

Tópico:


Análise Fatorial

Bibliografia:

- R.A. **Johnson**, Applied Multivariate Statistical Analysis, Prentice Hall, 1992
- L.J. **Corrar; E. Paulo; J.M. Dias Filho**, Analise multivariada ..., Atlas, 2007
- L.P. **Favero**; et al, Análise de dados - modelagem multivariada ..., Campus, 2009.


Análise Fatorial

A Análise Fatorial tem como principal objetivo descrever um **conjunto de variáveis originais** através da criação de um número menor de variáveis (**fatores**). Os fatores são variáveis hipotéticas que explicam parte de variabilidade total dos dados.




Técnicas de dependência × interdependência

- Qual a diferença entre Análise Fatorial e as técnicas de análise de dependência (regressão múltipla, discriminante, etc.)?



Técnica de dependência: Análise das variáveis independentes para determinar a capacidade de previsão da variável dependente

Cada variável é explicada levando em consideração todas as outras.



Técnica de interdependência: Análise das variáveis com o intuito de maximizar o poder de explicação do conjunto de variáveis

- Identificar dimensões latentes (fatores) que expliquem correlações entre um conjunto de variáveis.
- Identificar um conjunto menor de variáveis não correlacionadas para substituir um conjunto original de variáveis correlacionadas.
- Identificar em um conjunto maior, um conjunto menor de variáveis que se destacam para uso em um análise multivariada posterior.

Análise Fatorial - Charles Spearman

Análise fatorial: começou com Charles Spearman analisando correlações entre notas de várias disciplinas cursadas por estudantes:

	Cl (X1)	Fr (X2)	In (X3)	Ma (X4)	DT (X5)	Um (X6)
Cl	1	0,83	0,78	0,70	0,66	0,63
Fr	0,83	1	0,67	0,67	0,65	0,57
In	0,78	0,67	1	0,64	0,54	0,51
Ma	0,70	0,67	0,64	1	0,45	0,51
DT	0,66	0,65	0,54	0,45	1	0,40
Mu	0,63	0,57	0,51	0,51	0,40	1

Cl: clássicos
Fr: Francês
In: Inglês
Ma: matemática
DT: Discriminação de tom
Mu: Música

Matriz de correlação (*C. Spearman, Am. J. Psychol. 15, 201, 1904.*)

A idéia básica de Spearman era que a correlação entre as variáveis poderia ser explicada pela dependência comum delas **com uma variável latente** que ele chamou de fator, ou seja, no caso das seis disciplinas:

$$x_i = a_i F + \varepsilon_i \quad i = 1, 2, \dots, 6$$

Onde:

x_i : variável analisada padronizada (**média zero e desvio-padrão 1**)

a_i : é uma constante (**carga fatorial**)

F : **Fator** (com média zero e desvio-padrão 1) comum a todas as variáveis

ε_i : erro (que é específico de cada variável)

Conclusão de Spearman:

Cada resultado do teste (notas nas disciplinas) é composto de duas partes:

- Uma parte que é comum a todos os testes (disciplinas), contida no fator comum **F** ao qual foi dado o nome de “inteligência geral”.
- Uma parte que é específica de uma dada disciplina.

Caso geral de **p variáveis** x_i ($i = 1, 2, 3, \dots, p$) **padronizadas** e **m fatores** o modelo de análise de fatores é:

$$x_i = a_{i1} F_1 + a_{i2} F_2 + a_{i3} F_3 + \dots + a_{im} F_m + \varepsilon_i, \quad i = 1, 2, 3, \dots, p$$

Onde:

- a_{ij} são cargas fatoriais, medem o grau de correlação entre a variável original (x_i) e os fatores.

- F_1, F_2, \dots, F_m são os **m** fatores não correlacionados, cada um com média zero e variância unitária, ou seja,

$$\text{Var}(F_i) = 1 \text{ e } \text{Corr}(F_i F_j) = 0 \quad (i \neq j).$$

- ε_i : é um fator específico para a i -ésima variável, tem média zero e não é correlacionado com qualquer um dos fatores comuns, ou seja, $\text{Corr}(F_i \varepsilon_j) = 0$

Análise Fatorial – A variância de x_i

$$x_i = a_{i1} F_1 + a_{i2} F_2 + a_{i3} F_3 + \dots + a_{im} F_m + \varepsilon_i$$

$$\text{Var}(x_i) = a_{i1}^2 \text{Var}(F_1) + a_{i2}^2 \text{Var}(F_2) + \dots + a_{im}^2 \text{Var}(F_m) + \text{Var}(\varepsilon_i)$$

1 1 1

$$\text{Var}(x_i) = \boxed{a_{i1}^2 + a_{i2}^2 + \dots + a_{im}^2} + \boxed{\text{Var}(\varepsilon_i)}$$

