matriz de covariância \mathbf{S} os autovalores são:

$$\lambda = \frac{(s_{11} + s_{22}) \pm \sqrt{(s_{11} + s_{22})^2 - 4(s_{11}s_{22} - s_{12}^2)}}{2} \quad (11)$$

No caso específico da matriz \mathbf{S} obtida em (5), os autovalores são:

$$\lambda_1 = 15,267221 \quad \lambda_2 = 0,732779. \quad (12)$$

Os autovalores da matriz de correlação \mathbf{R} são:

$$\lambda = 1 \pm r_{12}. \quad (13)$$

No caso específico da matriz \mathbf{R} obtida em (10), os autovalores são:

$$\lambda_1 = 1,908025 \quad \lambda_2 = 0,091975. \quad (14)$$

2º Passo: Determinar os autovetores da matriz de covariância.

No caso de uma matriz 2x2 deve-se resolver o sistema:

$$\begin{bmatrix} S_{11} & S_{12} \\ S_{21} & S_{22} \end{bmatrix} \begin{bmatrix} v_{1i} \\ v_{2i} \end{bmatrix} = \lambda_i \begin{bmatrix} v_{1i} \\ v_{2i} \end{bmatrix} \quad (15)$$

para cada autovalor. Para resolver o sistema podemos considerar $v_{ii} = 1$.

- Considerando o primeiro autovalor λ_1 :

$$v_{11} = 1, \quad (16-a)$$

então v_{21} é obtida pela expressão:

$$v_{21} = \frac{s_{11} + s_{21} - \lambda_1}{\lambda_1 - s_{22} - s_{12}}. \quad (16-b)$$

o resultado é:

$$\begin{bmatrix} v_{11} \\ v_{21} \end{bmatrix} = \begin{bmatrix} 1 \\ 0,93341 \end{bmatrix} \quad (16-c)$$

- Considerando o segundo autovalor λ_2 :

$$v_{22} = 1, \quad (17-a)$$

então v_{12} é obtida pela expressão:

$$v_{12} = \frac{\lambda_2 - s_{22} - s_{12}}{s_{11} + s_{21} - \lambda_2}. \quad (17-b)$$

o resultado é:

$$\begin{bmatrix} v_{21} \\ v_{22} \end{bmatrix} = \begin{bmatrix} -0,93341 \\ 1 \end{bmatrix} \quad (17-c)$$

3º Passo: Normalizar os autovetores \mathbf{e} : Divida cada componente dos autovetores obtidos pelo seu módulo. No caso, o módulo dos dois vetores obtidos é igual a 1,367938. O resultado obtido é:

$$\begin{bmatrix} e_{11} \\ e_{21} \end{bmatrix} = \begin{bmatrix} 0,731027 \\ 0,682348 \end{bmatrix} \quad (18-a)$$

$$\begin{bmatrix} e_{12} \\ e_{22} \end{bmatrix} = \begin{bmatrix} -0,682348 \\ 0,731027 \end{bmatrix} \quad (18-b)$$

Os vetores normalizados apresentados nas expressões (18-a) e (18-b) acima são autovetores da matriz de covariância.

A1.3 Componentes Principais

Componentes Principais são escritos em termos das variáveis originais através de ponderações, dadas pelas componentes dos autovetores \mathbf{e} . Se tivermos duas variáveis originais teremos dois componentes principais: $\mathbf{CP} = \mathbf{e}' \mathbf{X}$

$$\text{Sendo, } \mathbf{e} = \begin{bmatrix} e_{11} & e_{12} \\ e_{21} & e_{22} \end{bmatrix} \text{ ou seja } \mathbf{e}' = \begin{bmatrix} e_{11} & e_{21} \\ e_{12} & e_{22} \end{bmatrix}.$$

$$\text{Assim, } \begin{bmatrix} \mathbf{CP}_1 \\ \mathbf{CP}_2 \end{bmatrix} = \begin{bmatrix} e_{11} & e_{21} \\ e_{12} & e_{22} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \text{ e então:}$$

$$\begin{aligned} \mathbf{CP}_1 &= e_{11}x_1 + e_{21}x_2 \\ \mathbf{CP}_2 &= e_{12}x_1 + e_{22}x_2 \end{aligned} \quad (19)$$

