

5.7 Erros e propagação de erros*

Qualquer medida obtida experimentalmente está sujeita a erro (diferença entre o valor medido e o valor "verdadeiro") que é impossível eliminar totalmente.

1) Classificação dos erros

(a) **Erros sistemáticos:** são erros independentes das leis do acaso e produzidos sempre no mesmo sentido.

(b) **Erros acidentais** ou fortuitos: estes erros são devidos a variações, ao acaso, de causas não conhecidas exactamente (em geral, "irregulares" e "pequenas") e podem ocorrer em qualquer sentido.

Nota: os dois tipos de erros podem ocorrer simultaneamente.

* Só para Probabilidades, Erros e Estatística

Embora possam ser estabelecidos majorantes para certos erros e calculado o erro máximo por acumulação dos erros parciais tal não deve ser feito, por conduzir a valores demasiado pessimistas. O procedimento mais correcto para avaliar este tipo de erros consiste na utilização de métodos estatísticos.

Admite-se que o erro acidental, associado a uma certa medição, é uma variável aleatória com determinada distribuição de probabilidades, sendo depois possível, através da observação de vários resultados experimentais, estimar os parâmetros dessa distribuição.

A prática mostra (e uma justificação teórica é fornecida pelo Teorema do Limite Central) que **os erros acidentais seguem geralmente distribuições normais**.


2) Precisão e exactidão

Considere-se um conjunto de medidas independentes, x_1, x_2, \dots, x_n , de uma mesma quantidade, efectuadas em condições idênticas (utilizando o mesmo método, nas mesmas circunstâncias).

A **precisão** do método de medida está relacionada com a concordância entre os vários valores experimentais obtidos: quanto mais próximos entre si estiverem (quanto menor for a sua dispersão) maior será a precisão do método. Para medir a precisão usa-se então um parâmetro de dispersão, geralmente o desvio padrão, σ , estimado por

$$s = \left[\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1} \right]^{1/2}, \text{ com } \bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

A **exactidão** do método traduz a concordância entre o valor médio dos valores experimentais (μ), estimado, em geral, pela média aritmética, \bar{x} , e o valor exacto ou verdadeiro, μ_0 . A exactidão está, portanto, relacionada com a existência, ou não, de erro sistemático. A $e = \mu_0 - \bar{x}$ chama-se erro simples e ao seu módulo erro absoluto.



Nos Capítulos 7 e 8 aprenderemos:

- a avaliar e controlar a precisão (intervalos de confiança para μ e σ a partir de \bar{x} e s ; determinação do número de observações que conduzem a um intervalo de confiança com dado comprimento);
- a comparar dois métodos tendo em conta as suas precisões (comparação de duas médias);
- a comparar as precisões de dois métodos (comparação de duas variâncias)¹;
- e a avaliar a exactidão de um método (comparação da média dos valores experimentais com um valor padrão, tido como verdadeiro).

¹ Apenas como curiosidade, não faz parte do programa.

3) Propagação dos erros acidentais

Considere-se uma grandeza, A , função de duas variáveis (grandezas) X e Y , ambas sujeitas a erros acidentais:

$$A = f(X, Y)$$

$$\text{e } E(X) = \mu_X, E(Y) = \mu_Y, V(X) = \sigma_X^2, V(Y) = \sigma_Y^2$$

(estes valores ou são conhecidos ou podem ser estimados)

A grandeza A terá uma distribuição de probabilidades que é, em geral, de difícil determinação.

O que vamos fazer é encontrar uma expressão aproximada para os parâmetros μ_A e σ_A , da distribuição de probabilidades de A .

Aproximação da função f dada pela fórmula de Taylor, com termos até à segunda ordem, em torno do ponto (μ_X, μ_Y) :

$$\begin{aligned} A = f(X, Y) \approx & f(\mu_X, \mu_Y) + \\ & + (X - \mu_X) \frac{\partial f}{\partial X} \Big|_{(\mu_X, \mu_Y)} + (Y - \mu_Y) \frac{\partial f}{\partial Y} \Big|_{(\mu_X, \mu_Y)} + \\ & + \frac{(X - \mu_X)^2}{2} \frac{\partial^2 f}{\partial X^2} \Big|_{(\mu_X, \mu_Y)} + \frac{(Y - \mu_Y)^2}{2} \frac{\partial^2 f}{\partial Y^2} \Big|_{(\mu_X, \mu_Y)} + \\ & + (X - \mu_X)(Y - \mu_Y) \frac{\partial^2 f}{\partial X \partial Y} \Big|_{(\mu_X, \mu_Y)} \end{aligned}$$

