

# Least Squares as Orthogonal Projection

Renato Assunção  
ESRI Inc. and DCC-UFMG

# Dois problemas clássicos em Machine Learning

- {
  - ⊕ Regressão
  - ⊕ Classificação

⊕ Regressão: prever  $Y = \text{preço de aluguel}$  a partir de características (features) tais

como:  $x_1 = \text{área do apartamento}$

$x_2 = \text{idade do apartamento}$

$x_3 = \text{nº de quartos}$

$\vdots x_{30} = \underline{\text{nº vagas de garagem}}$

(2)

$Y = \text{preço do ap}^{\text{to}}$

$$X = (x_1, x_2, \dots, x_{30}) \in \mathbb{R}^{30}$$

↓  
 area      ↓  
 idade      ↓  
 vagas

Numerical variables

Dados

Amostra

{	$y_1$	$x_{11}$	$x_{12}$	—	$x_{1,30}$
	$y_2$	$x_{21}$	$x_{22}$	—	$x_{2,30}$
	$y_3$	$x_{31}$	$x_{32}$	—	$x_{3,30}$
	⋮	⋮	⋮	⋮	⋮
	$y_{2000}$	$x_{2000,1}$	$x_{2000,2}$	—	$x_{2000,30}$
		↓ preço	↓ area	↓ idade	↓ vagas

Queremos encontrar una fórmula (función) <sup>(3)</sup>

$$g(\tilde{x}) = g(\text{área}, \text{idade}, \dots, \text{vagos})$$

tal que  $|Y - g(\tilde{x})| \approx 0$

para todos elementos da amostra (todo  $\stackrel{+/-}{\approx}$ )

⊕  $Y - g(\tilde{x})$  = erro ao prever preçô Y  
usando  $g(\tilde{x})$  como preditor

⊕ O que eu realmente quero é (4)  
medir o novo  $\alpha^+$  que eu  
não observei ainda

⊕ Conceito :

⊕ selecione um novo  $\alpha^+$  ao  
acaso  $(Y, \tilde{X}) = (Y, x_1, \dots, x_{30})$

⊕ Qual o valor esperado do  
novo de medições  $E(|Y - g(\tilde{X})|)$

⊕ Resultados práticos e teóricos para o erro ao quadrado:

$$MSE = E \left[ (Y - g(\tilde{x}))^2 \right]$$

↓  
Mean  
Squared  
Error

↓  
erro de previsão ao quadrado


⊕ Vários algoritmos: { Regressão Linear,  
SVM, Árvores de regressão  
Redes Neurais,

- ⊕ Em todos, o objetivo é encontrar (6)  
uma função  $g(\tilde{x})$  que minimize

$$\mathbb{E} \left[ (Y - g(\tilde{x}))^2 \right]$$

- ⊕ Minimizar num espaço de funções:

Ládeus



Agora

Qual a função  
 $g(\tilde{x})$  que minimiza  
a expressão  $\mathbb{E}[Y - g(\tilde{x})]^2$

⊕ Temos a Solução tórica e perfeita (7)

Teorema Dentro as infinitas funções  $g(x)$ , aquela que minimiza

$$\mathbb{E}[(Y - g(X))^2]$$

é a esperança condicional

$$\mu(\tilde{x}) = \mathbb{E}(Y | \tilde{x})$$

⊕ Temos a Solução tórica e perfeita (7)

Teorema Dentro as infinitas funções  $g(x)$ , aquela que minimiza

$$E[(Y - g(x))^2]$$

é a esperança condicional

$$\mu(x) = E(Y | x)$$

Provamos este resultado na aula passada. Ver notas no website

- ⊕ Esta solução teórica é pouco útil (8) pois não sabemos calcular  $\mu(\tilde{X}) = E(Y|\tilde{X})$
- ⊕ Em geral, não conhecemos a distribuição conjunta das variáveis aleatórias  $(Y, \tilde{X}) = (Y, X_1, X_2, \dots, X_{30})$
- ⊕ O que fazemos então?

-

⊕ Todos modelos/algortimos de ML estabelece<sup>④</sup>  
uma classe  $\mathcal{G}$  (um conjunto) de funções  
possíveis  $g(\tilde{x})$

⊕ Dentro desse subconjunto  $\mathcal{G}$ , procura  
achar aquele  $g^*(\tilde{x})$  que seja  
próximo da função ótima  
perfeita  $\mu(\tilde{x}) = E(Y | \tilde{x})$

(10)

⊕ Exemplos:

### Regressão linear

$$\mathcal{C} = \left\{ g(\underline{x}) = \underbrace{\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_{30} x_{30}} \right\}$$

combinações lineares  
das features

Cada  $g(\underline{x}) \in \mathcal{C}$  é determinado pelos  
Coeficientes  $(\theta_0, \theta_1, \dots, \theta_{30}) \in \mathbb{R}^{31}$

Queremos encontrar uma  $g^*(\tilde{x}) \in \mathcal{E}$  ⑪

(isto é, escolher coeficientes  $\theta_0, \theta_1, \dots, \theta_{30}$ )

tal que

$$E \left[ \left( Y - \underbrace{\left( \theta_0 + \theta_1 x_1 + \dots + \theta_{30} x_{30} \right)}_{g(\tilde{x})} \right)^2 \right]$$

seja mínimo

Queremos encontrar uma  $g^*(\tilde{x}) \in \mathcal{E}$  ⑪

(isto é, escolher coeficientes  $\theta_0, \theta_1, \dots, \theta_{30}$ )


tal que

$$E \left[ \left( Y - \underbrace{\left( \theta_0 + \theta_1 x_1 + \dots + \theta_{30} x_{30} \right)}_{g(\tilde{x})} \right)^2 \right]$$

seja mínimo

Justificativa para esta escolha linear para o conjunto C: usar a melhor aprox polinomial para  $E(Y | X) = \mu(x)$ . Aqui, usamos aprox do polinomio de primeira ordem (vimos na aula passada).

Example: Regression tree with two features (12)




$$\hat{Y} = g(\underline{x}) = \text{prediction}$$

"función a granelo"

$$\hat{Y} = g(X_1, X_2) = \begin{cases} c_1, & \text{if } X_1 \leq t_1 \text{ AND } X_2 > t_2 \\ c_2, & \text{if } X_1 > t_1 \text{ AND } X_2 > t_3 \\ c_3, & \text{if } X_1 > t_1 \text{ AND } X_2 \leq t_3 \\ c_4, & \text{if } X_1 \leq t_1 \text{ AND } X_2 \leq t_2 \end{cases}$$

⊕ Achar a  $g(x_1, x_2)$  nsta classe de "funções agulhejos" & é encontrar os pontos de corte

$t_1, t_2, t_3$  e os valores  $c_1, c_2, c_3, c_4$



RESUMO Objetivo: sechar a função de  $\tilde{X}$  (14)

ótima (para minimizar o erro<sup>2</sup> esperado)

$$\mu(\tilde{X}) = \mathbb{E}(Y | \tilde{X})$$

Solução Definir uma classe de funções  $\mathcal{E}$

que seja:

⊕ flexível, moleável, que possa  
aproximar qualquer função

trade-off → ⊕ "pequeno" para ser trabalhado  
municamente

Soluções: SVM, NN, Regressão linear...