Comunalidade de x_i : h_i^2 , parte da variância relacionada aos fatores comuns (soma dos quadrados das cargas fatoriais)

Especificidade: parte da variância não relacionada aos fatores comuns

$$h_i^2 = a_{i1}^2 + a_{i2}^2 + \dots + a_{im}^2$$

Análise Fatorial – Correlações

$$\mathbf{x}_i = a_{i1} \mathbf{F}_1 + a_{i2} \mathbf{F}_2 + a_{i3} \mathbf{F}_3 + \dots + a_{im} \mathbf{F}_m + \varepsilon_i$$

Correlação entre \mathbf{x}_i e \mathbf{x}_j :

$$\text{Corr}(\mathbf{x}_i \mathbf{x}_j) = r_{ij} = a_{i1} a_{j1} + a_{i2} a_{j2} + \dots + a_{im} a_{jm}$$

Portanto a correlação entre duas variáveis é alta se elas tem altas cargas no mesmos fatores.

Correlação entre \mathbf{x}_i e \mathbf{F}_j : $\text{Corr}(\mathbf{x}_i \mathbf{F}_j) = a_{ij}$ (carga fatorial)

Como na análise de componentes principais, é interessante obter um número de fatores menor que o número de variáveis. Veremos então o procedimento para realizar uma análise factorial.

Semelhança: ambas buscam uma estrutura mais simples de variáveis (menor número de variáveis).

Diferenças:

- **CP** são combinações lineares das variáveis originais. Na **AF**, as variáveis originais são combinações lineares dos fatores.
- Na análise de **CP**, busca-se explicar a variância total dos dados. Em **AF**, busca-se explicar as correlações (ou covariância) entre variáveis.

Uma das maneiras de encontrar os fatores é por componentes principais

Na AF, após analisar a correlação entre variáveis, é feito um agrupamento das variáveis num número menor de variáveis (denominadas fatores)

Modelo matemático: Spearman - As variações em x_i podem ser explicadas a partir de um conjunto de fatores F_j

$$x_i = a_{i1} F_1 + a_{i2} F_2 + a_{i3} F_3 + \dots + a_{im} F_m + \varepsilon_i$$

- a_{ij} são as cargas fatoriais que medem o grau de correlação entre a variável original e os fatores.
- a carga factorial ao quadrado representa o quanto da variação de uma variável é explicado pelo fator:

$$a_{ij}^2 : \text{variação de } x_i \text{ explicado pelo fator } F_j$$

Os fatores, por sua vez, poderiam ser estimados por uma combinação linear das variáveis originais.

$$F_j = b_{j1}x_1 + b_{j2}x_2 + \dots + b_{ji}x_i$$

Sendo.

- F_j os fatores comuns não relacionados entre si;
- b_{ji} os **coeficientes dos escores fatoriais** e
- x_i as variáveis originais envolvidas no estudo.

O **escore factorial** é um número resultante da multiplicação dos coeficientes b_{ji} pelo valor das variáveis originais .

Considerando a expressão para \mathbf{F}_j :

$$\mathbf{F}_j = b_{j1}\mathbf{x}_1 + b_{j2}\mathbf{x}_2 + \dots + b_{ji}\mathbf{x}_i$$

podemos obter o escore fatorial para todas as observações

Ou seja, para uma determinada observação, o **escore fatorial** é um número resultante da multiplicação dos coeficientes b_{ji} pelo valor das variáveis originais desta observação.

Análise Fatorial – Exemplo clientes de um banco

Na Análise de Componentes Principais vimos um exemplo:

SSE OC

$$\mathbf{X} = \begin{bmatrix} 7 & 6 \\ 1 & 4 \\ 3 & 4 \\ 3 & 5 \\ 6 & 6 \\ 4 & 5 \end{bmatrix}$$

Matriz Covariância

$$\mathbf{S} = \begin{bmatrix} 4,8 & 1,8 \\ 1,8 & 0,8 \end{bmatrix}$$

Matriz Correlação

$$\mathbf{R} = \begin{bmatrix} 1 & 0,919 \\ 0,919 & 1 \end{bmatrix}$$

$$\text{Variância Total} = \text{Tr} (\mathbf{S}) = 4,8 + 0,8 = 5,6$$

Autovalores de \mathbf{S}

$$\lambda_1 = 5,491$$

$$\lambda_2 = 0,109$$

Autovetores

$$\mathbf{e}_1 = \begin{bmatrix} 0,9336 \\ 0,3583 \end{bmatrix}$$

$$\mathbf{e}_2 = \begin{bmatrix} 0,3583 \\ -0,9336 \end{bmatrix}$$

Componentes Principais:

$$\text{CP}_1 = 0,9336 X_1 + 0,3583 X_2$$


$$\text{CP}_2 = 0,3583 X_1 - 0,9336 X_2$$

Correlações entre CP e x


	SSE	OC
CP ₁	0,9985	0,9387
CP ₂	0,0540	-0,3446

Na Análise Fatorial, utilizaremos o SPSS para este exemplo:


