

Estimativa de σ^2 e Teorema de Gauss-Markov

Renato

ESTIMATIVA de σ^2 (a)

$$\sigma^2 = \text{Var}(\varepsilon_i) = \text{Var}(y_i | x_i) = E\left((y_i - E(y_i | x_i))^2\right)$$

Se o modelo de regressão linear está correto, devemos

$$\text{ter } E(y_i | x_i) = x_i' \beta \approx x_i' \hat{\beta} = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_p x_{ip}$$

Isto é, podemos olhar para o resíduo

$$r_i = y_i - \hat{y}_i = y_i - x_i' \hat{\beta}$$

como uma ~~aproximação~~ para o erro

$$\varepsilon_i = y_i - E(y_i | x_i)$$

Para obter um valor aproximado para σ^2 para (6)

$$\sigma^2 = E \left(y_i - E(y_i | x_i) \right)^2$$

podemos usar

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \text{Média dos resíduos (ao quadrado)}$$

~~Ma~~ $\hat{\sigma}^2$ é um valor aleatório (uma variável aleatória)

Portanto, $\hat{\sigma}^2$ possui uma distribuição de probabilidade, tem $E(\hat{\sigma}^2)$ e também

$\text{Var}(\hat{\sigma}^2)$.

Além disso,

$$\sigma^2 \neq \hat{\sigma}^2$$

por
saias

Na verdade, usamos uma ligeira (c)
modificação:

$$\frac{1}{\sigma^2} = \frac{1}{n - (p+1)} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Se $p \ll n$, teremos $\frac{1}{n - (p+1)} \approx \frac{1}{n}$

Por exemplo, no caso do Cement dataset, $n=1030$ e $p=8$


$$\Rightarrow 0.0009794319 = \frac{1}{1030 - (8+1)} \approx \frac{1}{1030} = 0.000970874$$

~~Para obter~~ A distribuição de $\hat{\sigma}^2$:

$$\sum_{i=1}^n (y_i - \hat{y}_i)^2 = \|\underline{y} - \hat{\underline{y}}\|^2 \sim \chi^2_{n-(p+1)} \quad \leftarrow \text{graus de liberdade}$$

O que é uma v.a. χ^2 ??

Por definição, $\chi^2_k = \underbrace{\text{construção}}_{\text{soma de } k} \left(N(0,1)^2 \text{ indep.} \right)$




$$z_1 \sim N(0,1) \quad \text{indep.}$$


$$z_2 \sim N(0,1)$$

$$z_1^2 + z_2^2 \sim \chi^2_2$$



Bivariate Standard Normal Sample



Histogram of $Q = Y_1^2 + Y_2^2$



3D Standard Normal Sample



```

import numpy as np
import matplotlib.pyplot as plt
from mpl_toolkits.mplot3d import Axes3D
from scipy.stats import chi2

# Set seed for reproducibility
np.random.seed(42)

# Step 1: Generate 500 samples from 3D standard normal
n_samples = 500
mean = [0, 0, 0]
cov = np.identity(3)
Y = np.random.multivariate_normal(mean, cov, size=n_samples)
Y1, Y2, Y3 = Y[:, 0], Y[:, 1], Y[:, 2]

# Step 2: Compute  $Q = Y_1^2 + Y_2^2 + Y_3^2$ 
Q = Y1**2 + Y2**2 + Y3**2



# Step 3: Create subplots
fig = plt.figure(figsize=(14, 6))

# Left-hand side: 3D scatter plot
ax1 = fig.add_subplot(1, 2, 1, projection='3d')
ax1.scatter(Y1, Y2, Y3, alpha=0.6, edgecolor='k')
ax1.set_title("3D Standard Normal Sample")
ax1.set_xlabel("$Y_1$")
ax1.set_ylabel("$Y_2$")
ax1.set_zlabel("$Y_3$")


# Right-hand side: Histogram of Q with chi-squared(3) density
ax2 = fig.add_subplot(1, 2, 2)
x_vals = np.linspace(0, max(Q), 300)
ax2.hist(Q, bins=30, density=True, alpha=0.6, color='gray', edgecolor='black', label="Empirical Histogram")
ax2.plot(x_vals, chi2.pdf(x_vals, df=3), 'b-', linewidth=2, label=r'$\chi^2(3)$ Density')
ax2