No classe  $\mathcal{C}$  escolhida pelo algoritmo,<sup>(15)</sup>  
seleciona-se func  $g^*(x) \in \mathcal{C}$  que  
melhor aproxime  $\mu(x) = E(T|x)$

Mas como encontrar esta  $g^*(x)$  se não  
conhecemos  $\mu(x)$ ?

No prática, buscamos minimizar a  
soma dos erros de predição no conjunto  
de treinamento

Para qualquer vetor aleatório

$$(Y, \tilde{X}) = (Y, X_1, \dots, X_{30})$$

o valor esperado de uma função

$h(Y, \tilde{X})$  é aprox. a média

aritmética de  $h$  calculada numa amostra de tamanho grande:

$$E[h(Y, \tilde{X})] \approx \frac{1}{N} \sum_{i=1}^N h(Y_i, \tilde{X}_i)$$


---

$$E \left( \underbrace{(y - g(x))^2}_{h(y,x)} \right) \approx \frac{1}{N} \sum_{i=1}^N (y_i - g(x_i))^2 \quad (17)$$

Ache  $g^* \in \mathcal{C}$  que minimize esta soma

- Como minimizar um objetivo num espaço de funções? Derivar e igualar a zero? Derivar em relação a quê?

Se  $\mathcal{C}$  é uma classe parametrizada por <sup>(18)</sup>  
 um vetor de coeficientes  $(\theta_0, \theta_1, \dots, \theta_{30})$ ,  
 derive em relação a estes coeficientes.

Ex: Regressão Linear

$$g(x) = \beta_0 + \beta_1 x$$

Achar  $\boxed{\beta_0 \text{ e } \beta_1}$  que minimizam

$$\frac{1}{N} \sum_{i=1}^N (y_i - (\beta_0 + \beta_1 x_i))^2 = \frac{1}{N} \left( (90.3 - (\beta_0 + \beta_1 \cdot 150))^2 + (90.7 - (\beta_0 + \beta_1 \cdot 210))^2 + \dots \right)$$

Ignorando a constante 1/N, derive em relação a beta\_0 e beta\_1 e iguale a zero:

- Derivando e igualando a zero:

$$0 = \sum_i \frac{\partial}{\partial \beta_0} (y_i - (\beta_0 + \beta_1 x_i))^2$$

$$0 = \sum_i \frac{\partial}{\partial \beta_1} (y_i - (\beta_0 + \beta_1 x_i))^2$$

- Ou seja:

$$0 = \sum_i 2(y_i - (\beta_0 + \beta_1 x_i)) (-1)$$

$$0 = \sum_i 2(y_i - (\beta_0 + \beta_1 x_i)) (-x_i)$$

- Temos

$$0 = - \sum_i y_i + \beta_0 n + \beta_1 \sum_i x_i$$

$$0 = - \sum_i (y_i x_i) + \beta_0 \sum_i x_i + \beta_1 \sum_i x_i^2$$

- Rearranjando:

$$\beta_0 n + \beta_1 \sum_i x_i = \sum_i y_i$$

$$\beta_0 \sum_i x_i + \beta_1 \sum_i x_i^2 = \sum_i (y_i x_i)$$

- Este é um sistema linear de duas equações com duas incógnitas,  $\beta_0$  e  $\beta_1$ .

- Sistema na forma matricial

$$\begin{bmatrix} n & \sum_i x_i \\ \sum_i x_i & \sum_i x_i^2 \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = \begin{bmatrix} \sum_i y_i \\ \sum_i (x_i y_i) \end{bmatrix}$$

- Com solução:

$$\begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = \begin{bmatrix} n & \sum_i x_i \\ \sum_i x_i & \sum_i x_i^2 \end{bmatrix}^{-1} \begin{bmatrix} \sum_i y_i \\ \sum_i (x_i y_i) \end{bmatrix}$$

- Vamos usar uma notação para simplificar as expressões.
- Vamos denotar a média dos  $x$  e  $y$ 's por
  - $\bar{x} = \frac{1}{n} \sum_i x_i$ , média aritmética dos  $x_i$ 's
  - $\bar{y} = \frac{1}{n} \sum_i y_i$
  - $\bar{x^2} = \frac{1}{n} \sum_i x_i^2$ , média aritmética dos  $x_i^2$ 's
  - $\bar{xy} = \frac{1}{n} \sum_i (x_i y_i)$ , média aritmética dos  $x_i y_i$ 's

- Sistema na forma matricial e com a notação introduzida

$$\begin{bmatrix} 1 & \bar{x} \\ \bar{x} & \bar{x^2} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = \begin{bmatrix} \bar{y} \\ \bar{xy} \end{bmatrix}$$

- Com solução:

$$\begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = \begin{bmatrix} 1 & \bar{x} \\ \bar{x} & \bar{x^2} \end{bmatrix}^{-1} \begin{bmatrix} \bar{y} \\ \bar{xy} \end{bmatrix}$$

- Como a inversa de uma matriz  $2 \times 2$  é conhecida, podemos resolver de forma explícita a solução de mínimos quadrados.
- Após alguma manipulação algébrica, temos a solução como uma fórmula envolvendo os pontos:

$$\begin{aligned}\hat{\beta}_1 &= \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sum_i (x_i - \bar{x})^2} \\ \hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \bar{x}\end{aligned}$$

# Regressão: caso geral

- Vetor Y de dimensão n:
  - preço de n aptos
- $(k+1)$  features, vetores-coluna de dimensão n
  - Feature 0: vetor-coluna de 1's
  - Feature 1: vetor-coluna com área dos aptos n aptos
  - ....
  - Feature k: vetor-coluna com indicador binário “tem salão de festa?”
- Colete as features numa matriz X de dimensão  $n \times (k + 1)$
- Objetivo: minimizar

$$\sum_{i=1}^n (y_i - \beta_0 * 1 + \beta_1 x_{i1} + \dots \beta_k x_{ik})^2 = \sum_{i=1}^n ||\mathbf{Y} - \mathbf{X}\beta||^2$$

# Regressão: caso geral

- Derive
- $\sum_{i=1}^n (y_i - \beta_0 * 1 + \beta_1 x_{i1} + \dots \beta_k x_{ik})^2 = \sum_{i=1}^n \|\mathbf{Y} - \mathbf{X}\beta\|^2$
- em relação aos coeficientes  $\beta_j$  de cada feature
- Iguale cada derivada parcial a zero
- “Isole” os beta’s
- Teremos um sistema linear chamado equações normais:

$$(\mathbf{X}^t \mathbf{X})\beta = \mathbf{X}^t \mathbf{Y}$$

# Equações normais

$$\underbrace{(\mathbf{X}^t \mathbf{X})}_{(k+1) \times n \quad n \times (k+1)} \quad \underbrace{\beta}_{(k+1) \times 1} = \underbrace{\mathbf{X}^t \mathbf{Y}}_{(k+1) \times n \quad n \times 1}$$

$$\underbrace{(\mathbf{X}^t \mathbf{X})}_{(k+1) \times (k+1)} \quad \underbrace{\beta}_{(k+1) \times 1} = \underbrace{\mathbf{X}^t \mathbf{Y}}_{(k+1) \times 1}$$

Temos um sistema linear

$\mathbf{X}'\mathbf{X}$  é matriz quadrada  $(k+1) \times (k+1)$

Se tiver inversa, podemos obter a solução

$$\hat{\beta} = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{Y}$$

# Uma abordagem mais geral

Solução Least Squares foi vista como um problema numérico:

minimizar uma função objetivo

$$L(\beta_0, \beta_1, \dots, \beta_k) = \sum_i (\text{preço}_i - \beta_0 * 1 + \beta_1 \text{área}_i + \dots + \beta_k \text{banheiro?}_i)^2$$

Ao invés de olhar o problema como um problema numérico, vamos dar uma roupagem mais teórica.

