

MAE 5776

ANÁLISE MULTIVARIADA

Júlia M Pavan Soler

pavan@ime.usp.br

1º Sem/2020 - IME

Análise Multivariada

😊 Já vimos

- Análise Descritiva Multivariada
- Elipsóides de Dispersão e de Confiança, MANOVA
- Metodologias Clássicas de redução de dimensionalidade: $Y_{n \times p}$; $\mathbb{R}^p \rightarrow \mathbb{R}^m$
- ✓ ACP ($m \leq \min(n, p)$), ACoP ($m \leq \min(n, p)$), AC ($m \leq \min(I-1, J-1)$), AF ($m \leq \min(n, p)$)
- ✓ AG
- ✓ AD ($m \leq \min(n, p, G-1)$), ACC ($m \leq \min(n, p, q)$)
- ✓ Soluções Duais ($\mathbb{R}^{n \times p}$, $\mathbb{R}^{p \times p}$, $\mathbb{R}^{n \times n}$), Representações Biplot
- ✓ PCR (Regressão via CP), PLS (Regressão via MQ Parciais)
- Integração de Bancos de Dados - Diagrama de Caminhos (Grafos)

Var. quantitativas
 $n > p$
Obs iid

Caso: $n \ll p$ (**big p**): Soluções Regularizadas e Penalizadas

⇒ Componentes Principais (ACP)

⇒ Análise Discriminante (AD)

⇒ Correlação Canônica (ACC)

Métodos via Fatoração de Matrizes
e via Modelos de Regressão!

Caso: observações “dependentes” ⇒ dados de famílias
(indivíduos e seus familiares)

⇒ Componentes Principais de Herdabilidade (PCH)

Matriz de Dados

| Unidades Amostras | Variáveis | | | | | |
|-------------------|-----------|----------|-----|----------|-----|----------|
| | 1 | 2 | ... | j | ... | p |
| 1 | Y_{11} | Y_{12} | ... | Y_{1j} | ... | Y_{1p} |
| 2 | Y_{21} | Y_{22} | ... | Y_{2j} | ... | Y_{2p} |
| ... | ... | ... | ... | ... | ... | ... |
| i | Y_{i1} | Y_{i2} | ... | Y_{ij} | ... | Y_{ip} |
| ... | ... | ... | ... | ... | ... | ... |
| n | Y_{n1} | Y_{n2} | ... | Y_{nj} | ... | Y_{np} |

- Amostra Aleatória Simples de n-Vetores em \mathcal{R}^p

$$Y_{n \times p} \in \mathcal{R}^{n \times p}; \quad Y_i \in \mathcal{R}^p \stackrel{iid}{\sim} (\mu; \Sigma)$$

Já vimos vários resultados sob a formalização de observações independentes (AASn)!

Casos mais gerais:

- Considere G Amostras Aleatórias de observações em $\mathcal{R}^{n_g \times p}$

(AAS_G)



$$(g = 1, \dots, G; \sum_g n_g = n)$$

Motivação – Dados de Base Familiar

Projeto Corações de Baependi, MG

Mapear “Genes” associados a fatores de risco cardiovascular na População Brasileira


- Amostragem de domicílios de Baependi, MG (2006-)
- Amostra: 1.712 indivíduos de 119 famílias
- Tamanho das famílias: 21 ± 26
- Gerações: 2 - 4
- Número de filhos: 3 ± 2
- Núcleos familiares: 631
- Gênero: M(43,5%) F(56,5%)



Nos membros de todas as famílias, muitas variáveis foram avaliadas (fenótipos, genótipos, dentre outras).

Motivação – Dados de Base Familiar

$Y_{n \times p}$ Observações em \mathbb{R}^p correlacionadas devido à estrutura familiar (grau de parentesco entre indivíduos)



⇒ Modelar a dependência entre observações do mesma família (*cluster*):
Matriz de parentesco

$$\Psi_g = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \\ 7 \end{matrix} & \begin{bmatrix} 1 & 0 & \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & 0 & \frac{1}{4} \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & 0 & \frac{1}{4} \\ \frac{1}{2} & \frac{1}{2} & 1 & \frac{1}{2} & \frac{1}{2} & 0 & \frac{1}{4} \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & 1 & \frac{1}{2} & 0 & \frac{1}{4} \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & 1 & 0 & \frac{1}{2} \\ 0 & 0 & 0 & 0 & 0 & 1 & \frac{1}{2} \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{2} & \frac{1}{2} & 1 \end{bmatrix} \end{matrix}$$

