

PROPAGACIÓN DE VARIANZAS Y COVARIANZAS

PROPAGACIÓN DE INCERTIDUMBRES

Introducción

Por lo gral. los modelos con los cuales estudiamos la realidad no son tan sencillos y tan simples que se puedan definir con un solo mensurando, sino que partiendo de varias variables medidas debemos inferir o calcular otras más complejas.

En estos casos nos interesará conocer a partir de las incertidumbres o errores con las cuales medimos las variables originales, los efectos que tengan sobre las resultantes. A este proceso se le llama propagación.

Ejemplos:

- 1) Medimos ángulos y distancias → calculamos coordenadas.
- 2) Medimos coordenadas → calculamos superficies y deslindes.
- 3) Medimos niveles → calculamos desniveles y cotas.

Propagación de Errores Sistemáticos

Como ya vimos al realizar una observación el error de medida tiene dos componentes, el error sistemático y el error aleatorio.

Los errores sistemáticos los podemos eliminar directamente de nuestras observaciones mediante correcciones o podemos estudiar el efecto de su propagación.

X → variable independiente con errores dx sistemáticos.

Y → variable dependiente con error dy (el que se quiere hallar).

CASO LINEAL

$$Y = A \cdot X + B \rightarrow Y + dy = A \cdot (X + dx) + B$$

$$Y + dy = A \cdot X + A \cdot dx + B \rightarrow dy = A \cdot dx$$

CASO NO LINEAL

$$Y = f(X)$$

Linealizamos por Taylor

$$Y = Y_0 + \left(\frac{\partial f}{\partial X}\right) X - \left(\frac{\partial f}{\partial X}\right) X_0$$

$$Y = \left(\frac{\partial f}{\partial X}\right) X + \left(Y_0 - \left(\frac{\partial f}{\partial X}\right) X_0\right) \rightarrow Y = AX + B \rightarrow$$

\downarrow \downarrow
 A B

→Aplicando el caso lineal → $dy = \left(\frac{\partial f}{\partial X}\right) dx$


Generalización: $X = (X_1, X_2, \dots, X_n)$

1) Caso lineal → $Y = AX_1 + BX_2 + \dots$
 $dy = Adx_1 + Bdx_2 + \dots$

2) Caso no lineal → $Y = f(X_1, X_2, \dots, X_n)$
 $dy = \left(\frac{\partial f}{\partial X_1}\right) dx_1 + \left(\frac{\partial f}{\partial X_2}\right) dx_2 + \dots$

Ejemplo:

Se mide con una cinta de 30 m los lados de una figura rectangular.



Posteriormente se contrasta la cinta y se encuentra que la misma es 0,03 m más corta.
Calcularemos el error en el área calculada debido al error sistemático en la medida con la cinta.

30 m 0,03
50,170 m $dX_1 = 0,050$ $\frac{\partial Y}{\partial X_1} = X_2$

30 m 0,03
61,090 m $dX_2 = 0,061$ $\frac{\partial Y}{\partial X_2} = X_1$

$$dy = \left(\frac{\partial Y}{\partial X_1}\right) dx_1 + \left(\frac{\partial Y}{\partial X_2}\right) dx_2 = 6,1m^2$$


$$\text{Area Corregida} = X_1 \times X_2 - 6,1 = 3058,785 \text{ m}^2$$

Propagación de Varianzas y Covarianzas

Cuando tratamos con errores aleatorios, el valor específico no lo conocemos y es imposible aplicar la técnica de propagación vista anteriormente. Pero es posible estudiar los efectos de su propagación.

Consideremos dos vectores X e Y, donde X representa un conjunto de mediciones e Y representa al conjunto de cantidades calculadas.

Ejemplo: Observamos la distancia d, el azimut α



$$x_p = d \cdot \text{sen} \alpha$$

$$y_p = d \cdot \text{cos} \alpha$$

$$\Rightarrow Y = \begin{pmatrix} x \\ y \end{pmatrix} \text{ y } X = \begin{pmatrix} d \\ \alpha \end{pmatrix}$$

El problema consiste en buscar la distribución del vector Y, conociendo la distribución del vector X.

Desarrollaremos primero la propagación suponiendo un vector aleatorio X compuesto por dos variables conjuntamente distribuidas x_1 y x_2 que tienen el mismo modelo aleatorio. Y un vector aleatorio Y compuesto por dos variables y_1 e y_2 .