Vai permitir uma solução mais elegante e ... generalizável para espaços de funções

⊕ Mas, e quando  $\mathcal{C}$  não é tão simples? ⑯

⊕ O que é uma classe  $\mathcal{C}$  boa?

⊕ Podemos garantir que sempre vamos encontrar uma função  $g^*(x)$  que seja uma boa aproximação para  $\mu(x) = E(Y|x)$ ?

⊕ Precisamos de três coisas:

- trabalhar no espaço de funções
- medir distância entre funções
- saber quando uma sequência de funções converge (aproxima) para outra

⊕ Isto nos leva a conceitos de análise 20  
funcional

⊕ Recordar espaço vetorial

Conjunto de objetos em geral:

- podemos somar objetos e  
obter um 3º objeto
- podemos "espichar", "encolher"  
ou "reverter" objetos ao  
multiplicá-los por escalares

To have a vector space, the eight following [axioms](#) must be satisfied for every  $\mathbf{u}$ ,  $\mathbf{v}$  and  $\mathbf{w}$  in  $V$ , and  $a$  and  $b$  in  $F$ .<sup>[3]</sup>



Axiom	Statement
Associativity of vector addition	$\mathbf{u} + (\mathbf{v} + \mathbf{w}) = (\mathbf{u} + \mathbf{v}) + \mathbf{w}$
Commutativity of vector addition	$\mathbf{u} + \mathbf{v} = \mathbf{v} + \mathbf{u}$
Identity element of vector addition	There exists an element $\mathbf{0} \in V$ , called the <a href="#">zero vector</a> , such that $\mathbf{v} + \mathbf{0} = \mathbf{v}$ for all $\mathbf{v} \in V$ .
Inverse elements of vector addition	For every $\mathbf{v} \in V$ , there exists an element $-\mathbf{v} \in V$ , called the <a href="#">additive inverse</a> of $\mathbf{v}$ , such that $\mathbf{v} + (-\mathbf{v}) = \mathbf{0}$ .
Compatibility of scalar multiplication with field multiplication	$a(b\mathbf{v}) = (ab)\mathbf{v}$ [nb 3]
Identity element of scalar multiplication	$1\mathbf{v} = \mathbf{v}$ , where $1$ denotes the <a href="#">multiplicative identity</a> in $F$ .
Distributivity of scalar multiplication with respect to vector addition	$a(\mathbf{u} + \mathbf{v}) = a\mathbf{u} + a\mathbf{v}$
Distributivity of scalar multiplication with respect to field addition	$(a + b)\mathbf{v} = a\mathbf{v} + b\mathbf{v}$

(4)

## Exemplos de espaços vetoriais:

$$\vec{v} \in \mathbb{R}^2 = \{ \vec{v} = (x, y), x \in \mathbb{R}, y \in \mathbb{R} \}$$

com escalares reais




$$\oplus \mathbb{R}^m = \{(x_1, x_2, \dots, x_m) \mid x_i \in \mathbb{R}\}$$

(22)

• Espacio de funciones  $\mathcal{F}$

$$\mathcal{F} = \{f: \mathbb{R} \rightarrow \mathbb{R}\}$$









Somar duas funções  $\rightarrow$  ainda é uma função (23)

Definir a soma  $g + f = h$ :

é a função tal que


$$h(x) = g(x) + f(x) \text{ para todos } x$$






$\mathcal{F} = \{ f \text{ funções em qual domínio?} \}$  (26)


$$\mathcal{F}(\mathbb{R}) = \{ f: \mathbb{R} \rightarrow \mathbb{R} \}$$



$$\mathcal{F}([0, 1]) = \{ f: [0, 1] \rightarrow \mathbb{R} \}$$





$$\mathcal{F}([-1, 1]) = \{ f: [-1, 1] \rightarrow \mathbb{R} \}$$







(27)

$$\mathcal{F}(I) = \{ f : I \text{ intervalo} \rightarrow \mathbb{R} \}$$

$\mathcal{F}(I)$  tem elementos muito estranhos



$$c = \sin^2(s + 2^x) \quad s = 1$$



Ignorar espaços de funções (por enquanto)  
Foco em  $\mathbb{R}^n$  e regressão linear

## Exemplo de preço de apto

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_{1499} \\ y_{1500} \end{pmatrix} \approx b_0 \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \\ 1 \end{pmatrix} + b_1 \begin{pmatrix} \text{área}_1 \\ \text{área}_2 \\ \vdots \\ \text{área}_{1499} \\ \text{área}_{1500} \end{pmatrix} + b_2 \begin{pmatrix} \text{idade}_1 \\ \text{idade}_2 \\ \vdots \\ \text{idade}_{1499} \\ \text{idade}_{1500} \end{pmatrix} + \dots + b_{30} \begin{pmatrix} \text{salão}_1 \\ \text{salão}_2 \\ \vdots \\ \text{salão}_{1499} \\ \text{salão}_{1500} \end{pmatrix}$$

- $Y$  é um vetor de dimensão 1500 escrito como combinação linear de 31 vetores, cada um deles de dimensão 1500.
- Problema: encontrar os coeficientes  $b_0, b_1, \dots, b_{30}$  que tornem a aproximação acima a melhor possível.

## A matriz de desenho $X$

- Seja  $X$  a matriz  $1500 \times 31$  abaixo (note que ela tem uma coluna composta apenas de 1's):

$$X = \begin{pmatrix} 1 & \text{renda}_1 & \text{área}_1 & \cdots & \text{salão}_1 \\ 1 & \text{renda}_2 & \text{área}_2 & \cdots & \text{salão}_2 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & \text{renda}_{1499} & \text{área}_{1499} & \cdots & \text{salão}_{1499} \\ 1 & \text{renda}_{1500} & \text{área}_{1500} & \cdots & \text{salão}_{1500} \end{pmatrix}$$

# Combinações lineares e a matriz $X$

- A combinação linear que buscamos

$$b_0 \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \\ 1 \end{pmatrix} + b_1 \begin{pmatrix} \text{área}_1 \\ \text{área}_2 \\ \vdots \\ \text{área}_{1499} \\ \text{área}_{1500} \end{pmatrix} + b_2 \begin{pmatrix} \text{idade}_1 \\ \text{idade}_2 \\ \vdots \\ \text{idade}_{1499} \\ \text{idade}_{1500} \end{pmatrix} + \dots + b_{30} \begin{pmatrix} \text{salão}_1 \\ \text{salão}_2 \\ \vdots \\ \text{salão}_{1499} \\ \text{salão}_{1500} \end{pmatrix}$$

- pode ser escrita como

$$X \cdot b = \begin{bmatrix} 1 & \text{renda}_1 & \text{área}_1 & \cdots & \text{salão}_1 \\ 1 & \text{renda}_2 & \text{área}_2 & \cdots & \text{salão}_2 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & \text{renda}_{1499} & \text{área}_{1499} & \cdots & \text{salão}_{1499} \\ 1 & \text{renda}_{1500} & \text{área}_{1500} & \cdots & \text{salão}_{1500} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_{30} \end{bmatrix}$$