Analyze > Dimension Reduction > Factor:



Scores:





Extraction:



Rotation:

Importante:
Em geral é analisada a **matriz de correlação!**
Neste exemplo utilizei a análise pela **matriz de covariância.**



Resultado AF no SPSS:

Descriptive Statistics

	Mean	Std. Deviation	Analysis N
SSE	4,00	2,191	6
OC	5,00	,894	6

Inverse of Covariance Matrix

	SSE	OC
SSE	1,333	-3,000
OC	-3,000	8,000

Correlation Matrix

		SSE	OC
Correlation	SSE	1,000	,919
	OC	,919	1,000
Sig. (1-tailed)	SSE		,005
	OC	,005	

Communalities

	Raw		Rescaled	
	Initial	Extraction	Initial	Extraction
SSE	4,800	4,800	1,000	1,000
OC	,800	,800	1,000	1,000

Extraction Method: Principal Component Analysis.


Total Variance Explained

Component	Initial Eigenvalues ^a			Extraction Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
Raw	1	5,491	98,049	98,049	5,491	98,049
	2	,109	1,951	100,000	,109	1,951
Rescaled	1	5,491	98,049	98,049	1,878	93,901
	2	,109	1,951	100,000	,122	6,099

Extraction Method: Principal Component Analysis.

SPSS – Variáveis em termos de Fatores

Resultado AF no SPSS:



	Componente	
	Fator 1	Fator 2
SSE	2,188	-0,118
OC	0,839	0,309

	Variação Explicada	Comunalidade h_i^2	
SSE	4,787	0,014	h_1^2
OC	0,704	0,095	h_2^2
Total	5,491	0,109	5,60
	λ_1	λ_2	Autovalores

	Raw		Rescaled	
	Component		Component	
	1	2	1	2
SSE	2,188	-,118	,999	-,054
OC	,839	,309	,939	,345

Extraction Method: Principal Component Analysis.

a. 2 components extracted.

Variáveis em termos de fatores:

$$SSE = 2,188 F_1 - 0,118 F_2 + \varepsilon_1$$

$$OC = 0,839 F_1 + 0,309 F_2 + \varepsilon_2$$

Cargas fatoriais a_{ij}

Cálculo das comunalidades

Para a variável SSE:

$$h_1^2 = (2,188)^2 + (-0,118)^2 = 4,80$$

Para a variável OC:

$$h_2^2 = (0,839)^2 + (0,095)^2 = 0,80$$

Quais variáveis são mais relacionadas a quais fatores?
Olhar a maior correlação (cargas mais altas em módulo)
entre uma dada variável e os fatores.

Variáveis em termos de fatores:

$$\text{SSE} = 2,188 F_1 - 0,118 F_2$$

$$\text{OC} = 0,839 F_1 + 0,309 F_2$$

As duas variáveis são mais relacionadas ao Fator 1.
Obs. A expressão vale para variáveis normalizadas

SPSS – Fatores em termos de Variáveis

Resultado AF no SPSS:

Escore Fatorial (novas variáveis)

$$F_1 = 0,873 Z_{SSE} + 0,137 Z_{OC}$$

$$F_2 = -2,374 Z_{SSE} + 2,526 Z_{OC}$$

**Component Score
Coefficient Matrix^a**

	Component	
	1	2
SSE	,873	-2,374
OC	,137	2,526

Extraction Method: Principal Component Analysis.
Component Scores.

a. Coefficients are standardized.

	SSE	OC	FAC1_1	FAC2_1	V
1	7	6	1,34819	-,42706	
2	1	4	-1,34819	,42706	
3	3	4	-,55133	-1,74051	
4	3	5	-,39843	1,08378	
5	6	6	,94976	,65673	
6	4	5	,0	,0	
7					

	SSE	OC	Z_SSE	Z_OC	F1	F2
7	6	1,3693	1,1180	1,3482	-0,4271	
1	4	-1,3693	-1,1180	-1,3482	0,4271	
3	4	-0,4564	-1,1180	-0,5513	-1,7405	
3	5	-0,4564	0,0000	-0,3984	1,0838	
6	6	0,9129	1,1180	0,9498	0,6567	
4	5	0,0000	0,0000	0,0000	0,0000	

Média 4 5

Desv. Pad 2,1909 0,8944