```

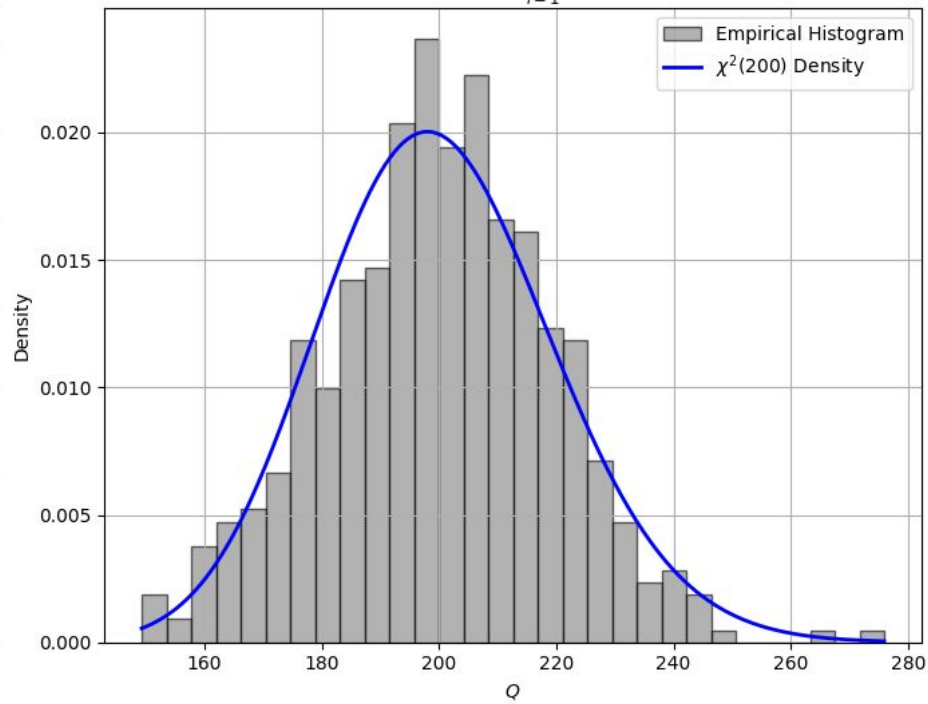

Qui-quadrado: densidade



Histogram of $Q = \sum_{i=1}^{20} Y_i^2$ ($\chi^2(20)$)



Histogram of $Q = \sum_{i=1}^{200} Y_i^2$ ($\chi^2(200)$)



```

import numpy as np
import matplotlib.pyplot as plt
from scipy.stats import chi2

# Set seed for reproducibility
np.random.seed(42)

# Define simulation parameters
n_samples = 500
dfs = [20, 200] # Degrees of freedom

# Prepare figure
fig, axes = plt.subplots(1, 2, figsize=(14, 6))

for i, df in enumerate(dfs):
    # Step 1: Generate samples from multivariate standard normal
    Y = np.random.normal(0, 1, size=(n_samples, df))

    # Step 2: Compute Q = sum of squares (chi-squared variable)
    Q = np.sum(Y**2, axis=1)

    # Step 3: Plot histogram with chi-squared density
    ax = axes[i]
    ax.hist(Q, bins=30, density=True, alpha=0.6, color='gray', edgecolor='black', label='Empirical Histogram')


    x_vals = np.linspace(min(Q), max(Q), 300)
    ax.plot(x_vals, chi2.pdf(x_vals, df), 'b-', linewidth=2, label=fr'$\chi^2({df})$ Density')

    ax.set_title(fr"Histogram of $Q = \sum_{{i=1}}^{{{{df}}}} Y_i^2$ ($\chi^2({df})$)")
    ax.set_xlabel("$Q$")
    ax.set_ylabel("Density")
    ax.legend()
    ax.grid(True)


plt.tight_layout()
plt.show()