## Vetores próximos

Nosso problema é encontrar os coeficientes  $b_0, b_1, \dots, b_{30}$  tais que

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_{1499} \\ y_{1500} \end{pmatrix} \approx b_0 \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \\ 1 \end{pmatrix} + b_1 \begin{pmatrix} \text{área}_1 \\ \text{área}_2 \\ \vdots \\ \text{área}_{1499} \\ \text{área}_{1500} \end{pmatrix} + b_2 \begin{pmatrix} \text{idade}_1 \\ \text{idade}_2 \\ \vdots \\ \text{idade}_{1499} \\ \text{idade}_{1500} \end{pmatrix} + \dots + b_{30} \begin{pmatrix} \text{salão}_1 \\ \text{salão}_2 \\ \vdots \\ \text{salão}_{1499} \\ \text{salão}_{1500} \end{pmatrix}$$

Ou seja, encontrar  $b_0, b_1, \dots, b_{30}$  tais que  $Y \approx Xb$  onde

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_{1498} \\ y_{1499} \\ y_{1500} \end{pmatrix} \approx \begin{pmatrix} 1 & \text{renda}_1 & \text{área}_1 & \cdots & \text{salão}_1 \\ 1 & \text{renda}_2 & \text{área}_2 & \cdots & \text{salão}_2 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & \text{renda}_{1499} & \text{área}_{1499} & \cdots & \text{salão}_{1499} \\ 1 & \text{renda}_{1500} & \text{área}_{1500} & \cdots & \text{salão}_{1500} \end{pmatrix} \begin{pmatrix} b_0 \\ b_1 \\ \vdots \\ b_{30} \end{pmatrix} = Xb$$

onde  $b = (b_0, \dots, b_{30})^t$ .

## Solução: minimizar norma

- $X$  é uma matriz  $1500 \times 31$ .
- $Y$  e  $Xb$  são vetores 1500-dim.
- Além disso,  $Xb$  é uma combinação linear das colunas da matriz  $X$ .
- Queremos encontrar  $b$  tal que o vetor  $Xb$  seja o mais próximo possível do vetor  $Y$ .
- Queremos  $Y - Xb$  aproximadamente igual AO VETOR ZERO.
- Queremos  $\|Y - Xb\| \approx 0$  (o comprimento-norma é um número, não um vetor)

## Solução melhor: minimizar norma ao quadrado

- Queremos  $\|Y - Xb\| \approx 0$
- Queremos  $\hat{b}$  que minimize  $\|Y - Xb\|$
- Mas norma euclidiana envolve a raiz quadrada da soma dos quadrados ...
- Mas se  $\hat{b}$  minimiza  $\|Y - Xb\|$  então  $\hat{b}$  minimiza  $\|Y - Xb\|^2$
- Esta segunda função é mais fácil de derivar.

## Solução melhor: minimizar norma ao quadrado

- Então procuramos vetor  $b$  tal que  $\|Y - Xb\|^2 \approx 0$ .
- Queremos  $\hat{b}$  que minimize  $\|Y - Xb\|^2$
- Matematicamente: queremos  $\hat{b} = \arg \min_b \|Y - Xb\|^2$ .
- Como encontrar este  $\hat{b}$ ?

## Vetores e combinações lineares

- $X$  é matriz  $1500 \times 31$ .  $b$  é vetor  $31 \times 1$
- Para qualquer vetor  $b \in \mathbb{R}^{31}$ , temos  $Xb$  em  $\mathbb{R}^{1500}$ .
- Varie  $b$  varrendo todos os vetores  $b$  possíveis. O que obtemos?
- Isto é, o que é o conjunto

$$\mathfrak{M}(X) = \{v \in \mathbb{R}^{1500} \text{ tal que } v = Xb \text{ para algum } b\} \ ?$$

# O que é $\mathfrak{M}(X)$ ?

- Colunas da matriz  $X$  estão fixadas, são vetores  $1500 \times 1$  de números constantes, conhecidos.

$$\mathfrak{M}(X) = \left\{ b_0 \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \\ 1 \end{pmatrix} + b_1 \begin{pmatrix} \text{área}_1 \\ \text{área}_2 \\ \vdots \\ \text{área}_{1499} \\ \text{área}_{1500} \end{pmatrix} + b_2 \begin{pmatrix} \text{idade}_1 \\ \text{idade}_2 \\ \vdots \\ \text{idade}_{1499} \\ \text{idade}_{1500} \end{pmatrix} + \dots + b_{30} \begin{pmatrix} \text{salão}_1 \\ \text{salão}_2 \\ \vdots \\ \text{salão}_{1499} \\ \text{salão}_{1500} \end{pmatrix} \right\}$$

- $\mathfrak{M}(X)$  é um subconjunto de vetores do espaço vetorial  $\mathbb{R}^{1500}$ .
- Vetor zero pertence a  $\mathfrak{M}(X)$ .
- Somando duas combinações lineares de  $\mathfrak{M}(X)$  ainda permanecemos em  $\mathfrak{M}(X)$ .
- Multiplicando um elemento de  $\mathfrak{M}(X)$  por uma constante ainda permanecemos em  $\mathfrak{M}(X)$ .

# Sub-espacos vetoriais

- Informal: Sub-espaco vetorial  $W$  de um espaco vetorial  $V$  é um subconjunto de  $V$  tal que:
  - a soma de dois vetores de  $W$  permanece em  $W$
  - multiplicar um vetor de  $W$  por um escalar permanece em  $W$
  - O vetor 0 (nulo) pertence a  $W$
- Só isto:  $W$  é um espaco vetorial e não saímos de dentro dele ao manusear seus vetores com adição ou multiplicação por escalar.

## Espaço $\mathfrak{M}(X)$ das combinações lineares

- $\mathfrak{M}(X)$  é um sub-espaço vetorial de  $\mathbb{R}^{1500}$ .
- $\mathfrak{M}(X)$  é o sub-espaço vetorial formado pelas combinações lineares dos 31 vetores-colunas de  $X$ .
- Se as colunas de  $X$  são linearmente independentes, então  $\mathfrak{M}(X)$  é um sub-espaço vetorial de dimensão igual ao número de colunas de  $X$  (que é 31, no nosso exemplo).
- Nosso problema então é: encontrar os coeficientes  $b$  da combinação linear  $Xb \in \mathfrak{M}(X)$  tal que  $Xb$  seja o mais próximo possível do vetor  $Y$ .

## Geometria dos Mínimos quadrados




Figura: Representação do vetor  $Y \in \mathbb{R}^{1500}$ . O plano inclinado representa o sub-espaco vetorial  $\mathfrak{M}(X)$  gerado por uma matriz  $X$  com apenas duas colunas, os vetores  $X_1$  e  $X_2$ , ambos do  $\mathbb{R}^{1500}$ . O sub-espaco vetorial  $\mathfrak{M}(X)$  é de dimensão 2. Identifique visualmente o ponto-vetor em  $\mathfrak{M}(X)$  que minimiza  $\|Y - Xb\|^2$ .