$$\Psi_{n \times n} = I_G \otimes_{g=1}^G \Psi_g$$

⇒ Modelar a dependência entre observações do mesmo indivíduo (vetor em \mathbb{R}^p): Matriz de correlação entre variáveis ($\Sigma_{p \times p}$)

$$\Omega_{np \times np} = \Psi_{n \times n} \otimes \Sigma_{p \times p}$$

| Família | Unidade Amostral | Y_1 | Y_2 | ... | Y_p |
|------------------------------|------------------|----------------|----------------|-----|----------------|
| 1 | 1 | Y_{111} | Y_{112} | | Y_{11p} |
| 1 | 2 | Y_{121} | Y_{122} | | Y_{12p} |
| ... | ... | | | | |
| 1 | n_1 | Y_{1n11} | Y_{1n12} | | Y_{1n1p} |
| Médias da Família 1 | | \bar{Y}_{11} | \bar{Y}_{12} | | \bar{Y}_{1p} |
| ... | | | | | |
| G | 1 | Y_{G11} | Y_{G12} | | Y_{G1p} |
| G | 2 | Y_{G21} | Y_{G22} | | Y_{G2p} |
| ... | ... | | | | |
| G | n_G | Y_{GnG1} | Y_{GnG2} | | Y_{GnGp} |
| Médias da Família G | | \bar{Y}_{G1} | \bar{Y}_{G2} | | \bar{Y}_{Gp} |
| Vetor de Médias Geral | | $\bar{Y}_{.1}$ | $\bar{Y}_{.2}$ | | $\bar{Y}_{.p}$ |

Variáveis Aleatórias Multidimensionais

- Matriz aleatória (Gupta and Nagar, 2000):

Formulação matricial

$$Y_{n \times p} \sim N_{n,p}(M; \Psi \otimes \Sigma);$$

Formulações alternativas

Formulação vetorial

$$\text{vec}(Y)_{np \times 1} \sim N_{np}(\text{vec}(M); \Psi \otimes \Sigma)$$

$$Y_{n \times p} = (Y_{ij}) \in \mathfrak{R}^{n \times p};$$

$$M_{n \times p} = \mathbf{1}_n \mu'_{p \times 1} : \text{matriz de médias}$$

$$\text{vec}(M)_{np \times 1} = \mathbf{1}_n \otimes \mu_{p \times 1} : \text{vetor de médias de } n \text{ observações em } p \text{ variáveis}$$

$$(\Psi_{n \times n} \otimes \Sigma_{p \times p})_{np \times np} : \text{matriz de covariâncias}$$

Formulação flexível para diferentes modelagens

Matrizes de covariância Estruturadas: entre indivíduos (Ψ) e entre variáveis (Σ)

$$\Psi = I_n; \quad \Sigma = I_p$$

Observações e variáveis independentes

$$\Psi = I_n; \quad \Sigma = (1 - \rho) I_p + \rho \mathbf{1}_p \mathbf{1}'_p$$

Observações independentes e correlação uniforme entre as variáveis

$$\Psi = \bigoplus_{g=1}^G \left[(1 - \rho) I_{n_g} + \rho \mathbf{1}_{n_g} \mathbf{1}'_{n_g} \right]; \quad \Sigma = (\sigma_{jl})$$

Correlação uniforme entre observações agrupadas em G grupos

Correlação não estruturada entre variáveis

Matriz Aleatória

- Amostra Aleatória de n -Vetores em \mathfrak{R}^p

Já vimos!

$$Y_{n \times p} \in \mathfrak{R}^{n \times p}; \quad Y_i \in \mathfrak{R}^p \overset{iid}{\sim} (\mu_{p \times 1}; \Sigma_{p \times p})$$

- Amostra Aleatória de n -Vetores em \mathfrak{R}^p tal que

$$n = \sum_{g=1}^G n_g$$

n -Vetores estratificados em G grupos e com Correlação entre Observações dentro dos Estratos (grupos)

| Grupos | Unidades amostrais | Variáveis | | | | | |
|--------|--------------------|-----------|----------|-----|----------|-----|----------|
| | | 1 | 2 | ... | j | ... | p |
| 1 | 1 | Y_{11} | Y_{12} | ... | Y_{1j} | ... | Y_{1p} |
| | 2 | Y_{21} | Y_{22} | ... | Y_{2j} | ... | Y_{2p} |
| ... | ... | ... | ... | ... | ... | ... | ... |
| ... | i | Y_{i1} | Y_{i2} | ... | Y_{ij} | ... | Y_{ip} |
| G | ... | ... | ... | ... | ... | ... | ... |
| | n | Y_{n1} | Y_{n2} | ... | Y_{nj} | ... | Y_{np} |