```

Histogram of $Q = \sum_{i=1}^{500} Y_i^2 (\chi^2(500))$



Histogram of $Q = \sum_{i=1}^{2000} Y_i^2 (\chi^2(2000))$



Chi-squared distribution

- If $Q \sim \text{Chi-squared}$ with k degrees of freedom, then

1. $E(Q) = k$

2. $\text{Var}(Q) = 2k \rightarrow \text{DP}(Q) = \sqrt{2k}$

When k increases, the density becomes more concentrated around $E(Q)$:

$$\text{DP}(Q)/E(Q) = \sqrt{2k} / k = \sqrt{2/k} \rightarrow 0 \text{ when } k \text{ increases}$$

σ^2 é baseado em $\|\underline{r}\|^2 = \|\underline{y} - \hat{\underline{y}}\|^2$ (F)

Contraste: $\underline{y} = \underline{X}\underline{\beta} + \underline{\varepsilon}$

Versus $\underline{y} = \underline{X}\hat{\underline{\beta}} + \underline{r} (= \hat{\underline{y}} + (\underline{y} - \hat{\underline{y}}))$

$\underline{\varepsilon} \neq \underline{r}$
↑
não observado
↙
vetor aleatório conhecido

Quais as diferenças entre
 $\underline{\varepsilon}$ e \underline{r} ??

$$\underline{\varepsilon} \sim N_n(\underline{0}, \sigma^2 \underline{I}_n)$$

$$\underline{r} \sim ??$$

$$\underline{r} = \underline{Y} - \hat{\underline{Y}} = \underline{Y} - H\underline{Y} = (I - H)\underline{Y}$$

⑨

$$\underline{Y} \sim N_m(\underline{X}\beta, \sigma^2 I_m) \Rightarrow (I - H)\underline{Y} \sim N_m\left(\underbrace{(I - H)\underline{X}\beta}_{(*)}, \underbrace{\sigma^2(I - H)I_m(I - H)'}_{(**)}\right)$$

$$(*) \quad (I - H)\underline{X}\beta = (\underline{X} - H\underline{X})\beta = \left(\underline{X} - \underline{X}(\underline{X}'\underline{X})^{-1}\underline{X}'\underline{X}\right)\beta = (\underline{X} - \underline{X})\beta = \underline{0}$$

$$(**) = \sigma^2 (I - H)(I - H)' = \sigma^2 (I - H)(I - H) \quad \downarrow \text{symétrique} \quad \downarrow \text{idempotente: } (I - H)^2 = (I - H)$$

Assum, $\begin{cases} \underline{r} \sim N_m(\underline{0}, \sigma^2(I_m - H)) & \text{enquanto} \\ \underline{e} \sim N_m(\underline{0}, \sigma^2 I_m) & \text{matriz "cheia"} \end{cases}$

$$\text{Linha} \begin{cases} \underline{r} \sim N_n(\underline{0}, \sigma^2(\mathbf{I} - \mathbf{H})) \\ \underline{\varepsilon} \sim N_n(\underline{0}, \sigma^2 \mathbf{I}) \end{cases}$$

(0)

$$\text{Ent } \frac{1}{\sigma^2} \|\underline{\varepsilon}\|^2 = \frac{1}{\sigma^2} \underline{\varepsilon}' \underline{\varepsilon} = \sum_{i=1}^n \underbrace{\left(\frac{\varepsilon_i}{\sigma} \right)^2}_{\text{soma de } (N(0,1))^2 \text{ independentes}}$$

$$\Rightarrow \frac{1}{\sigma^2} \|\underline{\varepsilon}\|^2 \sim \chi_n^2$$

não-observado



$$\boxed{\|\underline{\varepsilon}\|^2 \sim \sigma^2 \chi_n^2}$$

$$\underline{r} \sim N(\underline{0}, \sigma^2 (\underline{I}_m - H))$$

(1)

~~$$\underline{r} \sim N(\underline{0}, \sigma^2 (\underline{I}_m - H))$$~~

$$\|\underline{r}\|^2 = \underline{r}' \underline{r} = \sum_{i=1}^m r_i^2 = \sum_{i=1}^m (y_i - \hat{y}_i)^2$$