No exemplo específico, utilizando os resultados obtidos para os autovetores, temos:

$$\begin{aligned} \mathbf{CP}_1 &= 0,731027 x_1 + 0,682348 x_2 \\ \mathbf{CP}_2 &= -0,682348 x_1 + 0,731027 x_2 \end{aligned} \quad (20)$$

A1.4 Variância explicada

O Percentual da variação explicada é dado por

$$\mathbf{CP}_i = \frac{\lambda_i}{\sum \lambda} \times 100. \quad (21)$$

No exemplo em questão, considerando os autovalores (12), obtemos:


$$\text{Variação explicada por } \mathbf{CP}_1 = 95,42 \%, \quad (22-a)$$

$$\text{Variação explicada por } \mathbf{CP}_2 = 4,58 \%. \quad (22-b)$$

A1.5 PCA: Exemplo no STATA

Após inserir os dados do exemplo (Equação 1) no Stata, para obter gráficos de dispersão, considere o link: [Graphics](#) ► [Scatterplot Matrix](#). O resultado é apresentado na Figura 1.

Figura 1. Scatterplot Matrix para variáveis X1 e X2, obtido no STATA.



Neste exemplo observa-se uma correlação linear positiva entre as variáveis X1 e X2.

Covariância e Correlação – Comando no STATA:

[Statistics](#) ► [Summaries, tables and tests](#)

- [Summary and descriptive statistics](#)
- [Correlation and Covariances](#)

Os resultados de covariância e de correlação são apresentados na Figura 2 a seguir.

Figura 2. Covariância e Correlação calculados no STATA.

```
. correlate, covariance
(obs=5)
```

	X1	X2
X1	8.5	
X2	7.25	7.5

```
. correlate
(obs=5)
```

	X1	X2
X1	1.0000	
X2	0.9080	1.0000

Observe que os valores apresentados para a matriz de covariância (correlate, covariance na Figura 2) e os valores apresentados para a matriz de correlação (correlate, na Figura 2) são os mesmos apresentados nas expressões (5) e (10), respectivamente.

Componentes Principais – Comando no STATA

[Statistics](#) ► [Multivariate analysis](#)

- [Factor and principal components analysis](#)
- [Principal components analysis \(PCA\)](#)

Nas Figuras 3 e 4 a seguir são apresentados os resultados da PCA considerando a matriz de correlação (Figura 3) e a matriz de covariância (Figura 4).

Figura 3. Resultado PCA, matriz de correlação.

Component	Eigenvalue	Difference
Comp1	1.90803	1.40803
Comp2	.0919748	

Principal components (eigenvectors)

Variable	Comp1	Comp2
X1	0.7071	0.7071
X2	0.7071	-0.7071

Figura 4. Resultado PCA, matriz de covariância.

Component	Eigenvalue	Difference
Comp1	15.2672	14.5672
Comp2	.732779	

Principal components (eigenvectors)


Variable	Comp1	Comp2	U
X1	0.7310	-0.6823	
X2	0.6823	0.7310	

Observe que o resultado PCA calculado para matriz de covariância (Figura 4) é equivalente ao resultado obtido em (20).

Gráfico Scree plot:

- Statistics ► Multivariate analysis
- Factor and principal components analysis
- Postestimation

Figura 5. Gráfico Scree plot para PCA calculada pela matriz de correlação (STATA)



A1.E – Exercícios de Componentes Principais

A1.E1 Produto Estadual Bruto, nos estados americanos. (Gross State Product – GSP).

Dados sobre produto estadual bruto estão disponíveis em dois arquivos: `gsp_raw` (expresso em milhões de dólares) e `gsp_share` (expresso como uma proporção do total do GSP para cada estado). Cada arquivo consiste em 50 linhas (uma para cada estado) e 14 colunas (a primeira é a identidade do estado e as 13 restantes correspondendo às diferentes áreas de atividade econômica).

A1.E1.a Usando os dados do `gsp_share` faça uma análise de componentes principais.

A1.E1.b O que acontecerá se você remover as observações correspondentes ao Alasca e Wyoming? Repita a análise e esquematize os scores para os primeiros dois componentes principais. Como você interpreta os resultados?