$$Y_{n \times p} = \begin{pmatrix} Y_1 \\ \dots \\ Y_G \end{pmatrix}$$

$$Y_{g(n_g \times p)}$$

$$n = \sum_{g=1}^G n_g$$

$$Y_{n \times p} \in \mathfrak{R}^{n \times p}; \quad Y_g \in \mathfrak{R}^{n_g \times p} \overset{iid}{\sim} (\mu_g; \Omega_g)$$

$$\begin{cases} \mu_{g(n_g \times p)} = \mathbf{1}_{n_g} \otimes \mu'_{p \times 1} \\ \Omega_{g(n_g p \times n_g p)} = \Psi_g \otimes \Sigma_{p \times p} \end{cases}$$

Matriz Aleatória – Componentes de Covariâncias em $\mathfrak{R}^{p \times p}$

- Amostra Aleatória de G-Grupos em $\mathfrak{R}^{n_g \times p}$ ($g = 1, \dots, G; \sum_g n_g = n$)

$$Y_{n \times p} \in \mathfrak{R}^{n \times p}; \quad Y_g \in \mathfrak{R}^{n_g \times p} \stackrel{iid}{\sim} (\mu_g; \Omega_g) \begin{cases} \mu_{g(n_g \times p)} = \mathbf{1}_{n_g} \otimes \mu'_{p \times 1} \\ \Omega_{g(n_g p \times n_g p)} = \Psi_g \otimes \Sigma_{p \times p} \end{cases}$$

$$Y_{n \times p} \sim (\mu_{n \times p}; \Omega_{np \times np}) \begin{cases} \mu_{n \times p} = \left(\bigoplus_{g=1}^G \mathbf{1}_{n_g} \right) \otimes \mu'_{p \times 1} \\ \Omega_{np \times np} = \bigoplus_{g=1}^G (\Psi_g \otimes \Sigma_{p \times p}) = \left(\bigoplus_{g=1}^G \Psi_g \right) \otimes \Sigma_{p \times p} \end{cases}$$

Decompor $\mathfrak{R}^{p \times p}$ em Componentes de Covariâncias

$$\Sigma_{p \times p} = \Sigma_B + \Sigma_W$$

$$\Omega_{np \times np} = \left(\bigoplus_{g=1}^G \Psi_g \right) \otimes \Sigma \Rightarrow \Omega = \left(\bigoplus_{g=1}^G \Psi_g \right) \otimes \Sigma_B + I_n \otimes \Sigma_W$$

Σ_B : componente da covariância associado à dependência entre as n -observações
 Σ_W : componente da covariância associado à independência entre as n -observações

Componentes de Covariâncias em $\mathfrak{R}^{p \times p}$

$$Y_{n \times p} \sim (\mu_{n \times p}; \Omega_{np \times np}) \left\{ \begin{array}{l} \mu_{n \times p} = \bigoplus_{g=1}^G (\mathbf{1}_{n_g} \otimes \mu'_{g \ p \times 1}) \\ \Omega_{np \times np} = \left(\bigoplus_{g=1}^G \Psi_g \right) \otimes \Sigma_B + I_n \otimes \Sigma_W \end{array} \right.$$

$$\Omega_{np \times np} = \begin{bmatrix} \Psi_1 & & & 0 \\ & \Psi_2 & & \\ & & \dots & \\ & & & \Psi_G \end{bmatrix} \otimes \Sigma_B + \begin{bmatrix} I_{n_1} & & & 0 \\ & I_{n_2} & & \\ & & \dots & \\ & & & I_{n_G} \end{bmatrix} \otimes \Sigma_W$$

A matriz de covariância Σ é decomposta em dois componentes, um associado à suposição de correlação entre observações do mesmo grupo (Σ_B : matriz de covariância ENTRE grupos) e outro associado à independência condicional entre observações dado o grupo (Σ_W : matriz de covariância DENTRO de grupos)

Componentes Principais em Modelos de Componentes de Covariâncias

$$\text{Cov}(Y_g) = \Omega_g = \Psi_g \otimes \Sigma_B + I_{n_g} \otimes \Sigma_W; \quad \Sigma_B + \Sigma_W = \Sigma$$

$$PC_B \Rightarrow \max_{\|a\|=1} \frac{a \widehat{\Sigma}_B a}{a' a} \quad : \text{ direção com máxima variação entre grupos}$$

$$PC_W \Rightarrow \max_{\|a\|=1} \frac{a \widehat{\Sigma}_W a}{a' a} \quad : \text{ direção com máxima variação dentro dos grupos}$$

$$PCH \Rightarrow \max_{\|\Sigma_W^{1/2} a\|=1} \frac{a \widehat{\Sigma}_B a}{a' \Sigma a} = \max_{\|\Sigma_W^{1/2} a\|=1} \frac{a \widehat{\Sigma}_B a}{a' \widehat{\Sigma}_W a} \quad : \text{ direção com máxima variação entre e mínima variação dentro de grupos}$$



Obter estimativas dos Componentes de Covariância!

$$\widehat{\Sigma}_B, \quad \widehat{\Sigma}_W$$

Como são essas estimativas sob o modelo MANOVA clássico?

