

Análise de correlações canônicas

Prof. Caio Azevedo

24 de novembro de 2009

- Construir variáveis que preservem uma parte da variabilidade e que concentrem, em poucas delas, a estrutura de correlação das variáveis originais.
- Variáveis canônicas:
 - $\mathbf{U}_{(p \times p)} = \mathbf{A}_{(p \times p)} \mathbf{X}_{(p \times 1)}^{(1)}$ e $\mathbf{U}_{(q \times q)} = \mathbf{B}_{(q \times q)} \mathbf{X}_{(q \times 1)}^{(2)}$.
 - $\mathbf{U}_{(p \times p)}^{(Z)} = \mathbf{A}_{(p \times p)}^{(Z)} \mathbf{Z}_{(p \times 1)}^{(1)}$ e $\mathbf{U}_{(q \times q)}^{(Z)} = \mathbf{B}_{(q \times q)}^{(Z)} \mathbf{Z}_{(q \times 1)}^{(2)}$.
- Em geral, trabalha-se com as variáveis canônicas obtidas a partir das variáveis padronizadas: interpretação, menor influência das médias, e menor influência das variâncias.

■ Equações:

$$U_1^{(Z)} = a_{11}^{(Z)} Z_1^{(1)} + a_{12}^{(Z)} Z_2^{(1)} + \dots + a_{1p}^{(Z)} Z_p^{(1)}$$

$$U_2^{(Z)} = a_{21}^{(Z)} Z_1^{(1)} + a_{22}^{(Z)} Z_2^{(1)} + \dots + a_{2p}^{(Z)} Z_p^{(1)}$$

⋮

$$U_p^{(Z)} = a_{p1}^{(Z)} Z_1^{(1)} + a_{p2}^{(Z)} Z_2^{(1)} + \dots + a_{pp}^{(Z)} Z_p^{(1)}$$

$$V_1^{(Z)} = b_{11}^{(Z)} Z_1^{(2)} + b_{12}^{(Z)} Z_2^{(2)} + \dots + b_{1q}^{(Z)} Z_q^{(2)}$$

$$V_2^{(Z)} = b_{21}^{(Z)} Z_1^{(2)} + b_{22}^{(Z)} Z_2^{(2)} + \dots + b_{2q}^{(Z)} Z_q^{(2)}$$

⋮

$$V_q^{(Z)} = b_{q1}^{(Z)} Z_1^{(2)} + b_{q2}^{(Z)} Z_2^{(2)} + \dots + b_{qq}^{(Z)} Z_q^{(2)}$$

- Magnitude dos "coeficientes canônicos".
- Correlação entre as variáveis canônicas e as variáveis originais: $Cor(\mathbf{Z}^{(1)}, \mathbf{U}^{(Z)}) = \mathbf{A}^{(Z)} \boldsymbol{\rho}_{11}$,
 $Cor(\mathbf{Z}^{(2)}, \mathbf{V}^{(Z)}) = \mathbf{B}^{(Z)} \boldsymbol{\rho}_{22}$.
- Proporção da variabilidade de cada v.c. explicada pelas variáveis originais $(\lambda_1^2, \lambda_2^2, \dots, \lambda_k^2)'$.
- Proporção da soma das variâncias das variáveis originais explicada pelas v.c.'s $Cov(\mathbf{Z}^{(1)}) = \mathbf{A}^{(Z)-1} \mathbf{A}'^{(Z)-1}$,
 $Cov(\mathbf{Z}^{(2)}) = \mathbf{B}^{(Z)-1} \mathbf{B}'^{(Z)-1}$. Com k variáveis canônicas,
 $\sum_{i=1}^p Var(Z_i^{(1)}) = p \cong tr(\mathbf{A}_k'^{(Z)-1} \mathbf{A}_k^{(Z)-1})$ e
 $\sum_{i=1}^p Var(Z_i^{(2)}) = p \cong tr(\mathbf{B}_k'^{(Z)-1} \mathbf{B}_k^{(Z)-1})$.

- Quantidade de nutrientes, vitaminas e outros compostos alimentares em porções (100 gramas?).
- Várias marcas de cereal.
- Variáveis escolhidas: calorias, proteína, gordura, fibra, sódio, carboidrato, açúcar, potássio.
- Como as variáveis "nutricionais" (calorias, proteína, gordura, fibra) se relacionam com as as variáveis "elementais" (sódio, carboidrato, açúcar, potássio).