Teorema No modelo de regressão linear,

$$\frac{1}{\sigma^2} \|\underline{r}\|^2 \sim \chi^2 \text{ com degrees of freedom}$$

igual à dimensão do
espaço vetorial $\mathbb{R}^m \ominus \mathcal{M}(X)$
(espaço \perp a $\mathcal{M}(X)$)

observado

Isto é,

$$\frac{1}{\sigma^2} \|\underline{r}\|^2 \sim \chi^2_{m-(p+1)}$$

Como $E(\chi^2_k) \approx k$, temos que ②

$$E\left(\frac{1}{\sigma^2} \|\underline{r}\|^2\right) = E\left(\chi^2_{\underbrace{n-(p+1)}_{\substack{\text{n.º de} \\ \text{observ.}}}}\right) = n - (p+1)$$

Então

$$E\left(\frac{\|\underline{r}\|^2}{n-p-1}\right) = \sigma^2$$

Usamos que $\frac{\|\underline{r}\|^2}{n-p-1}$ deve ser $\approx \sigma^2$

$\left. \begin{array}{l} \text{n.º de} \\ \text{obs.} \\ - \text{n.º de} \\ \text{colunas} \\ \text{em } X \end{array} \right\} = \left(\begin{array}{l} \text{n.º de} \\ \text{featur} \\ + 1 \end{array} \right)$

Isto é,

$$\cancel{\sigma^2} \approx \hat{\sigma}^2 = \frac{1}{n-(p+1)} \sum_{i=1}^n \underbrace{(y_i - \hat{y}_i)^2}_{r_i^2} \quad (3)$$

esperamos
isto

Veja que somamos n termos
 r_i^2 mas nós dividimos por
n, ~~ou~~ sim por $n-(p+1)$

```
#generate OLS regression results for all features
import statsmodels.api as sm

X_sm = sm.add_constant(X)
model = sm.OLS(y,X_sm)
print(model.fit().summary())
```

```

                        OLS Regression Results
=====
Dep. Variable:          csMPa      R-squared:                0.616
Model:                  OLS        Adj. R-squared:            0.613
Method:                 Least Squares    F-statistic:           204.3
Date:                   Fri, 15 Oct 2021    Prob (F-statistic):     6.29e-206
Time:                   16:43:15          Log-Likelihood:         -3869.0
No. Observations:       1030            AIC:                   7756.
Df Residuals:           1021            BIC:                   7800.
Df Model:                8
Covariance Type:        nonrobust
=====

```

	coef	std err	t	P> t	[0.025	0.975]
const	-23.3312	26.586	-0.878	0.380	-75.500	28.837
cement	0.1198	0.008	14.113	0.000	0.103	0.136
slag	0.1039	0.010	10.247	0.000	0.084	0.124
flyash	0.0879	0.013	6.988	0.000	0.063	0.113
water	-0.1499	0.040	-3.731	0.000	-0.229	-0.071
superplasticizer	0.2922	0.093	3.128	0.002	0.109	0.476
coarseaggregate	0.0181	0.009	1.926	0.054	-0.000	0.037
fineaggregate	0.0202	0.011	1.887	0.059	-0.001	0.041
age	0.1142	0.005	21.046	0.000	0.104	0.125

A soma dos quadrados dos resíduos não aparece neste output

```
#generate OLS regression results for all features
import statsmodels.api as sm
```

```
X_sm = sm.add_constant(X)
model = sm.OLS(y,X_sm)
print(model.fit().summary())
```

$$DP(\hat{\beta}_j) = \sqrt{\mathbb{V}(\hat{\beta}_j)} = \hat{\sigma} \sqrt{(\mathbf{X}'\mathbf{X})^{-1}[jj]}$$