Respostas, A1.E1:

Com a base `gsp.raw`:

```
. pca col1 col2 col3 col4 col5 col6 col7 col8 col9
col10 col11 col12 col13
```

Tabela 1. Autovalores da matriz de correlação para os dados `gsp_raw`

Component	Eigenvalue	Difference
Comp1	10.9443	9.96488
Comp2	.979435	.579379
Comp3	.400057	.0573802
Comp4	.342677	.203464
Comp5	.139213	.0698184
Comp6	.0693941	.0292465
Comp7	.0401476	.00680468
Comp8	.0333429	.00825054
Comp9	.0250924	.0145441
Comp10	.0105483	.00305999
Comp11	.00748827	.00143102
Comp12	.00605725	.00382676
Comp13	.00223049	.

Tabela 2. Autovalores da matriz de correlação para os dados `gsp.share`.

Component	Eigenvalue	Difference
Comp1	3.23551	.99905
Comp2	2.23646	.276623
Comp3	1.95984	.599488
Comp4	1.36035	.202928
Comp5	1.15742	.289087
Comp6	.868334	.143849
Comp7	.724486	.108706
Comp8	.615779	.297542
Comp9	.318237	.0828841
Comp10	.235353	.083691
Comp11	.151662	.0151629
Comp12	.136499	.136431
Comp13	.000068552	.

Nas Tabelas 1 e 2 são pode-se ver a diferença entre o cálculo com os dados do arquivo `gsp_raw` (formado com valores absolutos do produto estadual bruto) e o cálculo com os dados do arquivo `gsp_share` (formado com os dados proporcionais para cada estado. As Figuras 6 e 7 apresentam os gráficos Scree plot para os cálculos com as bases `gsp_raw` e `gsp_share`. Após

o cálculo, digite **.screeplot** para obter o gráfico ScreePlot.

Figura 6. Gráfico Scree plot para PCA calculada pela matriz de correlação `gsp_raw`.





Figura 7. Gráfico Scree plot para PCA calculada pela matriz de correlação `gsp_share`.



Para obter os scores como novas variáveis devemos utilizar o comando **predict** e depois o nome das componentes. Por exemplo para criar as primeiras duas componentes e gravá-las como novas variáveis podemos digitar:

predict pc1 pc2, score

A1.E2 Opinião Política.

Um pesquisador coletou informações sobre 100 respondentes acerca de seis variáveis de opinião política apresentadas a seguir:

- x1 O governo deveria investir mais dinheiro em escolas
- x2 O governo deveria investir mais dinheiro para reduzir o desemprego

- x3 O governo deveria controlar os grandes negócios
- x4 O governo deveria acelerar o fim da discriminação racial através de transporte escolar
- x5 O governo deveria zelar para que as minorias obtenham suas respectivas quotas de emprego
- x6 O governo deveria expandir o programa Head Start (www.acf.hhs.gov/programs/ohs)

A matriz de correlação para esses dados é apresentada na Tabela 1

Tabela 1. Matriz de correlação para os dados de opinião política.

	x1	x2	x3	x4	x5	x6
x1	1.00					
x2	.601	1.00				
x3	.498	.475	1.00			
x4	.192	.220	.208	1.00		
x5	.196	.191	.201	.433	1.00	
x6	.347	.298	.245	.320	.421	1.00

A1.E2.a Analise esses dados usando a análise de componentes principais. Quanta variação é explicada pelos dois primeiros componentes principais? Como você interpretaria os dois componentes?

Respostas, A1.E2:

Transformando os dados em matriz no STATA:
`mkmat x1 x2 x3 x4 x5 x6, matrix(MatrizOp)`

Obtendo a matriz completa:
`matrix Opinion = MatrizOp + MatrizOp' - I(6)`

Nomes das linhas e colunas da matriz:
`matrix rownames MatrizOp = x1 x2 x3 x4 x5 x6`
`matrix colnames MatrizOp = x1 x2 x3 x4 x5 x6`

Observando os valores da matriz:
`matrix list MatrizOp`

Componentes Principais:
`pcamat Opinion, n(6)`
 Resultados:

Figura 8. Resultado da pca a partir da matriz de correlação pelo comando **pcamat**.

```
Principal components/correlation

Rotation: (unrotated = principal)
```


Component	Eigenvalue	Difference
Comp1	2.63335	1.4067
Comp2	1.22665	.543098
Comp3	.683555	.123086
Comp4	.560469	.0555001
Comp5	.504969	.113962
Comp6	.391007	.

```
Principal components (eigenvectors)
```

Variable	Comp1	Comp2	Comp3
x1	0.4629	-0.3701	-0.1216
x2	0.4532	-0.3647	0.0356
x3	0.4202	-0.3334	0.3075
x4	0.3415	0.4846	0.6146
x5	0.3544	0.5463	-0.0333
x6	0.4019	0.2925	-0.7145

O Scree Plot obtido é apresentado na Figura 9 a seguir.

