



SME0822 Análise Multivariada e Aprendizado Não-Supervisionado

Aula 4c: **Inferência sobre a média**

Prof. Cibele Russo

cibele@icmc.usp.br

<http://www.icmc.usp.br/~cibele>

Baseado em Johnson, R. A., & Wichern, D. W. (2007). Applied Multivariate Statistical Analysis. Prentice Hall.

Estimação de parâmetros

Sejam $\underline{X}_1, \dots, \underline{X}_n$ vetores que representam uma amostra aleatória de uma distribuição $N_p(\underline{\mu}, \Sigma)$. A função densidade de probabilidade conjunta de $\underline{X}_1, \dots, \underline{X}_n$ é dada por

$$\begin{aligned} f(\underline{x}_1, \dots, \underline{x}_n) &= \prod_{j=1}^n \frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}} \exp \left\{ -\frac{(\underline{x}_j - \underline{\mu})^\top \Sigma^{-1} (\underline{x}_j - \underline{\mu})}{2} \right\} \\ &= \frac{1}{(2\pi)^{np/2} |\Sigma|^{n/2}} \exp \sum_{j=1}^n \left\{ -\frac{(\underline{x}_j - \underline{\mu})^\top \Sigma^{-1} (\underline{x}_j - \underline{\mu})}{2} \right\}. \end{aligned}$$

Estimação de parâmetros

Resultado

Seja $A_{k \times k}$ uma matriz simétrica e $\underline{x}_{k \times 1}$ um vetor

- $\underline{x}^T A \underline{x} = tr(\underline{x}^T A \underline{x}) = tr(A \underline{x} \underline{x}^T)$
- $tr(A) = \sum_{i=1}^k \lambda_i$, com λ_i autovalores de A para $i = 1, \dots, k$.

Estimação de parâmetros

Utilizando o resultado anterior, temos que

$$\begin{aligned} & \sum_{j=1}^n \left\{ (\mathbf{x}_j - \underline{\mu})^\top \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) \right\} = \\ & \sum_{j=1}^n \text{tr} \left\{ (\mathbf{x}_j - \underline{\mu})^\top \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) \right\} = \\ & \sum_{j=1}^n \text{tr} \left\{ \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) (\mathbf{x}_j - \underline{\mu})^\top \right\} = \\ & \text{tr} \left\{ \Sigma^{-1} \sum_{j=1}^n (\mathbf{x}_j - \underline{\mu}) (\mathbf{x}_j - \underline{\mu})^\top \right\} = \end{aligned}$$

Estimação de parâmetros

Utilizando o resultado anterior, temos que

$$\begin{aligned} & \sum_{j=1}^n \left\{ (\mathbf{x}_j - \underline{\mu})^\top \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) \right\} = \\ & \sum_{j=1}^n \text{tr} \left\{ (\mathbf{x}_j - \underline{\mu})^\top \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) \right\} = \\ & \sum_{j=1}^n \text{tr} \left\{ \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) (\mathbf{x}_j - \underline{\mu})^\top \right\} = \\ & \text{tr} \left\{ \Sigma^{-1} \sum_{j=1}^n (\mathbf{x}_j - \underline{\mu}) (\mathbf{x}_j - \underline{\mu})^\top \right\} = \end{aligned}$$

Estimação de parâmetros

Utilizando o resultado anterior, temos que

$$\begin{aligned} & \sum_{j=1}^n \left\{ (\mathbf{x}_j - \underline{\mu})^\top \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) \right\} = \\ & \sum_{j=1}^n \text{tr} \left\{ (\mathbf{x}_j - \underline{\mu})^\top \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) \right\} = \\ & \sum_{j=1}^n \text{tr} \left\{ \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) (\mathbf{x}_j - \underline{\mu})^\top \right\} = \\ & \text{tr} \left\{ \Sigma^{-1} \sum_{j=1}^n (\mathbf{x}_j - \underline{\mu}) (\mathbf{x}_j - \underline{\mu})^\top \right\} = \end{aligned}$$