CASO LINEAL

Supongamos que se relacionan:

$$Y = AX + B \text{ (Relación lineal)}$$

En donde:

$$Y = \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}, X = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

$$B = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} \quad A = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \text{ con A y B matrices numéricas.}$$

Nuestro objetivo será calcular $\sigma_{y_1}^2$, $\sigma_{y_2}^2$ y $\sigma_{y_1 y_2}^2$, conociendo $\sigma_{x_1}^2$, $\sigma_{x_2}^2$, $\sigma_{x_1 x_2}^2$ y cómo se relacionan

$$Y = AX + B.$$

$$\Rightarrow \begin{cases} Y_1 = a_{11} \cdot x_1 + a_{12} \cdot x_2 + b_1 \\ Y_2 = a_{21} \cdot x_1 + a_{22} \cdot x_2 + b_2 \end{cases}$$

Recordemos: $\sigma_x^2 = E(x^2) - (E(x))^2$

$$\sigma_{y_1}^2 = E((a_{11} \cdot x_1 + a_{12} \cdot x_2 + b_1)^2) - [E(a_{11} \cdot x_1 + a_{12} \cdot x_2 + b_1)]^2$$

$$\sigma_{y_1}^2 = E(a_{11}^2 \cdot x_1^2 + a_{12}^2 \cdot x_2^2 + 2a_{11} \cdot a_{12} \cdot x_1 \cdot x_2 + \dots + b_1^2) - [a_{11}E(x_1) + a_{12}E(x_2) + b_1]^2$$

$$\sigma_{y_1}^2 = a_{11}^2 [E(x_1^2) - E(x_1)^2] + a_{12}^2 \cdot E(x_2^2) + 2a_{11} \cdot a_{12} \cdot E(x_1 \cdot x_2) + \dots + b_1^2 - [a_{11}^2 + a_{12}^2 \cdot E(x_2)^2 + 2a_{11} \cdot a_{12} \cdot E(x_1) \cdot E(x_2) + \dots + b_1^2]$$

$$\sigma_{y_1}^2 = a_{11}^2 \sigma_{x_1}^2 + a_{12}^2 \sigma_{x_2}^2 + 2a_{11} \cdot a_{12} \sigma_{x_1 x_2}$$

$$\sigma_{y_2}^2 = a_{21}^2 \sigma_{x_1}^2 + a_{22}^2 \sigma_{x_2}^2 + 2a_{21} \cdot a_{22} \sigma_{x_1 x_2}$$

$$\sigma_{y_1 y_2} = E[(Y_1 - E(Y_1))(Y_2 - E(Y_2))]$$

$$Y_1 - E(Y_1) = a_{11}x_1 + a_{12}x_2 + b_1 - a_{11}E(x_1) - a_{12}E(x_2) - b_1 = a_{11}(x_1 - E(x_1)) + a_{12}(x_2 - E(x_2))$$

$$Y_1 - E(Y_1) = a_{11}(x_1 - E(x_1)) + a_{12}(x_2 - E(x_2))$$

$$Y_2 - E(Y_2) = a_{21}(x_1 - E(x_1)) + a_{22}(x_2 - E(x_2))$$

$$\sigma_{Y_1Y_2} = E \left[\left(a_{11}(x_1 - E(x_1)) + a_{12}(x_2 - E(x_2)) \right) \cdot \left(a_{21}(x_1 - E(x_1)) + a_{22}(x_2 - E(x_2)) \right) \right]$$

$$\sigma_{Y_1Y_2} = E \left[a_{11}a_{21}(x_1 - E(x_1))^2 + a_{12}a_{21}(x_1 - E(x_1))(x_2 - E(x_2)) + a_{11}a_{22}(x_1 - E(x_1))(x_2 - E(x_2)) + a_{12}a_{22}(x_2 - E(x_2))^2 \right]$$

$$\sigma_{Y_1Y_2} = a_{11}a_{21}E \left[(x_1 - E(x_1))^2 \right] + (a_{12}a_{21} + a_{11}a_{22})E \left[(x_1 - E(x_1))(x_2 - E(x_2)) \right] + a_{12}a_{22}E \left[(x_2 - E(x_2))^2 \right]$$

$$\sigma_{Y_1Y_2} = a_{11}a_{21}\sigma_{X_1}^2 + (a_{12}a_{21} + a_{11}a_{22})\sigma_{X_1X_2} + a_{12}a_{22}\sigma_{X_2}^2$$

Lo anterior lo podemos expresar en forma matricial de la siguiente manera:

Definimos: $\Sigma_{XX} = \begin{bmatrix} \sigma_{X_1}^2 & \sigma_{X_1X_2} \\ \sigma_{X_1X_2} & \sigma_{X_2}^2 \end{bmatrix}$ y $\Sigma_{YY} = \begin{bmatrix} \sigma_{Y_1}^2 & \sigma_{Y_1Y_2} \\ \sigma_{Y_1Y_2} & \sigma_{Y_2}^2 \end{bmatrix}$ **Matrices Covarianzas**

$$\Rightarrow \Sigma_{YY} = A \cdot \Sigma_{XX} \cdot A^T$$

Podemos generalizar lo anterior:

Considerando: $X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ \vdots \\ x_n \end{bmatrix}$

n variables aleatorias de las cuales conocemos: $\sigma_{X_1}^2, \sigma_{X_2}^2, \dots, \sigma_{X_n}^2, \sigma_{X_1X_2}, \sigma_{X_1X_3}, \dots$

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix} A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix} B = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{bmatrix}$$

$$Y = AX + B$$

$$\Sigma_{YY} = \begin{bmatrix} \sigma_{Y_1}^2 & \sigma_{Y_1Y_2} & \dots & \sigma_{Y_1Y_n} \\ \sigma_{Y_1Y_2} & \sigma_{Y_2}^2 & \dots & \sigma_{Y_2Y_n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{Y_mY_1} & \sigma_{Y_mY_2} & \dots & \sigma_{Y_m}^2 \end{bmatrix} \Sigma_{XX} = \begin{bmatrix} \sigma_{X_1}^2 & \sigma_{X_1X_2} & \dots & \sigma_{X_1Y_n} \\ \sigma_{X_1X_2} & \sigma_{X_2}^2 & \dots & \sigma_{X_2Y_n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{X_mX_1} & \sigma_{X_mX_2} & \dots & \sigma_{X_m}^2 \end{bmatrix}$$

$$\Sigma_{YY} = A \Sigma_{XX} A^T \text{ **Ley de Propagación de Varianzas y Covarianzas para el CASO LINEAL**}$$

CASO NO LINEAL

Cuando la relación entre X e Y no es lineal: $Y = f(x)$ se pueden linealizar las relaciones usando Desarrollos de Taylor:

$$\begin{cases} Y_1 = f_1(x_1, x_2, \dots, x_n) \\ Y_2 = f_2(x_1, x_2, \dots, x_n) \\ \vdots \\ Y_m = f_m(x_1, x_2, \dots, x_n) \end{cases}$$

$$Y_i = Y_{i0} + \sum \left(\frac{\partial f_i}{\partial x_i} \right)_{x_0} \Delta x_i$$

con: $Y_{i0} = f_i(x_{10}, x_{20}, \dots, x_{n0})$ y f evaluada en $X_0 = (x_{10}, x_{20}, \dots, x_{n0})$

$$\Delta X_i = x_i - x_{i0}$$

$$Y_i = \sum \left(\frac{\partial f_i}{\partial x_i} \right)_{x_0} \cdot x_i + \left[Y_{i0} - \sum \left(\frac{\partial f_i}{\partial x_i} \right)_{x_0} \cdot x_{i0} \right] \text{ Lineal en } x_i$$

$$Y = AX + B$$

Si para cada relación hacemos lo mismo:

$$A = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \dots & \frac{\partial f_1}{\partial x_n} \\ \vdots & \ddots & \vdots & \vdots \\ \frac{\partial f_m}{\partial x_1} & \frac{\partial f_m}{\partial x_2} & \vdots & \frac{\partial f_m}{\partial x_n} \end{bmatrix} = J_{YX} \text{ (jacobiano)}$$

Ley GENERAL de Propagación de Varianzas y Covarianzas $\Sigma_{YY} = J_{YX} \Sigma_{XX} J_{YX}^T$

En caso que x_1, x_2, \dots, x_n sean independientes, $\sigma_{x_i x_j} = 0$

$$\Sigma_{XX} = \begin{bmatrix} \sigma_{X1}^2 & 0 & \dots & 0 \\ 0 & \sigma_{X2}^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_{Xn}^2 \end{bmatrix} = \text{Matriz Varianza}$$

$$\text{Si } Y = a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n \Rightarrow \sigma_Y^2 = a_{11}^2 \sigma_{x1}^2 + a_{12}^2 \sigma_{x2}^2 + \dots + a_{1n}^2 \sigma_{xn}^2$$

$$\text{Si } Y = f(x_1, x_2, \dots, x_n) \Rightarrow \sigma_Y^2 = \left(\frac{\partial f}{\partial x_1} \right)^2 \sigma_{x1}^2 + \left(\frac{\partial f}{\partial x_2} \right)^2 \sigma_{x2}^2 + \dots + \left(\frac{\partial f}{\partial x_n} \right)^2 \sigma_{xn}^2$$