Figura 9. Scree Plot para A1.E2.a.



Pelo resultado observa-se que a variância explicada pelos dois primeiros componentes é 64,33%, ou seja:

$$(2.63335 + 1.22665)/6 = 0.643333$$

A2 Análise Fatorial

A2.1 Características gerais

O objetivo é descrever um **conjunto de k variáveis originais** (x_1, x_2, \dots, x_k) através da criação de um número menor de variáveis (**fatores**).

Cada variável é descrita em termos de fatores:

$$x_i = a_{i1}F_1 + a_{i2}F_2 + \dots + a_{in}F_n \quad (23)$$

a_{ij} são cargas fatoriais.

A soma das cargas ao quadrado, para uma determinada variável é igual a comunalidade da variável:

$$h_i^2 = \sum_{j=1}^n a_{ij}^2 \quad (24)$$

Uma regra útil para considerar uma variável na análise é que a comunalidade deve ser maior do que 0,7.

A medida de unicidade (uniqueness) é dada por um menos a comunalidade, ou seja:

$$u_i = 1 - h_i^2 \quad (25)$$

Se a soma das cargas fatoriais (23) ao quadrado, for feita para um índice relacionado a um fator, então obtemos o autovalor correspondente ao fator em questão, ou seja

$$\lambda_j = \sum_{i=1}^k a_{ij}^2 \quad (26)$$

Como resultado, cada Fator pode ser escrito em termos das variáveis sendo possível assim obter uma função para o Score Fatorial j :

$$F_j = b_{j1}z_1 + b_{j2}z_2 + \dots + b_{jk}z_k \quad (27)$$

Para obter o cálculo correto do Score Fatorial as variáveis devem ser padronizadas.

Assim, em (27) $z_i = (x_i - \bar{x}_i) / s_i$ é o Score-z.

A2.2 Exemplo Completo no STATA


Como exemplo é considerado o “Exemplo Completo” apresentado no livro “Análise Multivariada para cursos de Administração, Ciências Contábeis e Economia” (Corrar, Paulo e Dias Filho).

A base de dados está disponível no arquivo **Exemplo_CAP02_CORRAR.dta**

Os passos para a Análise Fatorial são os seguintes:

- **factor ICOM-ILGE, pcf.** Este comando executa a análise fatorial a partir de componentes principais. Utiliza todas as variáveis, desde ICOM até ILGE.
- **screepLOT, ytitle(Autovalor) xtitle(Fator).** Com este comando obtemos o screepLOT.

Figura 10. Scree plot obtido no exemplo completo com 15 variáveis.



- **estat kmo.** Um comando *postestimation* importante é o “estat kmo”. Com este comando podemos analisar a Medida de Adequação da Amostra (MSA – Measure of Sampling Adequacy) de Kaiser-Meyer-Olkin. Os valores variam de zero a um. Valores baixos podem indicar que a variável em questão não contribui para a análise e deve ser removida do modelo. Em geral, valores abaixo de 0,5 são considerados inaceitáveis.

Tabela 2. Medidas KMO para o Exemplo Completo com 15 variáveis

Variable	kmo
ICOM	0.5314
ICOA	0.2277
ICAP	0.7240
IEND	0.8243
IRPG	0.5147
IIMR	0.4153

continua...

... continuação da Tabela 2:

ISIN	0.3286
ICOL	0.7098
IDAD	0.6237
ILPG	0.5138
IRPL	0.4852
PRPL	0.7094
IALI	0.6393
ILCO	0.5713
ILGE	0.6020
Overall	0.5689

- **rotate.** Este comando proporciona a rotação (tendo como padrão o método varimax). A rotação permite observar um padrão mais claro das cargas fatoriais.

Tabela 3. Cargas fatoriais rotacionadas para o resultado da análise fatorial do exemplo completo, com 9 variáveis.