# Teorema da Projeção Ortogonal

- Seja  $\mathbb{R}^n$  um espaço vetorial real de dimensão  $n$ .
- Seja  $\mathcal{W}$  um sub-espaço vetorial de  $\mathcal{V}$  com dimensão  $m$ .
- Seja  $Y \in \mathbb{R}^n$  um vetor qualquer.
- **Teorema:** Existe um único vetor  $\hat{w} \in \mathcal{W}$  que minimiza  $\|Y - w\|$  com  $w \in \mathcal{W}$ .
- Além disso, este  $\hat{w} \in \mathcal{W}$  é o único vetor tal que  $Y - \hat{w}$  é ortogonal a  $\hat{w}$ . Isto é,  $\hat{w}$  é o único vetor tal que  $(Y - \hat{w}) \perp \hat{w}$ .

PROVA: a seguir

# Teorema da Projeção Ortogonal




Figura:  $v$  é um vetor do  $\mathbb{R}^3$ . O plano  $\mathcal{W}$  é um sub-espaco vetorial de dimensão 2. dado um vetor  $u$  do sub-espaco,  $\|v - u\|$  (linha tracejada fina) é o comprimento do vetor  $v - u$ .

De todos os vetores  $u$  do sub-espaco  $\mathcal{W}$ , aquele que minimiza o comprimento  $\|v - u\|$  é a projeção ortogonal  $\hat{v}$ . O vetor  $\hat{v}$  é a aproximação de mínimos quadrados em  $\mathcal{W}$  para  $v$ . O vetor  $r = v - \hat{v}$  é o vetor de resíduos.

# Geometria dos Mínimos quadrados




Figura: Projeção ortogonal de  $Y \in \mathbb{R}^{1500}$  no sub-espaco vetorial  $\mathfrak{M}(X)$  minimiza  $\|Y - X\beta\|^2$ . Esta projeção é o vetor  $X\hat{\beta}$ . Vetor de resíduos é  $r = Y - X\hat{\beta}$  e é  $\perp$  a  $X\hat{\beta}$ . Imagem retirada de

<https://commons.wikimedia.org/w/index.php?curid=7309159>

- Demonstração do Teorema da Projeção.
- Não veremos a demonstração geral para espaços vetoriais arbitrários.
- Vamos fazer apenas o caso especial da regressão linear.

## Produto interno com vetores-coluna

- Produto interno de dois vetores,  $\mathbf{v}$  e  $\mathbf{w}$ , no mesmo espaço vetorial de dimensão  $n$ :

$$\langle \mathbf{v}, \mathbf{w} \rangle = \sum_{i=1}^n v_i w_i$$

- Como  $\mathbf{v}$  e  $\mathbf{w}$  são vetores-coluna, temos

$$\langle \mathbf{v}, \mathbf{w} \rangle = \sum_i v_i w_i = \begin{bmatrix} v_1 & v_2 & \dots & v_n \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_n \end{bmatrix} = \mathbf{v}^t \mathbf{w}$$

- Temos  $\mathbf{v} \perp \mathbf{w}$  se, e só se,  $\langle \mathbf{v}, \mathbf{w} \rangle = \mathbf{v}^t \mathbf{w} = 0$ .
- Imitando o Scilab, vamos denotar  $\mathbf{v}^t$  por  $\mathbf{v}'$ .

- Primeiro, queremos achar  $\hat{Y} = X\hat{\beta}$  tal que  $(Y - \hat{Y}) \perp \hat{Y}$
- Depois, queremos mostrar que este  $\hat{Y} = X\hat{\beta}$  é o vetor que minimiza a distância  $\|Y - X\beta\|^2$

$$\begin{aligned}\hat{Y} &= X\beta \perp (Y - \hat{Y}), \forall Y \\ \langle X\beta, Y - \hat{Y} \rangle &= 0 \\ 0 &= (X\beta)^t (Y - X\beta) \\ &= \beta^t X^t (Y - X\beta) \\ &= \beta^t (X^t Y - X^t X\beta)\end{aligned}$$

- Ou  $\beta^t = 0$  (o que implica que  $\beta = 0$  e que  $\hat{Y} = 0$ ), solução sem sentido
- Ou  $X^t Y - X^t X\beta = 0 \implies$  com solução  $\hat{\beta} = (X^t X)^{-1} X^t Y$

- Seja  $\hat{Y} = X\hat{\beta} = X(X^tX)^{-1}X^tY$
- Vamos calcular agora  $\|Y - X\beta\|^2$  para um  $\beta$  arbitrário:
- Some e subtraia:  $Y - X\beta = Y - X\hat{\beta} + X\hat{\beta} - X\beta$
- Calculando:

$$\begin{aligned}
 \|Y - X\beta\|^2 &= (Y - X\beta)^t(Y - X\beta) = \\
 &= \left( (Y - X\hat{\beta}) + (X\hat{\beta} - X\beta) \right)^t \left( (Y - X\hat{\beta}) + (X\hat{\beta} - X\beta) \right) \\
 &= (Y - X\hat{\beta})^t(Y - X\hat{\beta}) + (Y - X\hat{\beta})^t(X\hat{\beta} - X\beta) + \\
 &\quad + (X\hat{\beta} - X\beta)^t(Y - X\hat{\beta}) + (X\hat{\beta} - X\beta)^t(X\hat{\beta} - X\beta) \\
 &= \underbrace{\|Y - X\hat{\beta}\|^2}_A + 2(Y - X\hat{\beta})^t(X\hat{\beta} - X\beta) + \|X\hat{\beta} - X\beta\|^2
 \end{aligned}$$

- Vamos mostrar agora que  $A = 0$

$$\begin{aligned}
 & \left( Y - X\hat{\beta} \right)^t \left( X\hat{\beta} - X\beta \right) = \left( Y - X(X^t X)^{-1} X^t Y \right)^t \left( X\hat{\beta} - Xb \right) \\
 &= \left( \left( I - X(X^t X)^{-1} X^t \right) Y \right)^t \left( X\hat{\beta} - Xb \right) \\
 &= \left( Y^t \left( I - X(X^t X)^{-1} X^t \right)^t \right) \left( X(\hat{\beta} - \beta) \right) = (*)
 \end{aligned}$$

- Temos  $\left( I - X(X^t X)^{-1} X^t \right)^t = I^t - (X^t)^t \left( (X^t X)^{-1} \right)^t X^t$

$$\begin{aligned}
 &= I - X \left( (X^t X)^t \right)^{-1} X^t \\
 &= I - X(X^t X)^{-1} X^t
 \end{aligned}$$

- Assim  $(*) = Y^t \left( I - X (X^t X)^{-1} X^t \right) X (\hat{\beta} - \beta)$

$$\begin{aligned}&= Y^t \left[ \left( I - X (X^t X)^{-1} X^t \right) X \right] (\hat{\beta} - \beta) \\&= Y^t \left[ X - X \underbrace{(X^t X)^{-1} X^t X}_I \right] (\hat{\beta} - \beta) \\&= Y^t [X - X] (\hat{\beta} - \beta) \\&= Y^t [0] (\hat{\beta} - \beta) = 0\end{aligned}$$

- Portanto:

$$\|Y - X\beta\|^2 = \|Y - X\hat{\beta}\|^2 + 0 + \|X\hat{\beta} - X\beta\|^2 \geq \|Y - X\hat{\beta}\|^2$$

- pois, sendo uma distância,  $\|X\hat{\beta} - X\beta\|^2$  é sempre maior ou igual a zero.
- Isto é,  $\hat{\beta} = (X^t X)^{-1} X^t Y$  é o vetor de coeficientes  $\beta$  que minimiza  $\|Y - X\beta\|^2$  para todo vetor  $Y$

# A solução de mínimos quadrados

16

- Nosso problema: encontrar  $\hat{\beta}$  tal que o vetor  $X\beta$  do subespaço  $\mathfrak{M}(X)$  seja o mais próximo possível do vetor  $Y$ .
- O Teorema da Projeção Ortogonal garante que existe uma solução. Além disso,...
- Solução:  $\hat{\beta}$  tal que  $X\hat{\beta} \in \mathfrak{M}(X)$  é a projeção ortogonal de  $Y$  em  $\mathfrak{M}(X)$ .
- Mas como encontrar este vetor  $\hat{\beta}$  tal que  $X\hat{\beta}$  e seja esta projeção ortogonal?
- O Teorema da Projeção Ortogonal também nos dá a dica de como encontrar esta solução.