OLS Regression Results

```
=====
Dep. Variable:          csMPa   R-squared:                0.616
Model:                  OLS     Adj. R-squared:            0.613
Method:                 Least Squares   F-statistic:            204.3
Date:                  Fri, 15 Oct 2021   Prob (F-statistic):      6.29e-206
Time:                  16:43:15   Log-Likelihood:          -3869.0
No. Observations:      1030   AIC:                     7756.
Df Residuals:          1021   BIC:                     7800.
Df Model:               9
Covariance Type:        nonrobust
=====
```

	coef	std err	t	P> t	[0.025	0.975]
const	-23.3312	26.586	-0.878	0.380	-75.500	28.837
cement	0.1198	0.008	14.113	0.000	0.103	0.136
slag	0.1039	0.010	10.247	0.000	0.084	0.124
flyash	0.0879	0.013	6.988	0.000	0.063	0.113
water	-0.1499	0.040	-3.731	0.000	-0.229	-0.071
superplasticizer	0.2922	0.093	3.128	0.002	0.109	0.476
coarseaggregate	0.0181	0.009	1.926	0.054	-0.000	0.037
fineaggregate	0.0202	0.011	1.887	0.059	-0.001	0.041
agg	0.1142	0.005	21.046	0.000	0.104	0.125

Teorema de Gauss-Markov

https://pt.wikipedia.org/wiki/Andrei_Markov

Recapitulando:

①

Predizer \underline{Y} : problema de interesse

Abordagem: usar preditor linear
 $\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p$

⊕ Visto como problema numérico:

$$\text{solu\c{c}\u00e3o \u00e9 } \hat{\underline{\beta}} = \underbrace{(\underline{X}'\underline{X})^{-1}\underline{X}'\underline{Y}}_{\underline{A}\underline{Y}} = \arg \min_{\underline{\beta}} \|\underline{Y} - \underline{X}\underline{\beta}\|^2$$

⊕ Visto como problema de \u00e1lgebra linear:

$$\hat{\underline{Y}} = \underline{X}\hat{\underline{\beta}} = \text{projec\u00e7\u00e3o } \perp \text{ de } \underline{Y} \text{ em } \mathcal{M}(\underline{X}) = \begin{matrix} \text{sub-espa\u00e7o} \\ \text{vetorial} \\ \text{das colunas} \\ \text{de } \underline{X} \end{matrix}$$
$$\hat{\underline{Y}} = \underline{H}\underline{Y} \quad \underline{H} = \text{hat matrix}$$

Adotamos uma visão estocástica: supõe-se⁽²⁾ que exista um β verdadeiro fixo e que os ~~modelos~~ dados sejam realmente gerados pelo modelo.

$$Y = X\beta + \varepsilon \quad \text{com } \varepsilon \sim N_n(0, \sigma^2 I_n)$$

Então: $\hat{\beta}_{(p+1) \times 1} = \underbrace{(X'X)^{-1}X'Y}_A \sim N_{p+1}(\beta, \sigma^2(X'X)^{-1})$

\nearrow verdadeiro, desconhecido

Consequência: $\begin{cases} E(\hat{\beta}) = \beta \quad \leadsto \quad \hat{\beta} \text{ é não-viesado para estimar } \beta \\ \text{aleatório} \end{cases}$

$$\begin{cases} \text{Var}(\hat{\beta}) = \sigma^2 (X'X)^{-1} \end{cases}$$

Usamos $\hat{\sigma}^2 = \frac{1}{n-(p+1)} \sum_{i=1}^n (y_i - \hat{y}_i)^2$ para estimar σ^2

Teorema de Gauss-Markov

$$\hat{\beta} = (X'X)^{-1}X'Y = AY$$

é a "melhor maneira" de estimar o
vetor β desconhecido

Uma "melhor maneira": abordagem numérica

$$\hat{\beta} = \arg \min_{\beta} \|Y - X\beta\|^2$$

Outra "melhor maneira": se existe um β verdadeiro e fixo, então $\hat{\beta}$ é o que menos
uma ao estimar este β desconhecido.