Tomando valores esperados em ambos os membros obtém-se

$$\begin{aligned} \mu_A = E(A) \approx & f(\mu_X, \mu_Y) + \frac{\sigma_X^2}{2} \frac{\partial^2 f}{\partial X^2} \Big|_{(\mu_X, \mu_Y)} + \\ & + \frac{\sigma_Y^2}{2} \frac{\partial^2 f}{\partial Y^2} \Big|_{(\mu_X, \mu_Y)} + \text{Cov}(X, Y) \frac{\partial^2 f}{\partial X \partial Y} \Big|_{(\mu_X, \mu_Y)} \end{aligned}$$

Notas:

- 1) Se as variáveis X e Y forem independentes (ou apenas não correlacionadas) a última parcela desaparece pois $\text{Cov}(X, Y) = 0$.
- 2) Pode obter-se uma aproximação mais grosseira tomando apenas os termos de primeira ordem $\mu_A \approx f(\mu_X, \mu_Y)$

Para obtenção da expressão aproximada da variância de A usam-se apenas os termos de 1ª ordem:

$$\begin{aligned} \sigma_A^2 = V(A) \approx & \sigma_X^2 \left(\frac{\partial f}{\partial X} \Big|_{(\mu_X, \mu_Y)} \right)^2 + \sigma_Y^2 \left(\frac{\partial f}{\partial Y} \Big|_{(\mu_X, \mu_Y)} \right)^2 + \\ & + 2\text{Cov}(X, Y) \frac{\partial f}{\partial X} \Big|_{(\mu_X, \mu_Y)} \cdot \frac{\partial f}{\partial Y} \Big|_{(\mu_X, \mu_Y)} \end{aligned}$$

As expressões obtidas podem generalizar-se para A função de várias variáveis

$$A = f(X_1, X_2, \dots, X_p).$$

Com $E(X_i) = \mu_i$, $V(X_i) = \sigma_i^2$ ($i = 1, \dots, p$) e $\text{Cov}(X_i, X_j) = \sigma_{ij}$ ($i, j = 1, \dots, p; i \neq j$), obtém-se então

$$\mu_A \approx f(\mu_1, \mu_2, \dots, \mu_p)$$

e

$$\sigma_A^2 \approx \sum_{i=1}^p \sigma_i^2 \left(\frac{\partial f}{\partial X_i} \Big|_{(\mu_1, \dots, \mu_p)} \right)^2 + 2 \sum_{i=1}^p \sum_{j=1}^{i-1} \sigma_{ij} \left(\frac{\partial f}{\partial X_i} \Big|_{(\mu_1, \dots, \mu_p)} \cdot \frac{\partial f}{\partial X_j} \Big|_{(\mu_1, \dots, \mu_p)} \right)$$

(a última parcela desaparece se as variáveis X_1, X_2, \dots, X_p forem não correlacionadas duas a duas ou se forem independentes duas a duas).

Nota: Se a função f for linear então as expressões anteriores são exactas e coincidem com as obtidas na secção 5.4 (combinações lineares de variáveis aleatórias).

Exemplo 1: Seja $A = f(X, Y) = X/Y$,

$$E(X) = \mu_X \quad E(Y) = \mu_Y \neq 0 \quad V(X) = \sigma_X^2$$

$$V(Y) = \sigma_Y^2 \quad \text{Cov}(X, Y) = \sigma_{X,Y}$$

$$\frac{\partial f}{\partial X} \Big|_{(\mu_X, \mu_Y)} = \frac{1}{Y} \Big|_{(\mu_X, \mu_Y)} = \frac{1}{\mu_Y} \quad \frac{\partial^2 f}{\partial X^2} \Big|_{(\mu_X, \mu_Y)} = 0$$

$$\frac{\partial f}{\partial Y} \Big|_{(\mu_X, \mu_Y)} = -\frac{X}{Y^2} \Big|_{(\mu_X, \mu_Y)} = -\frac{\mu_X}{\mu_Y^2}$$

$$\frac{\partial^2 f}{\partial Y^2} \Big|_{(\mu_X, \mu_Y)} = \frac{2X}{Y^3} \Big|_{(\mu_X, \mu_Y)} = \frac{2\mu_X}{\mu_Y^3}$$