ANOVA – Efeito Fixo e Aleatório

Como obter estimativas de componentes de “variância”?
Recordando o caso $p=1$

$$Y_{gi} = \mu_g + e_{gi}$$

$$= \mu + \tau_g + e_{gi}; \quad i = 1, \dots, n_g, \quad g = 1, \dots, G$$

Modelo ANOVA de Efeitos Fixos

$$\sum_{g=1}^G \tau_g = 0 \quad \text{Restrições de identificabilidade.}$$

$$e_{gi} \stackrel{iid}{\sim} (0; \sigma^2)$$

$$\Rightarrow Y_{gi} \stackrel{iid}{\sim} (\mu_g; \sigma^2)$$

$$\text{Cov}(Y_{n \times 1}) = \begin{bmatrix} \sigma^2 & 0 & 0 & 0 \\ 0 & \sigma^2 & 0 & 0 \\ 0 & 0 & \dots & 0 \\ 0 & 0 & 0 & \sigma^2 \end{bmatrix} = \sigma^2 I_n$$

Modelo ANOVA de Efeitos Aleatórios

$$\tau_g \sim (0; \sigma_B^2) \quad \mu_g = \mu + \tau_g \sim (\mu; \sigma_B^2)$$

$$e_{gi} \sim (0; \sigma_W^2) \quad \tau_g \perp e_{gi}$$

σ_B^2 : é componente de variância e de covariância

$$\Rightarrow Y_{gi} \sim (\mu; \sigma^2 = \sigma_B^2 + \sigma_W^2)$$

$$\text{Cov}(Y_{gi}; Y_{g'i'}) = \begin{cases} \sigma_B^2 + \sigma_W^2; & i = i', g = g' \\ \sigma_B^2; & i \neq i', g = g' \\ 0; & i \neq i', g \neq g' \end{cases}$$

$$\text{Cov}(Y_{n \times 1}) = \begin{bmatrix} \sigma^2 & \sigma_B^2 & 0 & 0 \\ \sigma_B^2 & \sigma^2 & 0 & 0 \\ 0 & 0 & \dots & \sigma_B^2 \\ 0 & 0 & \sigma_B^2 & \sigma^2 \end{bmatrix} = \sigma^2 \begin{bmatrix} 1 & \rho & 0 & 0 \\ \rho & 1 & 0 & 0 \\ 0 & 0 & \dots & \rho \\ 0 & 0 & \rho & 1 \end{bmatrix}$$

$$\rho = \frac{\sigma_B^2}{\sigma_B^2 + \sigma_W^2}$$

Coefficiente de correlação intraclasse


Modelo ANOVA de um único Fator Aleatório (componentes de variância), sob Normalidade:

$$\mu_g = \mu + \tau_g \sim N(\mu; \sigma_B^2)$$

Recordando!
p=1

Distribuição condicional de Y:

$$\Rightarrow y_{gi} | g \sim N(\mu_g; \sigma_W^2)$$



$$H_0 : \sigma_B^2 = 0 \Leftrightarrow H_0 : \mu_g = \mu$$

Sob H_0 , os modelos de ANOVA com um fator aleatório ou um fator fixo são equivalentes (mesma tabela ANOVA)

Tabela de ANOVA

Recordando o caso $p=1$.
Tabela ANOVA é
equivalente para os
modelos de um fator fixo
ou um fator aleatório!

$$H_0 : \sigma_B^2 = 0 \Leftrightarrow H_0 : \mu_g = \mu$$

| F.V. | g.l. | SQ | QM | F |
|---------|------|--|------------------------|-----------------------|
| Grupo | G-1 | $S_b = \sum r (\bar{Y}_g - \bar{Y})^2$ | $QMGr = S_b / (G-1)$ | $\frac{QMGr}{QM Res}$ |
| Resíduo | n-G | $S_w = \sum_{gi} (Y_{gi} - \bar{Y}_g)^2$ | $QM Res = S_w / (n-G)$ | |
| TOTAL | n-1 | $S_T = \sum_{gi} (Y_{gi} - \bar{Y})^2$ | | |