## Encontrando a solução de mínimos quadrados

- Solução é  $\hat{\beta}$ , um vetor tal que  $X\hat{\beta} \in \mathfrak{M}(X)$  é a projeção ortogonal de  $Y$  em  $\mathfrak{M}(X)$ .
- O Teorema da Projeção Ortogonal diz que a projeção  $X\hat{\beta}$  é única e é o vetor tal que  $X\hat{\beta} \perp (Y - X\hat{\beta})$ .
- Em resumo, devemos ter o produto interno zerado:  
$$\langle X\hat{\beta}, (Y - X\hat{\beta}) \rangle = 0.$$
- Isto implica que

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

# Example

# Concrete Compressive Strength

- A Resistência à Compressão do Concreto é uma medida da capacidade do concreto de suportar cargas que tendem a comprimir ou reduzir seu volume.
- É uma das propriedades mais críticas do concreto, indicando sua capacidade de suportar cargas estruturais sem romper.
- É definida como a tensão compressiva máxima que o concreto pode resistir antes da falha.
- É determinada pela aplicação de uma carga compressiva a uma amostra de concreto (geralmente um cubo ou um cilindro) sob condições controladas até que ela se quebre.
- <https://www.youtube.com/shorts/yGpwrL0zwHI>

# Kaggle Dataset

- Aim: To predict the compressive strength of concrete based on material composition.

## 🎯 Target Variable (Response Variable)

Feature Name	Description	Units	Typical Range
Compressive Strength	The maximum compressive stress the concrete can withstand.	MPa (MegaPascals)	2.33 - 82.6

- Number of Samples: 1,030 observations
- Number of Features: 8 predictors

## 🔍 Features (Predictor Variables)

Feature Name	Description	Units	Typical Range
Cement	The amount of cement used in the mix.	kg/m <sup>3</sup>	102 - 540
Blast Furnace Slag	By-product of steel production, often used as a cement substitute.	kg/m <sup>3</sup>	0 - 359.4
Fly Ash	A by-product of coal combustion, used as a partial cement replacement.	kg/m <sup>3</sup>	0 - 200.1
Water	The amount of water used in the mix.	kg/m <sup>3</sup>	121.8 - 247
Superplasticizer	Chemical additive to enhance workability and strength.	kg/m <sup>3</sup>	0 - 32.2
Coarse Aggregate	Gravel or crushed stone used as a filler material.	kg/m <sup>3</sup>	801 - 1145
Fine Aggregate	Sand used as a filler material.	kg/m <sup>3</sup>	594 - 992.6
Age	Age of the concrete sample when tested.	days	1 - 365

X'X matrix (9x9) scaled by 10^7:

```
[[ 0.    0.03  0.01  0.01  0.02  0.    0.1   0.08  0.   ]
 [ 0.03  9.27  1.88  1.3   5.24  0.19  28.08 22.21  1.38]
 [ 0.01  1.88  1.33  0.23  1.4   0.05  7.21  5.69  0.32]
 [ 0.01  1.3   0.23  0.72  0.98  0.05  5.43  4.36  0.19]
 [ 0.02  5.24  1.4   0.98  3.44  0.11  18.16 14.39  0.89]
 [ 0.    0.19  0.05  0.05  0.11  0.01  0.61  0.51  0.02]
 [ 0.1   28.08 7.21  5.43  18.16  0.61  98.12 77.41  4.57]
 [ 0.08  22.21 5.69  4.36  14.39  0.51  77.41 62.3   3.56]
 [ 0.    1.38  0.32  0.19  0.89  0.02  4.57  3.56  0.63]]
```

X'Y vector (9x1) scaled by 10^7: [0. 1.13 0.29 0.19 0.66 0.03 3.57 2.83 0.2 ]

