

# Método dos processos Gaussianos: Análise de dados em cosmologia

Kevin Mota da Costa

UFES

Julho/2023

# Definição de regressão linear

Dado um conjunto de vetores  $\{\mathbf{x}, \mathbf{y}\}$  se pretende encontrar um função tal que  $\mathbf{y} = f(\mathbf{x}) + \epsilon$

# Definição de regressão linear




Figure: C. E. Rasmussen & C. K. I. Williams, Gaussian Processes for Machine Learning

# Teorema do limite central

O teorema do limite central da probabilidade afirma que dado um conjunto  $X_1, X_2, \dots, X_n$  de  $n$  variáveis aleatórias, então

$$\lim_{n \text{ grande}} S_n \sim \mathcal{N}(\mu, \Sigma) \quad (1)$$

Assumimos então

$$\epsilon \sim \mathcal{N}(\mu, \Sigma) \quad (2)$$

A definição do modelo para o ruído junto com a definição da função  $f(\mathbf{x})$  da origem ao conceito de *likelihood*

$$P(\mathbf{y}|\mathbf{x}, \mathbf{w}) = \prod_{i=1}^n P(y_i|\mathbf{x}_i, \mathbf{w}) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma_n} \exp\left(-\frac{1}{2} \frac{(\mathbf{y}_i - \mathbf{x}_i^T \mathbf{w})^2}{\sigma_n^2}\right)$$

$$P(\mathbf{y}|\mathbf{x}, \mathbf{w}) = \frac{1}{(2\pi\sigma_n^2)^{\frac{n}{2}}} \exp\left(-\frac{1}{2\sigma_n^2} |\mathbf{y} - \mathbf{X}^T \mathbf{w}|^2\right) = \mathcal{N}(\mathbf{X}^T \mathbf{w}, \sigma_n^2 I_n)$$

A *likelihood* é a distribuição de probabilidade das observações dado o modelo

# Inferencia bayesiana

A inferência bayesiana é baseada na distribuição de probabilidade posterior sobre os parâmetros através do Teorema de Bayes

$$\text{posterior} = \frac{\textit{likelihood} \cdot \textit{prior}}{\textit{marginal likelihood}}$$

$$P(\mathbf{w}|\mathbf{y}, \mathbf{x}) = \frac{P(\mathbf{y}|\mathbf{x}, \mathbf{w}) \cdot P(\mathbf{w})}{P(\mathbf{y}|\mathbf{x})}$$

$$P(\mathbf{y}|\mathbf{x}) = \int P(\mathbf{y}|\mathbf{x}, \mathbf{w}) d\mathbf{w}$$

$$P(\mathbf{w}|\mathbf{y}, \mathbf{x}) \sim \mathcal{N}\left(\frac{1}{\sigma_n^2} A^{-1} \mathbf{x} \mathbf{y}, A^{-1}\right)$$

$$A = \sigma_n^{-2} \mathbf{x} \mathbf{x}^T + \Sigma^{-1}$$

Para realizar predições sobre os o vetor de entrada  $\mathbf{x}^*$  dados os vetores de treinamento  $\{x, y\}$  aplicamos

$$P(f^*|\mathbf{x}^*, x, y) = \int P(f^*|\mathbf{x}^*, w)P(w|x, y)dw$$

$$P(f^*|\mathbf{x}^*, x, y) = \mathcal{N}\left(\frac{1}{\sigma_n^2}\mathbf{x}^{*T}A^{-1}Xy, \mathbf{x}^{*T}A^{-1}\mathbf{x}^*\right)$$

# O método dos processos gaussianos

Um processo gaussiano (unidimensional) é uma família de variáveis aleatórias  $\{f(x)\}_{x \in \mathcal{X}}$ , tal que qualquer coleção finita em um subconjunto de  $\{f(x)\}$  tem uma distribuição conjunta gaussiana.