Variable	Factor1	Factor2	Factor3
ICOM	0.9701	-0.0728	0.1635
ICAP	0.3034	-0.8375	-0.1733
IEND	-0.0047	0.7487	-0.3004
IDAD	0.9403	-0.1181	0.2198
ILPG	0.9777	-0.0768	0.1607
PRPL	-0.0224	0.8246	-0.2391
IALI	-0.0687	0.9352	0.1387
ILCO	0.2150	0.0028	0.9684
ILGE	0.2307	-0.0068	0.9616

Os valores de comunalidade devem ser analisados a partir da medida de unicidade (25), que fica na coluna à direita das cargas fatoriais

Tabela 4. Unicidade

Variable	Factor1	Factor3	Uniqueness
ICOM	0.9701	0.1635	0.0268
ICAP	0.3034	-0.1733	0.1765
IEND	-0.0047	-0.3004	0.3492
IDAD	0.9403	0.2198	0.0536
ILPG	0.9777	0.1607	0.0123
PRPL	-0.0224	-0.2391	0.2624
IALI	-0.0687	0.1387	0.1015
ILCO	0.2150	0.9684	0.0160
ILGE	0.2307	0.9616	0.0220


- **predict f1 f2 f3.** Com este comando são obtidos os seguintes resultados:
 - a) Os coeficientes dos scores fatoriais. Ou seja, os valores de b_{ji} da expressão (27);
 - b) Os scores fatoriais, f1, f2 e f3, calculados para cada caso. Os scores resultantes são disponibilizados como novas variáveis na base de dados

Tabela 5. Coeficientes dos Scores Fatoriais

Variable	Factor1	Factor2	Factor3
ICOM	0.35505	0.04432	-0.06765
ICAP	0.08751	-0.28645	-0.14326
IEND	0.10009	0.27355	-0.15513
IDAD	0.33093	0.02572	-0.03327
ILPG	0.35822	0.04338	-0.07033
PRPL	0.08884	0.30040	-0.11960
IALI	0.01852	0.33923	0.08812
ILCO	-0.06779	0.02062	0.47840
ILGE	-0.06118	0.01817	0.47230


- **loadingplot, factors(3) combined xline(0) yline(0) aspect(1).** Este comando apresenta gráficos das cargas fatoriais.

Figura 11. Loadingplot. Gráfico com cargas fatoriais.



- **scoreplot, factors(3) combined.** Este comando apresenta gráficos dos cores fatoriais f1, f2 e f3 obtidos pelo comando predict.

Figura 12. Scoreplot. Gráfico com scores fatoriais



É testada então esta noção prévia para determinar se ela é consistente com o padrão de correlação nos dados.

A2.3 Análise Fatorial Exploratória vs Análise Fatorial Confirmatória

Na forma como realizada nas seções anteriores a Análise Fatorial é considerada uma “Análise Fatorial Exploratória”. Nesta seção são feitas considerações sobre os dois tipos de análises.

A2.3.1 Análise Fatorial Exploratória

Na Análise Fatorial Exploratória deixamos que cada variável tenha uma determinada carga em cada fator e utilizamos a rotação para identificar estruturas. Ou seja, obtemos uma solução interpretável a partir de rotações. A meta é inferir a estrutura fatorial a partir do padrão de correlação nos dados.

Este tipo de análise foi descrito na seção anterior quando, a partir de 15 indicadores investigamos o padrão de correlações e levantamos a estrutura de fatores. Ou seja, quais indicadores deveriam fazer parte da modelagem, quais deveriam ser retirados do modelo.

A2.3.2 Análise Fatorial Confirmatória

Neste caso começamos a análise com uma forte noção prévia da estrutura do modelo fatorial. Neste caso já partimos do pressuposto que existe uma solução única para o modelo, ou seja, não há necessidade de solução rotacionada.

Evandro Marcos Saidel Ribeiro
E-mail: esaidel@usp.br

Bibliografia:

- J. Lattin, J.D. Carroll, P.E. Green. Análise de dados Multivariados, Cengage Learning, 2011.
- L.P. Fávero, P. Belfiore, F.L. da Silva, B.L. Chan, Análise de Dados: Modelagem Multivariada para tomada de decisões, Elsevier, 2009.
- L.J. Corrar, E. Paulo, J.M. Dias Filho, Análise Multivariada para cursos de Administração, Ciências Contábeis e Economia, Atlas, 2007.
- R.A. Johnson, Applied Multivariate Statistical Analysis, Prentice Hall, 1992