Ejemplo Propagación:

X_1, X_2 y X_3 son mediciones independientes con: $\sigma_{X_1} = 2.0\text{cm}$, $\sigma_{X_2} = 4.0\text{cm}$, $\sigma_{X_3} = 2.0\text{cm}$. Las variables Y_1, Y_2, Z_1 y Z_2 pueden ser calculadas a partir de X_1, X_2 y X_3 de la siguiente manera:

$$\begin{cases} Y_1 = X_1 + X_2 + 2X_3 \\ Y_2 = X_1 - 2X_2 \end{cases} \quad \text{y} \quad \begin{cases} Z_1 = 0.5Y_1 - Y_2 \\ Z_2 = Y_1 + 0.5Y_2 \end{cases}$$

Calcular las matrices covarianzas de $Y = \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix}$ y de $Z = \begin{bmatrix} Z_1 \\ Z_2 \end{bmatrix}$

$$X = \begin{bmatrix} X_1 \\ X_2 \\ X_3 \end{bmatrix} \quad A = \begin{bmatrix} 1 & 1 & 2 \\ 1 & -2 & 0 \end{bmatrix} \Rightarrow Y = A.X$$

$$\Sigma_{YY} = \begin{bmatrix} 1 & 1 & 2 \\ 1 & -2 & 0 \end{bmatrix} \cdot \begin{bmatrix} \sigma_{x_1}^2 & 0 & 0 \\ 0 & \sigma_{x_2}^2 & 0 \\ 0 & 0 & \sigma_{x_3}^2 \end{bmatrix} \cdot \begin{bmatrix} 1 & 1 \\ 1 & -2 \\ 2 & 0 \end{bmatrix} = \begin{bmatrix} \sigma_{x_1}^2 + \sigma_{x_2}^2 + 4\sigma_{x_3}^2 & \sigma_{x_1}^2 - 2\sigma_{x_2}^2 \\ \sigma_{x_1}^2 - 2\sigma_{x_2}^2 & \sigma_{x_1}^2 + 4\sigma_{x_2}^2 \end{bmatrix}$$

$$\Rightarrow \Sigma_{YY} = \begin{bmatrix} \sigma_{Y_1}^2 & \sigma_{Y_1Y_2} \\ \sigma_{Y_1Y_2} & \sigma_{Y_2}^2 \end{bmatrix} = \begin{bmatrix} 36 & -28 \\ -28 & 68 \end{bmatrix}_{(\text{cm}^2)}$$

$$X = \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} \quad A = \begin{bmatrix} 1/2 & -1 \\ 1 & 1/2 \end{bmatrix} \Rightarrow Y = A.X$$

$$\Sigma_{YY} = \begin{bmatrix} 1/2 & -1 \\ 1 & 1/2 \end{bmatrix} \begin{bmatrix} \sigma_{Y_1}^2 & \sigma_{Y_1Y_2} \\ \sigma_{Y_1Y_2} & \sigma_{Y_2}^2 \end{bmatrix} \begin{bmatrix} 1/2 & 1 \\ -1 & 1/2 \end{bmatrix}$$

$$\Sigma_{YY} = \begin{bmatrix} (1/4)\sigma_{Y_1}^2 - (1/2)\sigma_{Y_1Y_2} - (1/2)\sigma_{Y_1Y_2} + \sigma_{Y_2}^2 & (1/2)\sigma_{Y_1}^2 + (1/4)\sigma_{Y_1Y_2} - \sigma_{Y_1Y_2} - (1/2)\sigma_{Y_2}^2 \\ (1/2)\sigma_{Y_1}^2 - \sigma_{Y_1Y_2} + (1/4)\sigma_{Y_1Y_2} - (1/2)\sigma_{Y_2}^2 & \sigma_{Y_1}^2 + (1/2)\sigma_{Y_1Y_2} + (1/2)\sigma_{Y_1Y_2} + (1/4)\sigma_{Y_2}^2 \end{bmatrix}$$

$$\Sigma_{YY} = \begin{bmatrix} 105 & 5 \\ 5 & 25 \end{bmatrix}$$