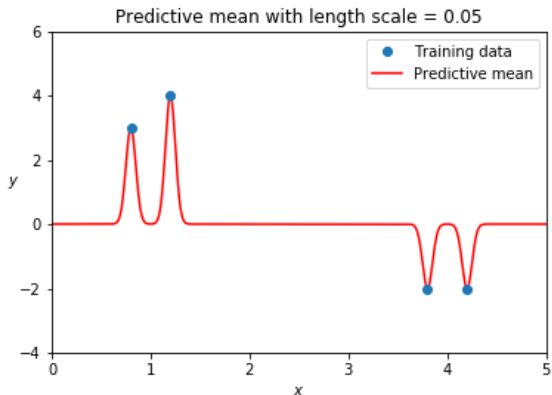
$$f \sim GP(\mu, \Sigma) \quad (3)$$

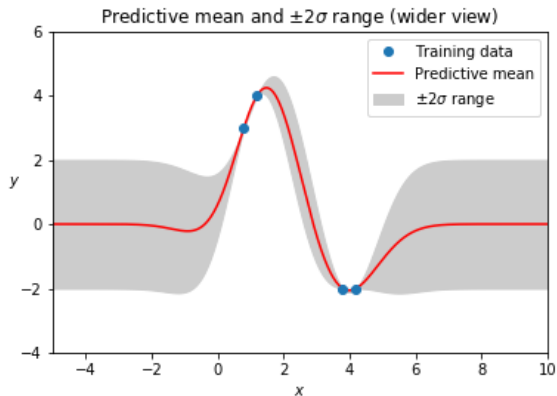
Um processo gaussiano é definido unicamente pela de média  $\mu$  e pela covariância  $\Sigma$



# Função de Média

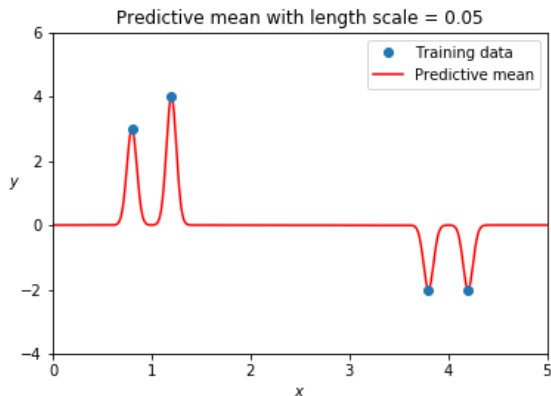
A função de média define a tendência global da função  $f^*$ , agindo - principalmente - onde não existem muitos pontos de input





# Função de Covariância

A função de covariância calcula a similaridade entre dois pontos, definindo o comportamento do ajuste principalmente em pontos locais