Estimação de parâmetros

Utilizando o resultado anterior, temos que

$$\begin{aligned} & \sum_{j=1}^n \left\{ (\mathbf{x}_j - \underline{\mu})^\top \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) \right\} = \\ & \sum_{j=1}^n \text{tr} \left\{ (\mathbf{x}_j - \underline{\mu})^\top \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) \right\} = \\ & \sum_{j=1}^n \text{tr} \left\{ \Sigma^{-1} (\mathbf{x}_j - \underline{\mu}) (\mathbf{x}_j - \underline{\mu})^\top \right\} = \\ & \text{tr} \left\{ \Sigma^{-1} \sum_{j=1}^n (\mathbf{x}_j - \underline{\mu}) (\mathbf{x}_j - \underline{\mu})^\top \right\} = \end{aligned}$$

Estimação de parâmetros

$$\text{tr} \left\{ \Sigma^{-1} \sum_{j=1}^n (\mathbf{x}_j - \underline{\mu})(\mathbf{x}_j - \underline{\mu})^\top \right\} =$$
$$\text{tr} \left\{ \Sigma^{-1} \sum_{j=1}^n (\mathbf{x}_j - \bar{\mathbf{x}} + \bar{\mathbf{x}} - \underline{\mu})(\mathbf{x}_j - \bar{\mathbf{x}} + \bar{\mathbf{x}} - \underline{\mu})^\top \right\} =$$

(após alguns cálculos - exercício)

$$\text{tr} \left\{ \Sigma^{-1} \left[\sum_{j=1}^n (\mathbf{x}_j - \bar{\mathbf{x}})(\mathbf{x}_j - \bar{\mathbf{x}})^\top + n(\bar{\mathbf{x}} - \underline{\mu})(\bar{\mathbf{x}} - \underline{\mu})^\top \right] \right\}.$$

Estimação de parâmetros

$$\begin{aligned} & \text{tr} \left\{ \Sigma^{-1} \sum_{j=1}^n (\mathbf{x}_j - \underline{\mu})(\mathbf{x}_j - \underline{\mu})^\top \right\} = \\ & \text{tr} \left\{ \Sigma^{-1} \sum_{j=1}^n (\mathbf{x}_j - \bar{\mathbf{x}} + \bar{\mathbf{x}} - \underline{\mu})(\mathbf{x}_j - \bar{\mathbf{x}} + \bar{\mathbf{x}} - \underline{\mu})^\top \right\} = \end{aligned}$$

(após alguns cálculos - exercício)

$$\text{tr} \left\{ \Sigma^{-1} \left[\sum_{j=1}^n (\mathbf{x}_j - \bar{\mathbf{x}})(\mathbf{x}_j - \bar{\mathbf{x}})^\top + n(\bar{\mathbf{x}} - \underline{\mu})(\bar{\mathbf{x}} - \underline{\mu})^\top \right] \right\}.$$

Estimação de parâmetros

$$\begin{aligned} & \text{tr} \left\{ \Sigma^{-1} \sum_{j=1}^n (\mathbf{x}_j - \underline{\mu})(\mathbf{x}_j - \underline{\mu})^\top \right\} = \\ & \text{tr} \left\{ \Sigma^{-1} \sum_{j=1}^n (\mathbf{x}_j - \bar{\mathbf{x}} + \bar{\mathbf{x}} - \underline{\mu})(\mathbf{x}_j - \bar{\mathbf{x}} + \bar{\mathbf{x}} - \underline{\mu})^\top \right\} = \end{aligned}$$

(após alguns cálculos - exercício)

$$\text{tr} \left\{ \Sigma^{-1} \left[\sum_{j=1}^n (\mathbf{x}_j - \bar{\mathbf{x}})(\mathbf{x}_j - \bar{\mathbf{x}})^\top + n(\bar{\mathbf{x}} - \underline{\mu})(\bar{\mathbf{x}} - \underline{\mu})^\top \right] \right\}.$$