$n_g = r$: Dados balanceados

Estimadores ANOVA dos
componentes de variância

$$E(QM Res) = \sigma_w^2 \Rightarrow$$

$$\hat{\sigma}_w^2 = QM Res$$

$$E(QMTr) = \sigma_w^2 + r \sigma_B^2 \Rightarrow$$

$$\hat{\sigma}_B^2 = \frac{QMTr - QM Res}{r}$$

$$F \sim F_{(G-1), (n-G)}$$

Componentes de Covariâncias em $\mathfrak{R}^{p \times p}$ Estruturas para Ψ em $\mathfrak{R}^{n \times n}$

- **Correlação Uniforme entre Observações** (Simetria Composta ou Equicorrelação)

(Konish and Rao, 1992)

$$Y_{n \times p} \in \mathfrak{R}^{n \times p}; \quad Y_g = Y_{n_g \times p} \in \mathfrak{R}^{n_g \times p} \stackrel{iid}{\sim} (\mu_g; \Omega_g) \begin{cases} \mu_g (n_g \times p) = \mathbf{1}_{n_g} \otimes \mu_g'_{p \times 1} \\ \Omega_g (n_g p \times n_g p) = \Psi_g \otimes \Sigma_{p \times p} \end{cases}$$

$$Cov(Y_{gi}, Y_{g'i'})_{(p \times p)} = \begin{cases} \Sigma = \Sigma_B + \Sigma_W & \text{se } g = g', i = i' \\ \Sigma_B & \text{se } g = g', i \neq i' \\ 0 & \text{se } g \neq g', i \neq i' \end{cases}$$

$\Psi_g = \mathbf{1}_{n_g} \mathbf{1}_{n_g}'$
 $\Sigma = \Sigma_B + \Sigma_W$

$$\Rightarrow Cov(Y_g)_{n_g p \times n_g p} = \Omega_g = (\mathbf{1}_{n_g} \mathbf{1}_{n_g}') \otimes \Sigma_B + I_{n_g} \otimes \Sigma_W$$

$$\Rightarrow Y_g \stackrel{iid}{\sim} \left(\mathbf{1}_{n_g} \otimes \mu_g'; \Omega_g = (\mathbf{1}_{n_g} \mathbf{1}_{n_g}') \Sigma_B + I_{n_g} \otimes \Sigma_W \right)$$

$$\Rightarrow Y_{n \times p} \sim \left(\bigoplus_{g=1}^G (\mathbf{1}_{n_g} \otimes \mu_g'); \Omega = \bigoplus_{g=1}^G \Omega_g \right)$$

Estimadores MANOVA

Equivalência analítica entre MANOVA com um Fator Fixo e MANOVA com um Fator Aleatório (sob equicorrelação)

$$\Rightarrow Y_g \stackrel{iid}{\sim} \left(\mathbf{1}_{n_g} \otimes \mu'_g; \Omega_g = (\mathbf{1}_{n_g} \mathbf{1}'_{n_g}) \Sigma_B + I_{n_g} \otimes \Sigma_W \right)$$

Tabela de MANOVA:

| F.V. | g.l. | Matriz de SQPC |
|---------|------|--|
| Trat | G-1 | $H_{p \times p} = \sum_{g=1}^G n_g (\bar{Y}_g - \bar{Y})(\bar{Y}_g - \bar{Y})' = S_b$ |
| Resíduo | n-G | $E_{p \times p} = \sum_{g=1}^G \sum_{i=1}^{n_g} (Y_{gi} - \bar{Y}_g)(Y_{gi} - \bar{Y}_g)' = S_w$ |
| TOTAL | n-1 | $H + E = \sum_{g=1}^G \sum_{i=1}^{n_g} (Y_{gi} - \bar{Y})(Y_{gi} - \bar{Y})'$ |

Sob $H_0 : \mu_g = \mu, \quad g = 1, \dots, G$

Estimadores MANOVA dos componentes de covariância

$$E\left(\frac{S_w}{n-G}\right) = \Sigma_W; \quad E\left(\frac{S_b}{G-1}\right) = \Sigma_W + n_0 \Sigma_B$$

$$n_0 = \frac{n - \left(\sum_g n_g^2 / n\right)}{G-1}$$

Componentes de Covariâncias em $\mathfrak{R}^{p \times p}$ Sob Correlação Uniforme entre Observações