Os próximos passos/slides

- Entender mais precisamente o que significa “menor erro” para estimar beta
 - Como medir isso?
 - Beta é um VETOR
 - E é um vetor ALEATÓRIO
-
- Como minimizar o erro de estimação?
 - O Teorema de Gauss-Markov e sua demonstração

A solução de mínimos quadrados (LS) (Least Squares) é $\hat{\beta}_{LS} = \underbrace{(X'X)^{-1}X'}_{(p+1) \times m} \underbrace{Y}_{m \times 1} = A \cdot Y$ ①

$$\text{e } \hat{\beta}_{LS} \sim N_{p+1} \left(\underbrace{\beta}_{\substack{\text{verdadeiro} \\ \text{e desconhecido}}}, \sigma^2 (X'X)^{-1} \right)$$

Seja $\hat{\beta}_* = C Y$ um outro candidato para

estimar o verdadeiro β que seja melhor que

$$\hat{\beta}_{LS} = A \cdot Y \quad \text{onde } A = \underbrace{(X'X)^{-1}X'}_{(p+1) \times m}$$

Vamos mostrar que outro candidato melhor que ② $\hat{\beta}_{LS}$ não existe.

Como a matriz C de $\hat{\beta}_* = C Y$ deve ser diferente da matriz A de $\hat{\beta}_{LS} = \underbrace{(X'X)^{-1}X'}_A Y$

Vamos escrever $C = A + D = (X'X)^{-1}X' + D$

Uma propriedade de $\hat{\beta}_{LS} = AY$ é ser ③
não-viciado: $E(\hat{\beta}_{LS}) = \beta$ para todo β possível

Esta é uma propriedade desejável de um estimador
e vamos querer que o candidato $\hat{\beta}_* = CY$ também
seja não-viciado.

Isto implica que a matriz $C = A + D = (X'X)^{-1}X' + D$
deve satisfazer $DX = \underset{(p+1) \times (p+1)}{0}$

Para ver que isto é verdade, vamos calcular:

$$\beta = E(\hat{\beta}) = E(CY) = C E(Y) = CX\beta \quad (4)$$

$$= \left((X'X)^{-1}X' + D \right) X\beta = \left((X'X)^{-1}X' + DX \right) \cdot \beta$$

$$= (I + DX)\beta = \beta + DX\beta$$

Isto é, devemos ter ~~$\beta = \beta + DX\beta$~~ para todo β

$$\Rightarrow DX\beta = \underset{(p+1) \times 1}{0} \text{ para todo } \beta$$

$$\Rightarrow DX = \underset{(p+1) \times (p+1)}{0}$$

Portanto, estamos buscando $\hat{\beta}_* = ((X'X)^{-1}X'D)Y$ ⑤
 $= (A+D) \cdot Y$

que seja "melhor" que $\hat{\beta}_{LS} = (X'X)^{-1}X'Y = AY$

⊕ O que significa "ser melhor"? Significa ter um erro de estimações esperado menor. Significa um estimador que seja menor. Isto é, o erro de estimações dos coeficientes

$$\hat{\beta}_* - \beta = \begin{bmatrix} \hat{\beta}_0^* - \beta_0 \\ \vdots \\ \hat{\beta}_p^* - \beta_p \end{bmatrix} \text{ deve ser } \underline{\text{menor}} \text{ que o}$$

erro de estimações cometido por $\hat{\beta}_{LS}$ que é

$$\hat{\beta}_{LS} - \beta = \begin{bmatrix} \hat{\beta}_0^{LS} - \beta_0 \\ \vdots \\ \hat{\beta}_p^{LS} - \beta_p \end{bmatrix}$$

Mas como avaliar isto?

β é desconhecido e arbitrário: mas podemos calcular os erros diretamente.

Além disso, os erros de estimação são vetores aleatórios.

Vamos considerar uma coordenada genérica de β e comparar os tamanhos típicos dos erros de estimação $(\hat{\beta}_j^* - \beta_j)$ e $(\hat{\beta}_j^{LS} - \beta_j)$

(6)

Qual o tamanho típico desses erros? ⑦
Ele pode ser medido olhando-se o valor
esperado dos erros (ao quadrado):

$E(\hat{\beta}_j^{LS} - \beta_j)^2$. Mas como $\hat{\beta}^{LS}$ é não-viciado
do para estimar β , temos $E(\hat{\beta}_j^{LS}) = \beta_j$

