

# Integração Numérica: Funções multivariadas

Prof. Caio Azevedo

- Objetivo: calcular aproximações analíticas numérica para integrais multivariadas (k-variadas).

- Relembrando:  $\int_a^b \left( \int_c^d f(x, y) dx \right) dy = F(b, d) - F(a, d) - F(b, c) + F(a, c)$ ,  $F(x, y) = \frac{\partial^2}{\partial x \partial y'} f(x, y) = \frac{\partial^2}{\partial y \partial x'} f(x, y)$ .

- Soluções:

- Aproximações analíticas (Laplace).
- Aproximações numéricas não estocásticas (Quadratura, Quadratura adaptativa).
- Aproximações numéricas estocásticas (não-iterativas) (Monte Carlo).
- Aproximações numéricas estocásticas iterativas (Monte Carlo via Cadeias de Markov).

# Aproximações analíticas

- Sob certas condições, para um dado  $\mathbf{x}_0$ ,

$$f(\mathbf{x}) = f(\mathbf{x}_0) + \frac{\partial}{\partial \mathbf{x}} f(\mathbf{x}_0)(\mathbf{x} - \mathbf{x}_0) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_0)' \frac{\partial^2}{\partial \mathbf{x} \partial \mathbf{x}'} f(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0) + R.$$

- Suponha que desejamos calcular

$\int_{a_1}^{b_1} \int_{a_2}^{b_2} \dots \int_{a_k}^{b_k} e^{Mf(\mathbf{x})} d\mathbf{x}$ ,  $\mathbf{x} = (x_1, \dots, x_k)$ . Suponha que existe um único máximo global para  $f(\cdot)$ .

# Aproximação de Laplace (AL)

- Seja  $\mathbf{x}_0$  o máximo global de  $f(\cdot)$ . Então :

$$f(\mathbf{x}) \approx f(\mathbf{x}_0) + \frac{1}{2} (\mathbf{x} - \mathbf{x}_0)' \frac{\partial^2}{\partial \mathbf{x} \partial \mathbf{x}'} f(\mathbf{x}_0) (\mathbf{x} - \mathbf{x}_0)$$

## Cont.

- Aproximação de Laplace:

$$\begin{aligned}
 & \int_{a_1}^{b_1} \int_{a_2}^{b_2} \dots \int_{a_k}^{b_k} e^{Mf(\mathbf{x})} d\mathbf{x} \approx \\
 & e^{Mf(\mathbf{x}_0)} \int_{a_1}^{b_1} \int_{a_2}^{b_2} \dots \int_{a_k}^{b_k} e^{-M\frac{1}{2}(\mathbf{x}-\mathbf{x}_0)'\left[-\frac{\partial^2}{\partial\mathbf{x}\partial\mathbf{x}'}f(\mathbf{x}_0)\right](\mathbf{x}-\mathbf{x}_0)} d\mathbf{x} \\
 & = e^{Mf(\mathbf{x}_0)} \left( \sqrt{2\pi M \left| -\frac{\partial^2}{\partial\mathbf{x}\partial\mathbf{x}'}f(\mathbf{x}_0) \right|} \right)^{-1} \\
 & \times P(\mathbf{X} \in A)
 \end{aligned}$$

$\mathbf{X} \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  e  $A$  é a região de integração correspondente.

# Característica da AL

- Relativamente rápida.
- Adequada quando o integrando é unimodal e o máximo pode ser obtido facilmente (ainda que seja necessário utilizar métodos numéricos).
- Inadequada: em integrais múltiplas à medida que a dimensão aumenta e/ou o máximo é complicado de ser obtido.
- Mesmo no caso univariado para funções complicadas: vários máximos locais, assimetria, etc.

## Exemplo: Dirichlet

- $$f(x, y) = \frac{1}{\beta(\alpha, \beta, \gamma)} x^{\alpha-1} y^{\beta-1} (1-x-y)^{\gamma-1} \mathbb{1}_{(0,1)}(x) \mathbb{1}_{(0,1-x)}(y) =$$

$$\frac{1}{\beta(\alpha, \beta, \gamma)} x^{\alpha-1} y^{\beta-1} (1-x-y)^{\gamma-1} \mathbb{1}_{(0,1-y)}(x) \mathbb{1}_{(0,1)}(y) ;$$

$$\beta(\alpha, \beta, \gamma) = \frac{\Gamma(\alpha)\Gamma(\beta)\Gamma(\gamma)}{\gamma(\alpha+\beta+\gamma)}.$$
- Função:  $f(x) = \int_0^{1/3} \left( \int_0^{1/3} f(x, y) dy \right) dx$
- Pode-se provar que  $x_0 = \frac{\alpha-1}{\alpha+\beta+\gamma-3}$  e  $y_0 = \frac{\beta-1}{\alpha+\beta+\gamma-3}$ .
- Além disso

$$-\Sigma^{-1} = \frac{\partial}{\partial \mathbf{x} \partial \mathbf{x}'} f(\mathbf{x}) = \begin{bmatrix} -\frac{\alpha-1}{x^2} - \frac{\gamma-1}{(1-x-y)^2} & -\frac{\gamma-1}{(1-x-y)^2} \\ -\frac{\gamma-1}{(1-x-y)^2} & -\frac{\beta-1}{y^2} - \frac{\gamma-1}{(1-x-y)^2} \end{bmatrix}$$