The Normal Equations are: X'X \* B = X'Y

Where B is the vector of regression coefficients (intercept + slopes).

```
#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

## Projeção e predição

- Se as variáveis (colunas) da matriz  $X$  realmente servirem para prever o valor de  $Y$  e
- se o modelo de regressão linear for uma boa aproximação para o relacionamento das variáveis,
- então esperamos que

$$Y \approx \hat{Y} = X\hat{\beta}$$

- Como medir o grau de aproximação?
- É possível obter uma decomposição do vetor  $Y$  em componentes ortogonais. A partir daí extraímos uma medida de qualidade do ajuste.

## Decomposição em soma de quadrados

- Seja  $\bar{y} = \sum_i y_i / 1500$ , o preço médio dos 1500 apartamentos.
- Defina o vetor  $1500 \times 1$  dado por  $\bar{Y} = (\bar{y}, \bar{y}, \dots, \bar{y})' = \bar{y}(1, 1, \dots, 1)'$
- O vetor  $Y$  pode ser escrito como

$$Y = \hat{Y} + (Y - \hat{Y}) = \bar{Y} + \hat{Y} - \bar{Y} + (Y - \hat{Y})$$

- Isto é,

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_{1499} \\ y_{1500} \end{bmatrix} = \begin{bmatrix} \bar{y} \\ \bar{y} \\ \vdots \\ \bar{y} \\ \bar{y} \end{bmatrix} + \begin{bmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \vdots \\ \hat{y}_{1499} \\ \hat{y}_{1500} \end{bmatrix} - \begin{bmatrix} \bar{y} \\ \bar{y} \\ \vdots \\ \bar{y} \\ \bar{y} \end{bmatrix} + \begin{bmatrix} y_1 - \hat{y}_1 \\ y_2 - \hat{y}_2 \\ \vdots \\ y_{1499} - \hat{y}_{1499} \\ y_{1500} - \hat{y}_{1500} \end{bmatrix}$$

## Decomposição em soma de quadrados

- Isto é,

$$\begin{bmatrix} y_1 - \bar{y} \\ y_2 - \bar{y} \\ \vdots \\ y_{1499} - \bar{y} \\ y_{1500} - \bar{y} \end{bmatrix} = \begin{bmatrix} \hat{y}_1 - \bar{y} \\ \hat{y}_2 - \bar{y} \\ \vdots \\ \hat{y}_{1499} - \bar{y} \\ \hat{y}_{1500} - \bar{y} \end{bmatrix} + \begin{bmatrix} y_1 - \hat{y}_1 \\ y_2 - \hat{y}_2 \\ \vdots \\ y_{1499} - \hat{y}_{1499} \\ y_{1500} - \hat{y}_{1500} \end{bmatrix}$$

- $\mathbf{Y} - \bar{y}\mathbf{1} = (\hat{\mathbf{Y}} - \bar{y}\mathbf{1}) + (\mathbf{Y} - \hat{\mathbf{Y}})$
- Os vetores do lado direito são ortogonais um ao outro. Em consequência,

$$\|\mathbf{Y} - \bar{y}\mathbf{1}\|^2 = \|\hat{\mathbf{Y}} - \bar{y}\mathbf{1}\|^2 + \|\mathbf{Y} - \hat{\mathbf{Y}}\|^2$$

Remember

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

@

$(p+1) \times 1$

$$\hat{Y} = X\hat{\beta} = \underbrace{X(X'X)^{-1}X'}_H Y = HY$$

$m \times 1$

$H$  = hat matrix (put the hat on top of  $Y$ )

$H$  is  $m \times m$  ~~projection matrix~~

Properties of  $H$

Properties of  $H = X(X'X)^{-1}X'$

③

- i)  $H$  is  $m \times m$
- ii)  $H$  is the  $\perp$  projection matrix  
Projects where?  $\rightarrow$  In  $\mathcal{M}(X)$ ,  
linear combination  
of columns of  $X$
- iii)  $H^2 = H$  (show this)
- iv)  $H$  is symmetric (show this)

Fact If  $\vec{v} \perp \vec{w}$  then

(c)

$$\|\vec{v} + \vec{w}\|^2 = \|\vec{v}\|^2 + \|\vec{w}\|^2$$

Proof:  $\|\vec{v} + \vec{w}\|^2 = \langle \vec{v} + \vec{w}, \vec{v} + \vec{w} \rangle$

$$= (\vec{v} + \vec{w})^T (\vec{v} + \vec{w})$$


$$= (v^1 + w^1) \cdot (v + w)$$

$$= v^1 v + \underbrace{v^1 w}_{\text{O } \text{ bei } \vec{v} \perp \vec{w}} + \underbrace{w^1 v}_{\text{O } \text{ bei } \vec{v} \perp \vec{w}} + w^1 w$$



$$= \|v\|^2 + \|w\|^2$$


Assumption: column  $\underline{i}$  is in  $X$  ④

$$X = \begin{bmatrix} 1 & x_{11} & \dots & x_{1p} \\ & \vdots & & \vdots \\ & & & \\ 1 & x_{m1} & \dots & x_{mp} \end{bmatrix} \quad \underline{i} \in M(X)$$
$$\underline{i} = 1 \cdot \underline{1} + 0 \cdot \underline{x_1} + \dots + 0 \cdot \underline{x_m}$$



(e)





$$\begin{aligned}
 \bar{y}_1 &= \left( \frac{1}{n} \sum y_i \right) \frac{1}{n} = \frac{1}{n} \underbrace{\left( \frac{1}{n} \cdot \underbrace{Y}_{\text{matrix associated with } \frac{1}{n}} \right)}_{\text{matrix associated with } \frac{1}{n}} \cdot \frac{1}{n} = \frac{1}{n} \frac{1}{n} \left( \frac{1}{n} \cdot Y \right) \\
 &\quad \left( \frac{1}{n}, \dots, \frac{1}{n} \right) \cdot \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} = \frac{1}{n} \left( \frac{1}{n} \cdot \frac{1}{n} \right) \cdot Y \\
 &= \frac{1}{n^2} Y
 \end{aligned}$$

*é um vetor escalar*

→  $U$  é matriz de projeção perpendicular ao vetor  $\frac{1}{\sqrt{n}}$  ⑧

Prova: basta mostrar que, para todos  $Y \in \mathbb{R}^n$ , temos



$$(UY) \perp (Y - UY).$$


$$(UY)^T \cdot (Y - UY) = (Y^T U^T) \cdot ((I - U) \cdot Y) = Y^T (U^T (I - U)) \cdot Y$$

$$= Y^T (U^T - U^T U) Y.$$

Mas  $U^T = U$  (show this)  $\Rightarrow U^T - U^T U = U - U^2 = 0$   
 $U^2 = U$  (show this)

~~q.e.d.~~





$$y - \bar{y}_1$$

~~scribble~~

$$\hat{y} - \bar{y}_2 = \hat{y} - \bar{y}_1 + \hat{y} - \hat{y}$$

~~scribble~~

(identifie  
 $\hat{y} - \bar{y}_2$  ma figure)

$$\tilde{Y} - \tilde{g}\tilde{z} = (\hat{Y} - \hat{g}\hat{z}) + (\tilde{Y} - \hat{Y})$$

↑'s !!!

$$\begin{aligned}\tilde{Y} - V\tilde{Y} &= (H\tilde{Y} - V\tilde{Y}) + (\tilde{Y} - H\tilde{Y}) \\ &= \underbrace{(H-V) \cdot \tilde{Y}}_{\perp ??} + \underbrace{(I-H) \cdot \tilde{Y}}_{\perp ??}\end{aligned}$$

Calcular  $\langle (H-V) \cdot \tilde{Y}, (I-H) \cdot \tilde{Y} \rangle = (*)$




$$\begin{aligned}(*) &= \langle (I-H)\tilde{Y} \rangle^T \cdot (H-V)\tilde{Y} = \tilde{Y}^T (I-H)^T \cdot (H-V) \tilde{Y} = \\ &= \tilde{Y}^T ((I-H) \cdot (H-V)) \cdot \tilde{Y} = \tilde{Y}^T \left( H - V - \underbrace{H^2}_{= 0} + HV \right) \tilde{Y} \\ &= \tilde{Y}^T (-V + HV) \cdot \tilde{Y}. \quad \text{Mas } HV = V \Rightarrow (*) = 0\end{aligned}$$

(K)

Assum,  $(H-U)Y \perp (I-H)Y$  e

$$\underbrace{\|Y - \bar{y}\|_2^2}_{\text{SSTotal}} = \|\hat{Y} - \bar{y}\|_2^2 + \|Y - \hat{Y}\|_2^2$$

$$\underbrace{\sum_i (y_i - \bar{y})^2}_{\text{SSTotal}} = \underbrace{\sum_i (\hat{y}_i - \bar{y})^2}_{\text{SSReg}} + \underbrace{\sum_i (y_i - \hat{y}_i)^2}_{\text{SSRes}}$$



## The sum of squares

- When the residual vector

$$\|\mathbf{r}\|^2 = \|\mathbf{Y} - \hat{\mathbf{Y}}\|^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

is small, we have a good fit.

- The idea is to compare this remaining variability with the original variability in  $\mathbf{Y}$  BEFORE any regressors were considered.
- The variation of  $\mathbf{Y}$  around  $\bar{y}$ , the mean of  $\mathbf{Y}$ , is equal to:

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \|\mathbf{Y} - \bar{y}\mathbf{1}\|^2$$

## Finally, the $R^2$

- That is, we consider the ratio

$$\frac{||\mathbf{Y} - \hat{\mathbf{Y}}||^2}{||\mathbf{Y} - \bar{y}\mathbf{1}||^2}$$

- If we have a good fit, we should have this ratio close to zero.
- We can prove that this ratio is always smaller than 1.
- Hence, it is more common to use  $R^2$ :

$$R^2 = 1 - \frac{||\mathbf{Y} - \hat{\mathbf{Y}}||^2}{||\mathbf{Y} - \bar{y}\mathbf{1}||^2}$$

- A good fit should have  $R^2 \approx 1$ .