Portanto,

$$E(\hat{\beta}_j^{LS} - \beta_j)^2 = E(\hat{\beta}_j^{LS} - E(\hat{\beta}_j^{LS}))^2 = \text{Var}(\hat{\beta}_j^{LS})$$

Mas já sabemos que $\hat{\beta}^{LS} \sim N_{p+1}(\beta, \sigma^2 (X'X)^{-1})$
Assim, $\text{Var}(\hat{\beta}_j^{LS}) = \sigma^2 (X'X)^{-1} [jj] \rightarrow$ elemento $[jj]$ na
diagonal de $(X'X)^{-1}$

Alhar a diagonal de $\sigma^2 (X'X)^{-1}$ fornece os tamanhos
típicos dos erros de $\hat{\beta}^{LS}$ em cada coordenada
Como $\hat{\beta}^*$ também é não-viesado para estimar
 β (o que implica $DX=0$) então
$$E(\hat{\beta}_j^* - \beta_j)^2 = E(\hat{\beta}_j^* - E(\hat{\beta}_j^*))^2 = \text{Var}(\hat{\beta}_j^*)$$

O que é a matriz de variância-covariância de $\hat{\beta}^*$.

$$\begin{aligned}
\text{Var}(\hat{\beta}^*) &= \text{Var}(CY) \quad (9) \\
(p+1) \times (p+1) &= C \text{Var}(Y) C' \quad (\text{ver exere. 2 da Lista}) \\
&= C (\sigma^2 I_n) C' = \sigma^2 C C' \\
&= \sigma^2 \left((X'X)^{-1} X' + D \right) \left(X (X'X)^{-1} X' + D' \right) \\
&= \sigma^2 \left((X'X)^{-1} X' + D \right) \left(X (X'X)^{-1} X' + D' \right) \\
&= \sigma^2 \left((X'X)^{-1} X' X (X'X)^{-1} + (X'X)^{-1} X' D' + D X (X'X)^{-1} + D D' \right) \\
&= \sigma^2 \left((X'X)^{-1} + \underbrace{(X'X)^{-1} (DX)'}_{\mathbf{0}} + \underbrace{(DX) (X'X)^{-1}}_{\mathbf{0}} + D D' \right) \\
&= \sigma^2 (X'X)^{-1} + \sigma^2 D D' \\
&= \underbrace{\text{Var}(\hat{\beta}^{LS})}_{(p+1) \times (p+1)} + \underbrace{\sigma^2 D D'}_{(p+1) \times (p+1)}
\end{aligned}$$

O elemento $[jj]$ na diagonal de $\text{Var}(\hat{\beta}^*)$ é positivo (pois é uma variância) e é igual ao elemento $[jj]$ na diagonal de $\text{Var}(\hat{\beta}^{LS})$ (também positivo) somado ao elemento $[jj]$ da matriz DD' .

Basta mostrar agora que este elemento $[jj]$ de DD' é positivo

Mas $[DD']_{jj} =$ produto interno da linha (i)
 j de D pela coluna j de D'

Mas coluna j de $D' =$ linha j de D

$\Rightarrow [DD']_{jj} =$ produto interno da linha
 j de D pela mesma linha j de D
 $= (\text{comprimento})^2$ da linha de D
e isto é sempre ≥ 0

Concluimos que, em toda coordenada, ①

$$\underbrace{\text{Var}(\hat{\beta}_j^*)}_{\substack{(\text{tamanho})^2 \\ \text{típico do} \\ \text{erro de} \\ \text{estimação} \\ \text{de } \hat{\beta}^* \text{ na} \\ \text{coordenada } j.}} \geq \underbrace{\text{Var}(\hat{\beta}_j^{LS})}_{\substack{(\text{tamanho})^2 \text{ típico} \\ \text{do erro de estimação} \\ \text{de } \hat{\beta}^{LS} \text{ na coordenada } j.}}$$

Que seja, se o modelo de regressão realmente gerar os dados com um β verdadeiro, então o estimador linear da forma $\hat{\beta} = A Y$ com $A = (X'X)^{-1}X'$ é o que terá os menores (erros)² de estimação em média em todas as coordenadas