# Cont.

- $f(\mathbf{x}_0) = \exp((\alpha - 1) \ln(x) + (\beta - 1) \ln(y) + (\gamma - 1) \ln(1 - x - y))$ .
- $h \approx \frac{1}{\beta(\alpha, \beta, \gamma)} e^{f(\mathbf{x}_0)} (2\pi |\boldsymbol{\Sigma}|)^{-1} P(0 < X_1 < 1/3, 0 < X_2 < 1/3),$   
 $\mathbf{X} \sim N((x_0, y_0), \boldsymbol{\Sigma}(x_0, y_0)).$



# Integração por Quadratura

- Substituir (no caso multivarido) o cálculo da área sob a curva pela soma das áreas de um número finito de paralelepípedos.
- Ponto-chave: Definir os pontos e pesos de quadratura.
- Formas de cálculo dos pontos e pesos:
  - Não-adaptativa: mantem-se fixo os pontos e pesos.
  - Adaptativa: muda-se os pontos e pesos.

# Características

- Em geral, na Estatística, deseja-se calcular

$$\mathcal{E}(w(\mathbf{X})) = \int_{a_1}^{b_1} \int_{a_2}^{b_2} \dots \int_{a_k}^{b_k} w(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}, \text{ onde } f(\cdot) \text{ é alguma fdp.}$$

- Assim,  $f(\cdot)$  terá massa relevante em apenas um subconj. de  $\mathcal{R}$ .

- Define-se um conjunto de pontos,  $(x_{11}, x_{12}, \dots, x_{1k});$

$(x_{21}, x_{22}, \dots, x_{2k}); \dots; (x_{m1}, x_{m2}, \dots, x_{mk})$  e os respectivos pesos

associados  $A_1, A_2, \dots, A_k, A = \prod_{j=1}^k A_j, A_j = A(x_{ij}), i = 1, 2, \dots, m,.$

Em geral, os pesos correspondem aos comprimentos dos intervalos determinados pelos pontos de quadraturas, em cada dimensão.

- Pode-se imaginar que cada ponto corresponde ao valor médio de intervalos de mesmo comprimento.

# Continuação

- Pontos de Quadratura:

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1k} \\ x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mk} \end{bmatrix}_{m \times k}$$

# Continuação

- À semelhança do que ocorre no caso univariado, tem-se o mesmo comprimento para cada dimensão, ou seja
- Comprimentos dos intervalos de Quadratura:

$$\mathbf{A} = \begin{bmatrix} A_1 & A_2 & \dots & A_k \\ A_1 & A_2 & \dots & A_k \\ \vdots & \vdots & \ddots & \vdots \\ A_1 & A_2 & \dots & A_k \end{bmatrix}_{m \times k}$$

- Assim, tem-se um vetor coluna com todos os elementos iguais à

$$A = \prod_{j=1}^k A_j.$$

# Continuação

- Faz-se necessário a construção de uma matriz com todas as  $k$ -uplas possíveis de serem formadas com os pontos de Quadratura de cada dimensão. Pelo princípio fundamental da contagem temos um total de  $m^k$   $k$ -uplas possíveis.

# Continuação

- Exemplo  $m = 3, k = 2$

$$\mathbf{X}^* = \begin{bmatrix} x_{11} & x_{12} \\ x_{11} & x_{22} \\ x_{11} & x_{32} \\ x_{21} & x_{12} \\ x_{21} & x_{22} \\ x_{21} & x_{32} \\ x_{31} & x_{12} \\ x_{31} & x_{22} \\ x_{31} & x_{32} \end{bmatrix} m^k \times k$$

# Continuação

- Analogamente, constrói-se um vetor com elementos todos iguais à  $A$ , de dimensão  $m^k \times 1$

# Continuação

- Exemplo  $m = 3, k = 2$

$$\mathbf{A}^* = \begin{bmatrix} A \\ A \\ A \\ A \\ A \\ A \\ A \\ A \\ A \\ A \end{bmatrix}_{m^k \times 1}$$



# Cont.

- Seja  $\mathcal{I}$  o conjunto que contém todas as k-uplas necessárias.
- Assim

$$\int_{a_1}^{b_1} \int_{a_2}^{b_2} \dots \int_{a_k}^{b_k} w(\mathbf{x}) f(\mathbf{x}) d\mathbf{x} \approx \sum_{i \in \mathcal{I}} A_i w(\mathbf{x}_i) f(\mathbf{x}_i)$$

em que  $\mathbf{x}_i$  é o vetor que contém a k-ésima upla.