# Regressão bayesiana

## Método dos processos gaussianos para regressão

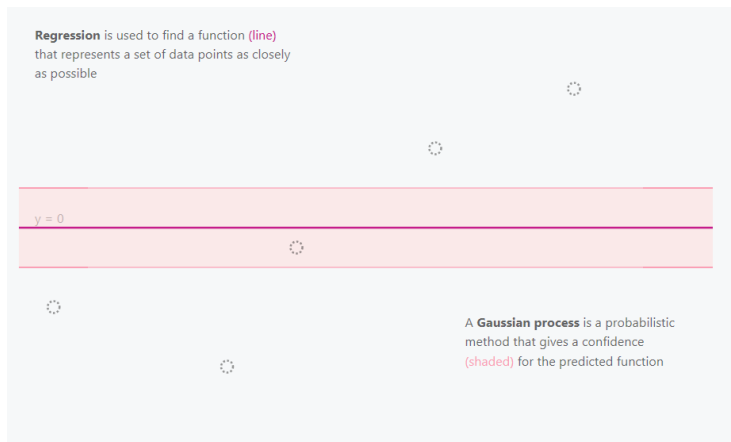


Figure: <https://distill.pub/2019/visual-exploration-gaussian-processes/>

# Regressão bayesiana

## Método dos processos gaussianos para regressão

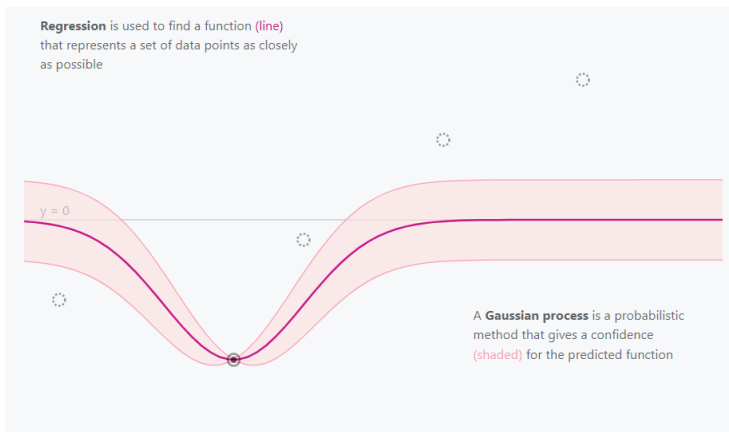


Figure: C. E. Rasmussen C. K. I. Williams, Gaussian Processes for Machine Learning

# Regressão bayesiana

## Método dos processos gaussianos para regressão




Figure: <https://distill.pub/2019/visual-exploration-gaussian-processes/>

# Regressão bayesiana

## Método dos processos gaussianos para regressão




Figure: <https://distill.pub/2019/visual-exploration-gaussian-processes/>

# Regressão bayesiana

## Método dos processos gaussianos para regressão




Figure: <https://distill.pub/2019/visual-exploration-gaussian-processes/>



# Regressão bayesiana

## Método dos processos gaussianos para regressão

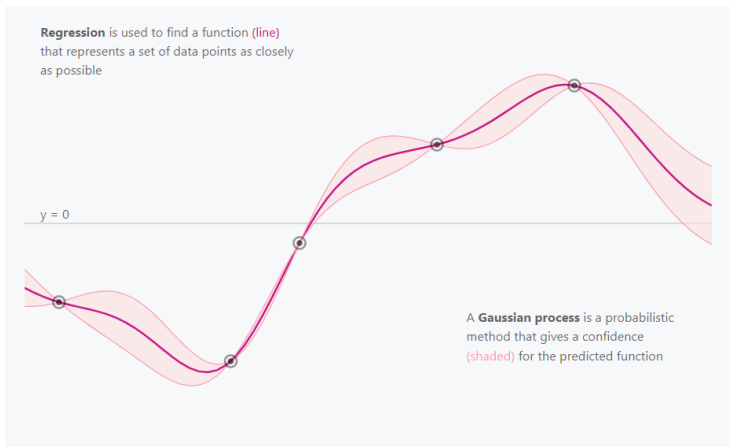



Figure: <https://distill.pub/2019/visual-exploration-gaussian-processes/>

Apesar da independência de um modelo de regressão, os processos gaussianos são muito dependentes de 3 fatores extremamente sensíveis

- Kernel
- Média
- Hiperparâmetros

# Regressão bayesiana

Utilizarei os dados de parâmetro de Hubble



Para os dados de Parâmetro de Hubble, utilizarei duas médias:

- LCDM:

$$H(z) = H_0 \sqrt{\Omega_{m0}(1+z)^3 + \Omega_{k0}(1+z)^2 + (1 - \Omega_{m0} - \Omega_{k0})}$$

- Zero:

$$H(z) = 0$$

O Kernel Matern é definido por


$$\text{Matern}_\nu(x, x') = \frac{2^{1-\nu}}{\Gamma(\nu)} \left( \frac{\sqrt{2\nu} \|x - x'\|}{\rho} \right)^\nu K_\nu \left( \frac{\sqrt{2\nu} \|x - x'\|}{\rho} \right)$$

Onde

- $\nu$  é um parâmetro semi-inteiro
- $\Gamma$  é a função gamma
- $K_\nu$  é a função de Bessel modificada de ordem  $\nu$