$$\frac{\partial^2 f}{\partial X \partial Y} \Big|_{(\mu_X, \mu_Y)} = -\frac{1}{Y^2} \Big|_{(\mu_X, \mu_Y)} = -\frac{1}{\mu_Y^2}$$

donde

$$\mu_A \approx E\left(\frac{X}{Y}\right) \approx \frac{\mu_X}{\mu_Y} + \frac{\sigma_Y^2 \mu_X}{\mu_Y^3} - \frac{\sigma_{X,Y}}{\mu_Y^2}$$

e

$$\sigma_A^2 \approx V\left(\frac{X}{Y}\right) \approx \frac{\sigma_X^2}{\mu_Y^2} + \sigma_Y^2 \left(-\frac{\mu_X}{\mu_Y^2}\right)^2 - 2 \frac{\sigma_{X,Y} \cdot \mu_X}{\mu_Y^3} = \left(\frac{\mu_X}{\mu_Y}\right)^2 \left(\frac{\sigma_X^2}{\mu_X^2} + \frac{\sigma_Y^2}{\mu_Y^2} - 2 \frac{\sigma_{X,Y}}{\mu_X \mu_Y}\right) \quad (\text{se } \mu_X \neq 0)$$

Exemplo 2: Na determinação da concentração de uma certa solução por titulação usa-se a expressão

$$C' = \frac{K \cdot \bar{V}}{V}$$

$K = 0.4271$ é uma constante não aleatória

\bar{V} e V são variáveis aleatórias independentes com

$$\mu_{\bar{V}} = 12.4, \quad \mu_V = 10.0, \quad \sigma_{\bar{V}} = 0.12 \quad \text{e} \quad \sigma_V = 0.04$$

(Numa situação real estes valores serão estimativas calculadas a partir dos valores experimentais.)

Aplicando as expressões deduzidas no Ex. 1:

$$\begin{aligned} \mu_{C'} &\approx 0.4271 \left(\frac{12.4}{10} + \frac{0.04^2 \times 12.4}{10^3} \right) \approx \\ &\approx 0.4271 \times \frac{12.4}{10} = 0.5296 \end{aligned}$$

$$\begin{aligned}\sigma_{C'}^2 &\approx 0.4271^2 \left(\frac{12.4}{10} \right)^2 \left(\frac{0.12^2}{12.4^2} + \frac{0.04^2}{10^2} \right) = \\ &= 3.0755 \times 10^{-5} \\ \sigma_{C'} &\approx 5.5 \times 10^{-3}\end{aligned}$$

Exemplo 3: (Problema de calibração) Sabe-se que entre as variáveis X e Y existe a relação $Y = B_0 + B_1X$, onde B_0 e B_1 também são variáveis aleatórias. Quando se quer determinar X a partir de Y usa-se

$$X = \frac{Y - B_0}{B_1}.$$

Admitindo que:

- $E(B_0) = \beta_0$, $E(B_1) = \beta_1$, $V(B_0) = \sigma_0^2$,
- $V(B_1) = \sigma_1^2$, $\text{Cov}(B_0, B_1) = \sigma_{01}$,
- Y é independente de B_0 e B_1 ,
- $E(Y - B_0) = \beta_1 E(X)$, $V(Y) = \sigma^2$

e aplicando a expressão para a variância (do Ex. 1)

$$\begin{aligned}\sigma_X^2 &\approx \left[\frac{E(Y - B_0)}{E(B_1)} \right]^2 \left[\frac{V(Y - B_0)}{E(Y - B_0)^2} + \frac{V(B_1)}{E(B_1)^2} - \right. \\ &\quad \left. - \frac{2\text{Cov}(Y - B_0, B_1)}{E(Y - B_0)E(B_1)} \right] = \\ &= \left[\frac{\beta_1 E(X)}{\beta_1} \right]^2 \left[\frac{\sigma^2 + \sigma_0^2}{\beta_1^2 E(X)^2} + \frac{\sigma_1^2}{\beta_1^2} + \frac{2\sigma_{01}}{\beta_1^2 E(X)} \right] = \\ &= \frac{1}{\beta_1^2} \left[\sigma^2 + \sigma_0^2 + \sigma_1^2 E(X)^2 + 2\sigma_{01} E(X) \right]\end{aligned}$$