Estimadores MANOVA dos
componentes de covariância

$$\Rightarrow \hat{\Sigma}_W = \frac{S_w}{n-G}; \quad \hat{\Sigma}_B = n_0^{-1} \left\{ \frac{S_b}{G-1} - \frac{S_w}{n-G} \right\}$$

$$\Rightarrow \hat{\Sigma} = \hat{\Sigma}_W + \hat{\Sigma}_B = n_0^{-1} \left\{ \frac{S_b}{G-1} + \frac{(n_0-1)S_w}{n-G} \right\}$$

$$n_0 = \frac{n - \left(\sum_g n_g^2 / n \right)}{G-1}$$

Componentes de Covariâncias em $\mathfrak{R}^{p \times p}$ Sob Correlação Uniforme entre Observações

Konishi and Rao, 1992; Oualkacha et al., 2012)

$$\Rightarrow Y_g \stackrel{iid}{\sim} \left(\mathbf{1}_{n_g} \otimes \boldsymbol{\mu}'_g; \Omega_g = (\mathbf{1}_{n_g} \mathbf{1}_{n_g}') \Sigma_B + I_{n_g} \otimes \Sigma_W \right); \quad \hat{\Sigma}_{p \times p} = \hat{\Sigma}_{B_{p \times p}} + \hat{\Sigma}_{W_{p \times p}}$$

$$PC_g \Rightarrow \max_a \frac{a' \hat{\Sigma}_B a}{a' a}, \quad a' a = 1 \quad \text{Direção com máxima variação Entre grupos}$$

$$PC_e \Rightarrow \max_a \frac{a' \hat{\Sigma}_W a}{a' a}, \quad a' a = 1 \quad \text{Direção com máxima variação Dentro de grupos}$$

$$PC_T \Rightarrow \max_a \frac{a' \hat{\Sigma} a}{a' a} = \max_a \frac{a' [\hat{\Sigma}_B + \hat{\Sigma}_W] a}{a' a}, \quad a' a = 1 \quad \text{Direção com máxima variação Total}$$

$$PCH \Rightarrow \max_a \frac{a' \hat{\Sigma}_B a}{a' [\hat{\Sigma}_B + \hat{\Sigma}_W] a} = \max_a \frac{a' \hat{\Sigma}_B a}{a' \hat{\Sigma}_W a},$$

$a' \hat{\Sigma}_W a = 1$ Direção com máxima variação Entre grupos e mínima variação Dentro

Componente
Principal de
Herdabilidade

Componentes Principais em Modelos de Componentes de Covariâncias

Correlação uniforme (equicorrelação)

$$\Rightarrow Y_g \stackrel{iid}{\sim} \left(\mathbf{1}_{n_g} \otimes \mu'_g; \Omega_g = (\mathbf{1}_{n_g} \mathbf{1}_{n_g}') \Sigma_B + I_{n_g} \otimes \Sigma_W \right) (**)$$

$$PCH \Rightarrow \max_a \frac{a \hat{\Sigma}_B a}{a \hat{\Sigma}_W a}$$

: Componentes Principais de Herdabilidade (PCH: direção com máxima variação Entre e mínima variação Dentro de grupos)


$$\Rightarrow \hat{\Sigma}_W = \frac{S_w}{n-G}; \quad \hat{\Sigma}_B = n_0^{-1} \left\{ \frac{S_b}{G-1} - \frac{S_w}{n-G} \right\} \quad n_0 = \frac{n - \left(\sum_g n_g^2 / n \right)}{G-1}$$

Os PCH de dados correlacionados (sob **) correspondem às direções da Análise Discriminante sob obs. independentes!

Obter os autovalores e autovetores (V) de $\hat{\Sigma}_W^{-1} \hat{\Sigma}_B \Rightarrow PCH = YV$

Componentes Principais-Componentes de Covariância Soluções Regularizadas

Ilustração do padrão de dispersão entre e dentro de grupos



(Wang, 2007)

Elipse vertical: corresponde à variabilidade dentro dos grupos (famílias)

Elipse maior: corresponde à variação entre grupos (famílias)

$$PCH_{\lambda} \Rightarrow \max_{a, \lambda > 0} \frac{a' \hat{\Sigma}_B a}{a' \hat{\Sigma}_W a + \lambda \|a\|^2} = \max_{a, \lambda > 0} \frac{a' \hat{\Sigma}_B a}{a' [\hat{\Sigma}_W + \lambda I_p] a}$$

$\lambda=0$: solução não regularizada do PCH

$\lambda=\infty$: solução do PCH próxima à solução para Σ_B . (maximização entre grupos)

Solução Regularizada ($n < p$). Como estimar o parâmetro de regularização λ ?