# Regressão bayesiana

Reconstrução para o Kernel Matern 3/2, com média LCDM




# Regressão bayesiana

Reconstrução para o Kernel Matern 3/2, com média Zero



# Regressão bayesiana


Reconstrução para o Kernel Matern 9/2, com média LCDM





# Regressão bayesiana

Reconstrução para o Kernel Matern 9/2, com média Zero



O Kernel Squared Exponential

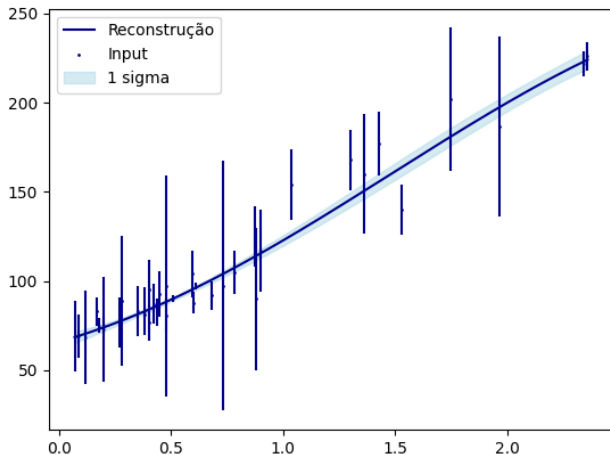
$$SE(x, x') = \sigma^2 \exp\left(-\frac{\|x - x'\|^2}{2\ell^2}\right)$$