Estimação de parâmetros

Reescrevemos então a função densidade de probabilidade agora como função de verossimilhança:

$$L(\underline{\mu}, \underline{\Sigma} | \underline{x}_1, \dots, \underline{x}_n) = \frac{1}{(2\pi)^{np/2} |\underline{\Sigma}|^{n/2}} \times \exp \left\{ -\text{tr} \left\{ \underline{\Sigma}^{-1} \left[\sum_{j=1}^n (\underline{x}_j - \bar{\underline{x}})(\underline{x}_j - \bar{\underline{x}})^T + n(\bar{\underline{x}} - \underline{\mu})(\bar{\underline{x}} - \underline{\mu})^T \right] \right\} / 2 \right\}$$

Estimação de parâmetros

e então, obtemos o logaritmo da verossimilhança:

$$\log L(\underline{\mu}, \Sigma | \underline{x}_1, \dots, \underline{x}_n) = -\frac{np}{2} \log(2\pi) - \frac{n}{2} \log |\Sigma| \\ - \text{tr} \left\{ \Sigma^{-1} \left[\sum_{j=1}^n (\underline{x}_j - \bar{\underline{x}})(\underline{x}_j - \bar{\underline{x}})^\top + n(\bar{\underline{x}} - \underline{\mu})(\bar{\underline{x}} - \underline{\mu})^\top \right] \right\} / 2.$$

Estimação de parâmetros

Resultado

Os estimadores de máxima verossimilhança de $\underline{\mu}$ e Σ são dados por

$$\hat{\underline{\mu}} = \bar{X} \quad \text{e} \quad \hat{\Sigma}_{MV} = \frac{1}{n} \sum_{j=1}^n (\underline{x}_j - \bar{X})(\underline{x}_j - \bar{X})^T.$$

As estimativas de máxima verossimilhança (após observar a amostra) de $\underline{\mu}$ e Σ são dados por

$$\hat{\underline{\mu}} = \bar{x} \quad \text{e} \quad \hat{\Sigma}_{MV} = \frac{1}{n} \sum_{j=1}^n (\underline{x}_j - \bar{x})(\underline{x}_j - \bar{x})^T$$

Prova em Johnson (2007, p. 172).

Estimação de parâmetros

Note que, como já mostramos, $\hat{\Sigma}_{MV}$ é viesado para estimar Σ .

Assim, em muitas aplicações consideramos o estimador não viesado para Σ :

$$\hat{\Sigma} = S = \frac{1}{n-1} \sum_{j=1}^n (\tilde{X}_j - \bar{\tilde{X}})(\tilde{X}_j - \bar{\tilde{X}})^T$$

Distribuição amostral de \bar{X} e S

Seja $\underline{X}_1, \dots, \underline{X}_n$ uma amostra aleatória de uma distribuição $N_p(\underline{\mu}, \Sigma)$ e

$$\hat{\underline{\mu}} = \bar{X} \quad \text{e} \quad \hat{\Sigma} = S = \frac{1}{n-1} \sum_{j=1}^n (\underline{X}_j - \bar{X})(\underline{X}_j - \bar{X})^T.$$

Temos o seguinte

Resultado

- 1 $\bar{X} \sim N_p\left(\underline{\mu}, \frac{\Sigma}{n}\right).$
- 2 $(n-1)S \sim \text{Wishart}(n-1).$
- 3 \bar{X} e S são independentes.

Distribuição amostral de \bar{X} e S

Obs: A distribuição Wishart é uma generalização da distribuição Gama, e é definida como a soma de produtos de normais multivariadas independentes de média $\underline{0}$ e variância Σ :

Em outras palavras, seja

$$W = \sum_{j=1}^n \underline{z}_j \underline{z}_j^{\top} \text{ com } \underline{z}_j \stackrel{i.i.d}{\sim} N(\underline{0}, \Sigma),$$

Então

$$W \sim \text{Wishart}(\Sigma, n).$$

A distribuição assintótica de \bar{X}

Teorema do Limite Central

Seja $\underline{X}_1, \dots, \underline{X}_n$ uma amostra aleatória de uma distribuição qualquer p -variada com $E(\underline{X}_i) = \underline{\mu}$ e $\text{Var}(\underline{X}_i) = \Sigma$, para $i = 1, \dots, n$ e Σ positiva definida.