Componentes Principais-Componentes de Covariância Soluções Regularizadas

Algoritmo para estimação do parâmetro de regularização λ

Passo 1: Partição dos grupos em dois sub-grupos: Grupo 1 e Grupo 2.
(Repetir L=50 vezes)

Passo 2: Grupo1: para $\lambda=0.01$, obter o j-ésimo autovetor $V_{j\lambda}^{(1)l}$ de $(\hat{\Sigma}_W + \lambda I_p)^{-1/2}$.

Será necessário substituir os autovalores negativos por "0" (Amemiya, 1985).

Grupo2: obter as estimativas $\hat{\Sigma}_B^{(2)l}$, $\hat{\Sigma}_W^{(2)l}$;

Passo 3. Repetir para $\lambda = 0.01, 2, 4, \dots, 1000$. O parâmetro de regularização é estimado como:

$$\lambda_{CV} = \arg \max_{\lambda} \frac{1}{L} \sum_{l=1}^L \frac{V_{j\lambda}^{(1)l'} \hat{\Sigma}_B^{(2)l} V_{j\lambda}^{(1)l}}{V_{j\lambda}^{(1)l'} \hat{\Sigma}_W^{(2)l} V_{j\lambda}^{(1)l}} ; \quad PCH_{\lambda_{CV}} = Ya'; \max_a \frac{a' \hat{\Sigma}_B a}{a' [\hat{\Sigma}_W + \lambda_{CV} I_p] a}$$


Componentes Principais-Componentes de Covariâncias

Correlação Familiar

Matriz de covariância mais geral entre obs.!


$Y_{n \times p}$ Observações correlacionadas devido à estrutura familiar (grau de parentesco entre indivíduos)

Modelo de Componentes de Covariância

$$\Rightarrow Cov(Y_g) = \Omega_g = \Psi_g \otimes \Sigma_B + I_{n_g} \otimes \Sigma_W$$

Matriz de parentesco (não é uniforme)

$$\Psi_g = \begin{matrix} & \begin{matrix} 1 & 2 & 3 & 4 & 5 & 6 & 7 \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ 3 \\ 4 \\ 5 \\ 6 \\ 7 \end{matrix} & \begin{bmatrix} 1 & 0 & \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & 0 & \frac{1}{4} \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & 0 & \frac{1}{4} \\ \frac{1}{2} & \frac{1}{2} & 1 & \frac{1}{2} & \frac{1}{2} & 0 & \frac{1}{4} \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & 1 & \frac{1}{2} & 0 & \frac{1}{4} \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & 1 & 0 & \frac{1}{2} \\ 0 & 0 & 0 & 0 & 0 & 1 & \frac{1}{2} \\ \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{4} & \frac{1}{2} & \frac{1}{2} & 1 \end{bmatrix} \end{matrix}$$



| Família | Unidade Amostral | Y_1 | Y_2 | ... | Y_p |
|------------------------------|------------------|----------------|----------------|-----|----------------|
| 1 | 1 | Y_{111} | Y_{112} | | Y_{11p} |
| 1 | 2 | Y_{121} | Y_{122} | | Y_{12p} |
| ... | ... | | | | |
| 1 | n_1 | Y_{1n11} | Y_{1n12} | | Y_{1n1p} |
| Médias da Família 1 | | \bar{Y}_{11} | \bar{Y}_{12} | | \bar{Y}_{1p} |
| ... | | | | | |
| G | 1 | Y_{G11} | Y_{G12} | | Y_{G1p} |
| G | 2 | Y_{G21} | Y_{G22} | | Y_{G2p} |
| ... | ... | | | | |
| G | n_G | Y_{GnG1} | Y_{GnG2} | | Y_{GnGp} |
| Médias da Família G | | \bar{Y}_{G1} | \bar{Y}_{G2} | | \bar{Y}_{Gp} |
| Vetor de Médias Geral | | $\bar{Y}_{.1}$ | $\bar{Y}_{.2}$ | | $\bar{Y}_{.p}$ |