Onde

- $\sigma$  é o parâmetro de variância
- $\ell$  é o parâmetro de escala


# Regressão bayesiana


Reconstrução para o Squared Exponential, com média Zero



# Regressão bayesiana

Reconstrução para o Squared Exponential, com média LCDM





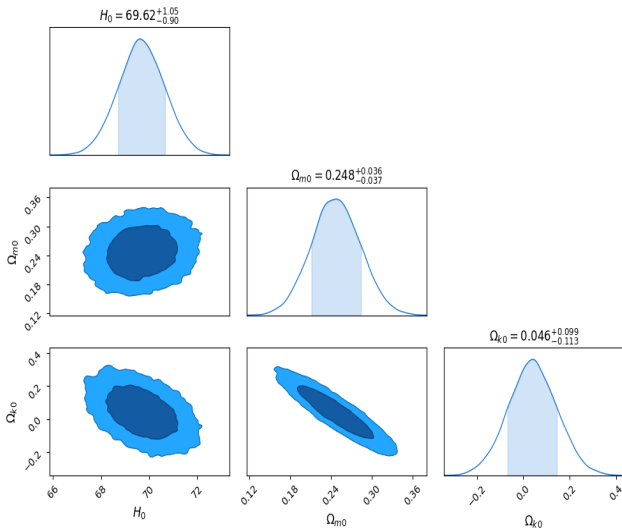


Figure: Resultado para os dados observacionais

# Inferência Estatística

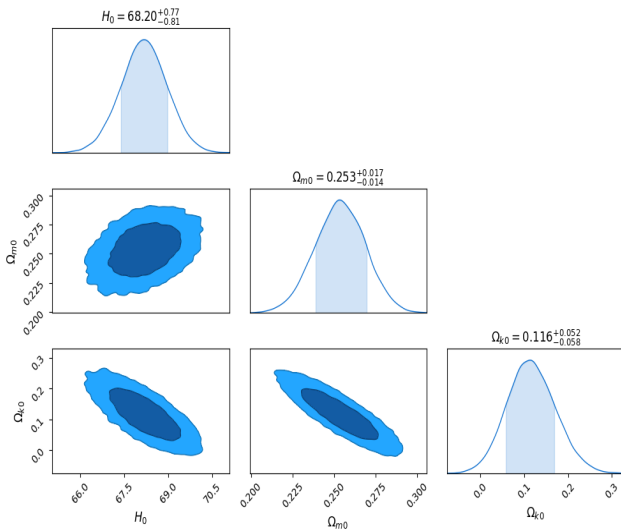


Figure: Resultado para o Kernel de Cauchy, com média LCDM ▶

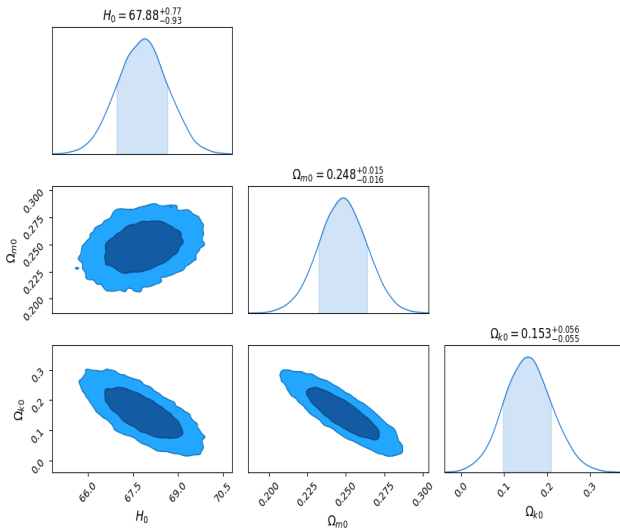


Figure: Resultado para o Kernel de Cauchy, com média Zero



# Inferência Estatística

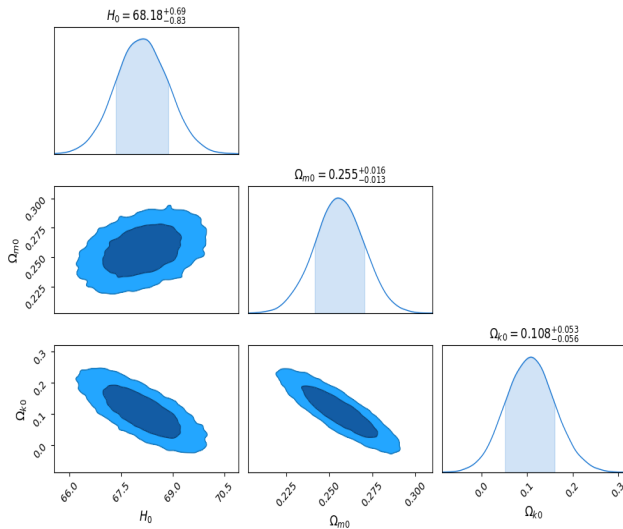


Figure: Resultado para o Kernel de Matern 1.5, com média  $\Lambda$ CDM

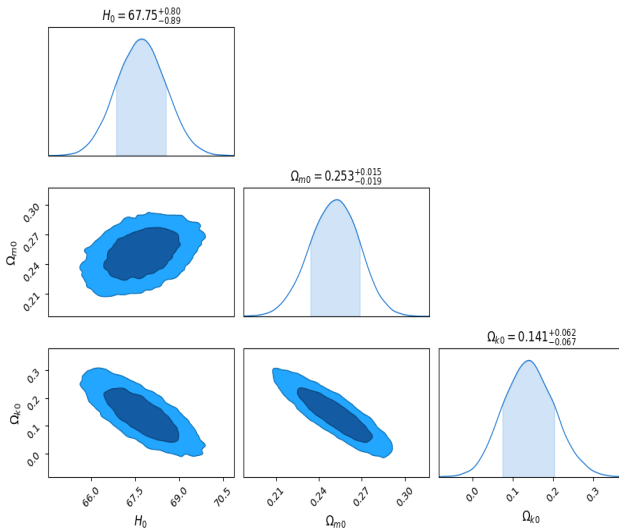


Figure: Resultado para o Kernel de Matern 1.5, com média Zero

- [1] Carl. Rasmussen and Christopher. Williams Gaussian Processes for Machine Learning