Então, para n suficientemente grande e $n \gg p$, temos

$$\sqrt{n}(\bar{\underline{X}} - \underline{\mu}) \sim N_p(\underline{0}, \Sigma)$$

e ainda

$$n(\bar{\underline{X}} - \underline{\mu})^\top S^{-1}(\bar{\underline{X}} - \underline{\mu}) \sim \chi_p^2.$$

Testes de hipóteses para a média

Seja $\underline{X}_1, \dots, \underline{X}_n$ uma amostra aleatória de uma distribuição normal p -variada com vetor de médias $\underline{\mu}$ e matriz de variâncias e covariâncias Σ .
Sejam \bar{X} e S o vetor de médias amostrais e a matriz de variâncias e covariâncias amostrais.

Queremos avaliar se

$$H_0 : \underline{\mu} = \underline{\mu}_0 \text{ contra } \cdot$$
$$H_1 : \underline{\mu} \neq \underline{\mu}_0,$$

Testes de hipóteses para a média

Relembramos o resultado anterior

Resultado

- 1 $\bar{X} \sim N_p \left(\underline{\mu}, \frac{\Sigma}{n} \right)$.
- 2 $(n-1)S \sim \text{Wishart}(n-1)$.
- 3 \bar{X} e S são independentes.

Além disso, sob H_0 ,

$$T^2 = \sqrt{n}(\bar{X} - \underline{\mu}_0)^\top \left(\frac{(n-1)S^{-1}}{n-1} \right) \sqrt{n}(\bar{X} - \underline{\mu}_0) \sim \frac{(n-1)p}{n-p} F_{p, n-p}$$

Testes de hipóteses para a média

A quantidade

$$T^2 = n(\bar{\underline{X}} - \underline{\mu}_0)^\top S^{-1}(\bar{\underline{X}} - \underline{\mu}_0) \sim \frac{(n-1)p}{n-p} F_{p, n-p}$$

é conhecida como a **Estatística T^2 de Hotelling**.

Testes de hipóteses para a média

Assim, rejeitamos H_0 a um nível de significância α se

$$T_{obs}^2 = n(\bar{\tilde{X}} - \underline{\tilde{\mu}}_0)^\top S^{-1}(\bar{\tilde{X}} - \underline{\tilde{\mu}}_0) > \frac{(n-1)p}{n-p} q_{F_{p,n-p,\alpha}}$$

em que $q_{F_{p,n-p,\alpha}}$ é o quantil α -superior de uma distribuição $F_{p,n-p}$.

Propriedade de T^2

Seja $\underline{X}_1, \dots, \underline{X}_n$ uma amostra aleatória de uma distribuição normal p -variada com vetor de médias $\underline{\mu}_X$ e matriz de variâncias e covariâncias Σ_X .

Seja $\underline{Y}_i = C\underline{X}_i + \underline{d}$, com C uma matriz não singular fixa e \underline{d} um vetor fixo.

Temos que $E(\underline{Y}_i) = C\underline{\mu}_X + \underline{d}$, $\text{Var}(\underline{Y}_i) = C\Sigma_X C^T$.

Além disso, $\bar{\underline{Y}} = C\bar{\underline{X}} + \underline{d}$ e $S_Y = CS_X C^T$ (exercício).

Propriedade de T^2

É possível mostrar que a estatística T^2 para avaliar

$$H_0 : \underline{\mu} = \underline{\mu}_0 \text{ contra}$$

$$H_1 : \underline{\mu} \neq \underline{\mu}_0,$$

é equivalente à estatística T^2 para avaliar

$$H_0 : C\underline{\mu} + \underline{d} = C\underline{\mu}_0 + \underline{d} \text{ contra}$$

$$H_1 : C\underline{\mu} + \underline{d} \neq C\underline{\mu}_0 + \underline{d},$$