```
#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

# Matriz de projeção ortogonal

Seja  $X$  uma matriz de números reais de dimensão  $n \times (p + 1)$ , seja  $\beta = (\beta_0, \beta_1, \dots, \beta_p)$  um vetor  $(p + 1) \times 1$  e  $\mathbf{y}$  um vetor  $n \times 1$ .

Sejam  $v_1, \dots, v_k$  vetores do  $\mathbb{R}^n$ . Verifique que o conjunto das combinações lineares desses vetores forma um sub-espaco vetorial do  $\mathbb{R}^n$ .

- Verifique que  $X\beta = \beta_0X_0 + \beta_1X_1 + \dots + \beta_pX_p$  onde  $X_0, X_1, \dots, X_p$  são os vetores colunas de  $X$ . Assim, o conjunto  $\mathfrak{M}(X)$  das combinações lineares das colunas de  $X$  é igual a  $\mathfrak{M}(X) = \{X\beta \mid \beta \in \mathbb{R}^{p+1}\}$ .

Seja  $X$  uma matriz de números reais de dimensão  $n \times (p + 1)$ , seja  $\beta = (\beta_0, \beta_1, \dots, \beta_p)$  um vetor  $(p + 1) \times 1$  e  $\mathbf{y}$  um vetor  $n \times 1$ .

- Verifique que  $X\beta = \beta_0 X_0 + \beta_1 X_1 + \dots + \beta_p X_p$  onde  $X_0, X_1, \dots, X_p$  são os vetores colunas de  $X$ . Assim, o conjunto  $\mathfrak{M}(X)$  das combinações lineares das colunas de  $X$  é igual a  $\mathfrak{M}(X) = \{X\beta \mid \beta \in \mathbb{R}^{p+1}\}$ .
- Seja  $W$  um subespaço do espaço vetorial  $V$ . Definimos o espaço ortogonal de  $W$  como sendo

$$W^\perp = \{u \in V \mid \langle u, w \rangle = 0 \quad \forall w \in W\}$$

Mostre que  $W^\perp$  é um subespaço vetorial de  $V$ .

**Solução:**  $\vec{0} \in W^\perp$  pois  $\langle \vec{0}, w \rangle = 0$  para todo  $w \in W$ . E tambem  $\langle a_1 u_1 + a_2 u_2, w \rangle = 0$  se  $\langle u_1, w \rangle = 0$  e  $\langle u_2, w \rangle = 0$

# A matriz de projeção ortogonal

- Seja  $H = X(X'X)^{-1}X'$  de dimensão  $n \times n$ . Verifique que  $H$  é idempotente ( $H^2 = H$ ) e simétrica ( $H' = H$ ).

# A matriz de projeção ortogonal

- Seja  $H = X(X'X)^{-1}X'$  de dimensão  $n \times n$ . Verifique que  $H$  é idempotente ( $H^2 = H$ ) e simétrica ( $H' = H$ ).
- Seja  $y \in \mathbb{R}^n$ . A matriz  $P$  de dimensão  $n \times n$  é dita de projeção ortogonal num certo subespaço vetorial se  $y - Py \perp Py$  para todo  $y \in \mathbb{R}^n$ . Mostre que  $H = X(X'X)^{-1}X'$  é uma matriz de projeção ortogonal usando que  $H$  é idempotente e simétrica.

# A matriz de projeção ortogonal

- Seja  $H = X(X'X)^{-1}X'$  de dimensão  $n \times n$ . Verifique que  $H$  é idempotente ( $H^2 = H$ ) e simétrica ( $H' = H$ ).
- Seja  $y \in \mathbb{R}^n$ . A matriz  $P$  de dimensão  $n \times n$  é dita de projeção ortogonal num certo subespaço vetorial se  $y - Py \perp Py$  para todo  $y \in \mathbb{R}^n$ . Mostre que  $H = X(X'X)^{-1}X'$  é uma matriz de projeção ortogonal usando que  $H$  é idempotente e simétrica.
- Como  $H = X(X'X)^{-1}X'$  é uma matriz de projeção ortogonal, resta saber em que sub-espaço vetorial  $W$  a matriz  $H$  projeta os vetores  $y \in \mathbb{R}^n$ . Mostre que  $H$  projeta ortogonalmente em  $\mathfrak{M}(X)$  (isto é, mostre que  $W = \mathfrak{M}(X)$ .)

**Solução:** Para todo  $y \in \mathbb{R}^n$ , temos  $Hy = X(X'X)^{-1}X'y = Xb$  onde  $b = (X'X)^{-1}X'y$ . Assim,  $Hy \in \mathfrak{M}(X)$  para todo  $y$  e portanto  $W \subset \mathfrak{M}(X)$ . Por outro lado, tome um elemento  $Xb$  qualquer de  $\mathfrak{M}(X)$ . Por definição,  $Hy \in W$  para todo  $y$ . Em particular, tomando  $y = Xb$ , temos então  $HXb \in W$ . Mas  $HXb = X(X'X)^{-1}X'Xb = Xb$ . Isto é,  $Xb \in W$  e portanto  $\mathfrak{M}(X) \subset W$ . Concluímos então que  $W = \mathfrak{M}(X)$ .

# LS = projeção ortogonal

- Seja  $H = X(X'X)^{-1}X'$  a matriz de projeção ortogonal no espaço  $\mathfrak{M}(X)$  das combinações lineares das colunas de  $X$ . Mostre que ao escolher  $\beta$  tal que  $X\beta = Hy$  estamos minimizando a distância  $\|y - X\beta\|^2$ . DICAS: Escreva some e subtraia  $Hy$  em  $\|y - X\beta\|^2$  e use que  $\|v\|^2 = \langle v, v \rangle$

**Solução:**  $\|y - X\beta\|^2 = \langle y - X\beta, y - X\beta \rangle$ . Somando e subtraindo  $Hy$  obtemos

$$\begin{aligned}\|y - X\beta\|^2 &= \langle y - Hy + Hy - X\beta, y - Hy + Hy - X\beta \rangle \\ &= \langle y - Hy, y - Hy \rangle + \langle Hy - X\beta, Hy - X\beta \rangle - 2 \langle y - Hy, Hy - X\beta \rangle \\ &= \|y - Hy\|^2 + \|Hy - X\beta\|^2 + 0.\end{aligned}$$

O último termo acima é zero pois  $Hy - X\beta \in \mathfrak{M}(X)$  já que  $Hy \in \mathfrak{M}(X)$  e  $X\beta \in \mathfrak{M}(X)$  e o conjunto  $\mathfrak{M}(X)$  é um sub-espaco vetorial (e portanto contém a diferença dos vetores). Além disso,  $y - Hy \in \mathfrak{M}(X)^\perp$ . Portanto, o produto interno  $\langle y - Hy, Hy - X\beta \rangle$  é nulo.

Assim,  $\|y - X\beta\|^2 = \|y - Hy\|^2 + \|Hy - X\beta\|^2$ . O primeiro termo do lado direito não depende de  $\beta$  e o segundo é não-negativo. Ele será minimizado se for igual a zero, o que ocorre se tomamos  $X\beta = Hy$ .