# Cont.

- Existem várias formas de se determinar os pontos e pesos. Em geral, faz-se, em torno do máximo (moda) de  $f(\cdot)$ . Pontos ótimos, em geral, são obtidos através de certos polinômios.
- Polinômios de Gauss-Hermite, Gauss-Legendre, Jacobi, Legendre, Gauss-Laguerre etc. Veja Abramowitz & Stegun (1972).

# Exemplo: Normal multivariada

- Seja  $\mathbf{X} \sim N_k(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ .
- Ver programa no arquivo para R.

# Quadratura Adaptativa

- Atualização dos pontos e pesos de quadratura.
- Nosso interesse continua sendo  $h = \int_{a_1}^{b_1} \int_{a_2}^{b_2} \dots \int_{a_k}^{b_k} w(\mathbf{x})f(\mathbf{x})d\mathbf{x}$ .
- Algoritmo
  - Calcule duas aproximações para h (considerando  $k=2$ ),  
 $S_1 = S(f(x); \mathbf{a}, \mathbf{b}) = \sum_{i=1}^m A_i w(\mathbf{x}_i) f(\mathbf{x}_i)$  e  
 $S_2 = S(f(x); a_1, (a_1 + b_1)/2, a_2, (a_2 + b_2)/2) + S(f(x); (a_1 + b_1)/2, b_1, (a_2 + b_2)/2, b_2) + S(f(x); (a_1 + b_1)/2, b_1, a_2, (a_2 + b_2)/2) + S(f(x); (a_1 + b_1)/2, b_1, (a_2 + b_2)/2, b_2)$ .
  - Calcule  $\epsilon = |S_1 - S_2|$ .
  - Se  $\epsilon < \tau$ , pare, caso contrário, aplique o passo 1, recursivamente, até que a precisão requerida seja atingida.

# Quadratura Adptativa no R

- Pacote **cubature**.
- Função **adaptIntegrate** .
- Permite calcular integrais, usando a quadratura adaptativa, para funções pré-definidas pelo usuário, em um dado intervalo.

# Integração por Monte Carlo

- Lei Forte dos Grandes Números: Seja  $\mathbf{X}_1, \mathbf{X}_2, \dots$  uma sequência iid, tal que  $\mathcal{E}(\mathbf{X}_i) = \boldsymbol{\mu}, \forall i$ . Defina  $Y_1, Y_2, \dots$ ,  
 $Y_i = g(\mathbf{X}_i), i = 1, 2, \dots, \mathcal{E}(Y_i) = \mathcal{E}(g(\mathbf{X}_i)) = h(\boldsymbol{\mu}) = \mu_y$ . Então

$$\bar{Y}_n = \sum_{i=1}^n \frac{1}{n} Y_i \xrightarrow{q.c.} \mu_y$$

- Integração por Monte Carlo.
  - 1 Gere um conjunto de  $m$  vetores aleatórios i.i.d, digamos  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m$ .
  - 2 Calcule  $h \approx \frac{1}{n} \sum_{i=1}^m w(\mathbf{x}_i)$ .

# Integração por Amostragem por Importância

- Muito esforço para simular pontos com massa desprezível
- Pode ser complicado definir o valor esperado e/ou a distribuição apropriadas.
- Refinar a geração dos números aleatórios: método da amostragem por importância.

# Algoritmo

- Gere uma amostra aleatória,  $\mathbf{X}_1, \dots, \mathbf{X}_m$  de uma densidade candidata  $g(\cdot)$  com o mesmo suporte  $f(\cdot)$ .

- Assim

$$h = \int_{a_1}^{b_1} \int_{a_2}^{b_2} \dots \int_{a_k}^{b_k} w(\mathbf{x}) f(\mathbf{x}) d\mathbf{x} = \int_{a_1}^{b_1} \int_{a_2}^{b_2} \dots \int_{a_k}^{b_k} w(\mathbf{x}) \frac{f(\mathbf{x})}{g(\mathbf{x})} g(\mathbf{x}) d\mathbf{x}.$$

- Construa pesos de importância

$$W(X_i) = \frac{f(X_i)}{g(X_i)}$$

- Calcule  $h \approx \frac{1}{m} \sum_{i=1}^m W(X_i) w(X_i)$



Exemplo:  $f(x_1, x_2) = e^{-90(x_1-0,5)^2} e^{-10(x_2+0,1)^4}$

- $h = \int_{-1}^1 \left( \int_{-1}^1 e^{-90(x_1-0,5)^2} e^{-10(x_2+0,1)^4} dx_1 \right) dx_2$ .
- Primeira abordagem: Integração por Monte Carlo. simular duas variáveis aleatórias, independente, Uniformes no intervalo  $[-1, 1]$  e calcular  $h \approx \frac{4}{m} \sum_{i=1}^m f(x_{i1}, x_{i2})$ .
- API: simular de duas variáveis aleatórias independentes normais truncadas no intervalo  $[-1, 1]$ .

$$g(x_1, x_2) \propto e^{-90(x_1-0,5)^2} e^{-10(x_2+0,1)^2}$$

# Comparação: API x MC