Componentes Principais-Componentes de Covariâncias Correlação Familiar

Estimadores MANOVA do Modelo de Componentes de Covariância: são funções lineares de S_b e S_w (Oualkacha et al., 2012)

$$\hat{\Sigma}_B = \frac{S_b / (G-1) - S_w / (n-G)}{(\tau_c - \tau_b / n) / (G-1) - (\tau_a - \tau_c) / (n-G)}$$

$$\hat{\Sigma}_W = \frac{1}{(n-G)} S_w - \frac{(\tau_a - \tau_c)}{(n-G)} \hat{\Sigma}_B$$

$$n = \sum_{g=1}^G n_g, \quad \tau_a = \sum_{g=1}^G \tau_{a_g}, \quad \tau_b = \sum_{g=1}^G \tau_{b_g}, \quad \tau_c = \sum_{g=1}^G \frac{1}{n_g} \tau_{b_g}$$

$$\tau_{a_g} = 2\text{Trace}[\Phi_g], \quad \tau_{b_g} = 2 \sum_{\substack{i'=1 \\ i'>i}}^{n_g} \sum_{i=1}^{n_g} (\Phi_g)_{ii'}$$

Componentes Principais-Componentes de Covariância Correlação Familiar (de Andrade et al., 2015)



Aplicação: Projeto Corações de Baependi (MG)

n=1.109 indivíduos de G=80 famílias e p=8.764 variáveis genéticas (SNPs)

PC sob Independência: $PC \Rightarrow \max_{\|a\|=1} \frac{a'Sa}{a'a}$

PCH $\Rightarrow \max_{\|S_W^{-1/2}a\|=1} \frac{a'S_B a}{a'S_W a}$

Solução mais adaptativa



Proporção da variância explicada pelos PC1 e PCH1

| CP | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
|---------------|-------|-------|-------|--------|--------|--------|--------|--------|--------|--------|
| S | 0.022 | 0.014 | 0.008 | 0.0069 | 0.0068 | 0.0061 | 0.0059 | 0.0055 | 0.0053 | 0.005 |
| $S_W^{-1}S_B$ | 0.086 | 0.070 | 0.035 | 0.031 | 0.028 | 0.026 | 0.0255 | 0.0249 | 0.0246 | 0.0239 |


Componentes Principais-Componentes de Covariâncias Correlação Familiar

Aplicação: Projeto Corações de Baependi (MG)
Componentes Principais da Síndrome Metabólica (doença multifatorial: $p=6$)

Calcular o PCH1 (variável latente da SM)

$$Y_g \sim \left(\mathbf{1}_{n_g} \mu_g'; \Psi_g \otimes \Sigma_B + I_n \otimes \Sigma_W \right)$$

$$\max_a \frac{a' \hat{\Sigma}_B a}{a' \hat{\Sigma}_W a} \quad PCH = a' Y_{6 \times 1}$$



| Var. | ObTr | Glic | Triglic | HDL | SBP | DBP | PCH1 |
|-----------------|-------|-------|---------|-------|-------|-------|-------------|
| ρ | 0,16 | 0,12 | 0,35 | 0,30 | 0,18 | 0,13 | 0,36 |
| $\rho(Y, PCH1)$ | -0,23 | -0,34 | -0,93 | -0,28 | -0,35 | -0,39 | |

$$\rho = \frac{\sigma_B^2}{\sigma_B^2 + \sigma_W^2}$$

Coef. de correlação
intraclasse

Componentes Principais em Dados de Famílias

Minicurso: Oficina - R


Visualização
do PCH!

- Gerar dados com **estrutura familiar** aleatória com **vetor de médias** e **matrizes de covariância** conhecidas ($p=2$)

$$Y_g \in \mathbb{R}^2; Y_g \sim N\left(\mathbf{1}_{n_g} \mu_g'; \Psi_g \otimes \Sigma_B + I_n \otimes \Sigma_W\right)$$

- Obter as estimativas das matrizes de covariância e os seguintes Componentes Principais ($a'Y$):

$$\max_a \frac{a' \hat{\Sigma}_B a}{a' \hat{\Sigma}_W a}$$



Exemplo 1: Σ_B e Σ_W com correlações positivas (0,30 e 0,25, respectivamente) e variáveis (fenótipos) com correlação intraclasse moderada (0,40 a 0,70).


Exemplo 2: Σ_B e Σ_W com correlações de sinais opostos (0,30 e -0,25, respectivamente) e variáveis (fenótipos) com correlação intraclasse moderada (0,40 a 0,70).

Exemplo 3: Σ_B e Σ_W com correlações negativas (-0,90 e -0,80, respectivamente) e variáveis (fenótipos) com correlação intraclasse moderada (0,40 a 0,70).


Componentes Principais em Dados de Famílias Oficina - R

Visualização
do PCH!


Exemplo 1



Exemplo 2



Exemplo 3



Preto: reta de MQO

Vermelho: CP maximizando a variabilidade ENTRE famílias (S_B)

Azul: Componente Principal de Herdabilidade (PCH: maximiza $S_W^{-1}S_B$)