■ Medidas descritivas: variáveis nutricionais

Estatística	Cal	Proteína	Gordura	Fibra
Média	149.4	3.69	1.42	3.87
D.P.	62.41	2.64	1.65	6.13
C.V (%)	41.72	71.74	115.80	6.13
Mínimo	50.00	0.76	0.00	0.00
Máximo	440.00	12.12	9.09	30.03


■ Medidas descritivas: variáveis elementais

Estatística	Sódio	Carb	Açucar	Potássio
Média	237.80	19.97	10.05	159.10
D.P.	130.63	8.46	5.83	180.29
C.V (%)	54.92	42.41	58.05	113.30
Mínimo	0.00	10.53	0.00	15.00
Máximo	787.90	68.00	20.90	969.70

■ Box plot: variáveis nutricionais



■ Box plot: variáveis elementais







■ Histograma: variáveis elementais

Análise de correlações canônicas)

Análise de correlações canônicas)

Número de variáveis canônicas)

Dados)







■ Histograma: variáveis elementais

Análise de correlações canônicas)

Análise de correlações canônicas)

Número de variáveis canônicas)

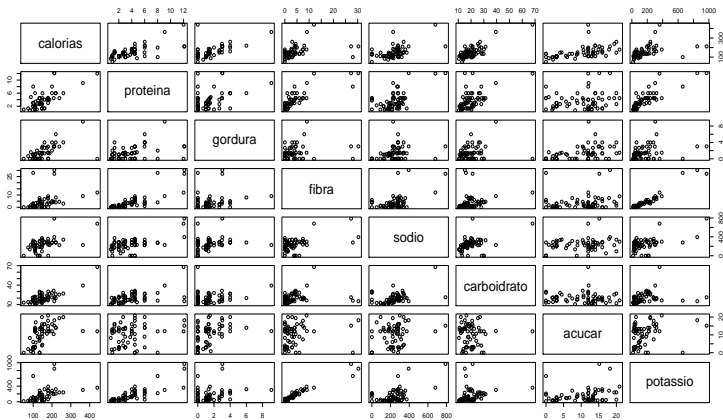
Dados)



Análise de correlações canônicas

Prof. Caio Azevedo

■ Gráfico de dispersão



Análise de correlações canônicas)

Análise de correlações canônicas)

Número de variáveis canônicas)

Dados)

- Solução considerando dois pares:
- Correlação canônicas: $\hat{\lambda}_1 = 0.99$, $\hat{\lambda}_2 = 0.97$
- Percentual da variabilidade explicada de cada variável canônica $(U_1^{(Z)}, V_1^{(Z)}) = \hat{\lambda}_1^2 = 0.97$ e $(U_2^{(Z)}, V_2^{(Z)}) = \hat{\lambda}_2^2 = 0.95$.
- Proporção das somas das variâncias explicadas: $\mathbf{Z}^{(1)} = 0.75$ e $\mathbf{Z}^{(2)} = 0.59$.

■ Coeficientes Canônicos:

$$U_1^{(Z)} = 1.31(0.77)\text{cal} - 0.23(0.17)\text{prot} - 0.32(0.25)\text{gordura} - 0.47(0.22)\text{fibra}$$

$$V_1^{(Z)} = 0.03(0.24)\text{sodio} + 0.89(0.76)\text{carb} + 0.57(0.41)\text{acucar} - 0.52(-0.13)\text{potassio}$$


$$U_2^{(Z)} = 0.19(0.59)\text{cal} + 0.15(0.91)\text{prot} - 0.01(0.34)\text{gordura} + 0.77(0.96)\text{fibra}$$

$$V_2^{(Z)} = -0.02(0.58)\text{sodio} + 0.17(0.39)\text{carb} - 0.01(0.24)\text{acucar} + 0.96(0.98)\text{potassio}$$

- A variável canônica $U_1^{(Z)}$ é um contraste entre caloria e proteína - gordura - fibra.
- A variável canônica $V_1^{(Z)}$ é um contraste entre açúcar e carboidrato - potássio.
- A variável canônica $U_2^{(Z)}$ é uma média ponderada entre caloria-proteína-fibra.
- A variável canônica $V_2^{(Z)}$ é uma média ponderada entre carboidrato e potássio.

- Carboidrato, açúcar e potássio influenciam (conjuntamente), no comportamento de todas variáveis nutricionais.
- Carboidrato e potássio influenciam (conjuntamente), no comportamento de quantidade de caloria, proteína e fibra.
- Gordura e açúcar parecem ter algum tipo de influência mútua.
- Um modelo de regressão normal linear simples, entre $U_1^{(Z)}$ e $V_1^{(Z)}$ com intercepto nulo, revela que o aumento de uma unidade da variável $V_1^{(Z)}$ implica, em média, no aumento de uma unidade na variável $U_1^{(Z)}$. O modelo se ajustou adequadamente aos dados (estrutura linear e suposição de normalidade).

■ Dispersão entre $U_1^{(Z)}$ e $V_1^{(Z)}$



■ Dispersão entre $U_1^{(Z)}$ e $V_2^{(Z)}$

