

## LEY DE PROPAGACIÓN DE COFACTORES

### 3er COMPONENTE DE LA OPTIMIZACION

- 1- Funcion MMCC
- 2- Ecs Condicion
- 3- Precisiones Fins mejores que Inics

$$\Sigma_{XX} = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{12} & \sigma_2^2 & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1n} & \cdots & \cdots & \sigma_n^2 \end{bmatrix}$$

Matriz COVARIANZA

$$\Sigma_{XX} = \begin{bmatrix} \sigma_1^2 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \cdots & \cdots & \sigma_n^2 \end{bmatrix}$$

Matriz VARIANZA (cuando no hay correlaciones)

$$\underbrace{Q_{XX}}_{\substack{\text{Matriz} \\ \text{Cofactor}}} = W^{-1} = \frac{1}{\sigma_0^2} \Sigma_{XX} = \begin{bmatrix} \frac{\sigma_1^2}{\sigma_0^2} & \cdots & \cdots & \cdots \\ \vdots & \frac{\sigma_2^2}{\sigma_0^2} & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \cdots & \cdots & \frac{\sigma_n^2}{\sigma_0^2} \end{bmatrix} = \begin{bmatrix} \frac{1}{\omega_1} & \cdots & \cdots & \cdots \\ \vdots & \frac{1}{\omega_2} & \vdots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \vdots & \cdots & \cdots & \frac{1}{\omega_n} \end{bmatrix}$$

Matriz COFACTOR →

→  $\Sigma_{XX} = \sigma_0^2 Q_{XX}$  Relaciones de Matrices:  $W \quad Q \quad \Sigma_{XX}$

De Teoría de errores 1, Propagación de la matriz varianza y covarianza:

Para funciones lineales  $y=ax+b \Rightarrow \Sigma_{YY} = A \Sigma_{XX} A^T$

Para funciones no lineales  $y=f(x) \Rightarrow \Sigma_{YY} = J_{YX} \Sigma_{XX} J_{YX}^T$

Sabemos que:

$$\Sigma_{XX} = \sigma_0^2 \cdot Q_{XX} \quad \text{para variables } X$$

$$\Sigma_{YY} = \sigma_0^2 \cdot Q_{YY} \quad \text{para variables } Y$$

Sustituyendo:

•  $\Sigma_{YY} = A \cdot \sigma_0^2 \cdot Q_{XX} \cdot A^T \div \sigma_0^2 \Rightarrow Q_{YY} = A Q_{XX} A^T$  •

LEY DE APLICACIÓN

•  $\Sigma_{YY} = J_{YX} \cdot \sigma_0^2 \cdot Q_{XX} \cdot J_{YX}^T \div \sigma_0^2 \Rightarrow Q_{YY} = J_{YX} Q_{XX} J_{YX}^T$  •

DE COFACTORES

**APLICACIÓN:**

*Demostración de que el peso de la Media Ponderada es igual a la suma de los pesos.*

$$\bar{X} = \frac{\omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n}{\omega_1 + \omega_2 + \dots + \omega_n} \quad \text{Media ponderada}$$

En notación matricial:

$$\bar{X}W = \left[ \frac{\omega_1}{\Sigma\omega}, \frac{\omega_2}{\Sigma\omega}, \dots, \frac{\omega_n}{\Sigma\omega} \right] \cdot \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} + 0$$

Es una formulación del tipo  $Y = A * X$  (función lineal)  $\Rightarrow$

$$Q_{XX} = W^{-1} = \begin{bmatrix} \frac{1}{\omega_1} & 0 & \dots & 0 \\ 0 & \frac{1}{\omega_2} & \dots & \vdots \\ \vdots & \dots & \ddots & 0 \\ 0 & \dots & 0 & \frac{1}{\omega_n} \end{bmatrix} \quad \text{Entonces:}$$

$$Q_{YY} = A Q_{XX} A^T$$

$$Q_{YY} = \left[ \frac{\omega_1}{\Sigma\omega}, \frac{\omega_2}{\Sigma\omega}, \dots, \frac{\omega_n}{\Sigma\omega} \right] \cdot \begin{bmatrix} \frac{1}{\omega_1} & 0 & \dots & 0 \\ 0 & \frac{1}{\omega_2} & \dots & \vdots \\ \vdots & \dots & \ddots & 0 \\ 0 & \dots & 0 & \frac{1}{\omega_n} \end{bmatrix} \cdot \begin{bmatrix} \frac{\omega_1}{\Sigma\omega} \\ \frac{\omega_2}{\Sigma\omega} \\ \vdots \\ \frac{\omega_n}{\Sigma\omega} \end{bmatrix} = \left[ \frac{\omega_1}{\Sigma\omega}, \frac{\omega_2}{\Sigma\omega}, \dots, \frac{\omega_n}{\Sigma\omega} \right] \cdot \begin{bmatrix} \frac{1}{\Sigma\omega} \\ \frac{1}{\Sigma\omega} \\ \vdots \\ \frac{1}{\Sigma\omega} \end{bmatrix}$$

$$Q_{YY} = \frac{\omega_1 + \omega_2 + \dots + \omega_n}{(\Sigma\omega)^2} = \frac{1}{\Sigma\omega}$$

$$Q_{YY} = W_{YY}^{-1} \Rightarrow \boxed{W = \Sigma\omega}$$

## PROPAGACIÓN DE COFACTORES PARA AMC + M

**Ecuaciones de condición**  $\rightarrow v + B\Delta = f$

con  $f = d - l$  donde  $d =$  datos numéricos  
 $l =$  observaciones.

**Trabajaremos con funciones lineales:**

Matriz cofactor asociada a las observaciones  $\rightarrow Q_{ll} = Q = W^{-1}$  pues simplifica la notación.

### ● Algoritmo AMC+M:

$$\begin{aligned} N &= B^T W B \\ t &= B^T W f \\ \Delta &= N^{-1} t \\ v &= f - B \Delta \\ \bar{l} &= l + v \end{aligned}$$

Esta es la nueva Varianza Referencial producto del Ajuste  $\hat{\sigma}_0^2 = \frac{v^t W v}{r}$ , y que deberá ser aplicada en las propagaciones, y no la  $\sigma_0^2$  anterior "a priori" que sirvió para calcular pesos o relaciones relativas entre observaciones.

Se verá con detalle este Estimador en una próxima clase.

$$f = (-I)l + d \rightarrow Q_{ff} = (-I)Q_{ll}(-I)^T = Q \rightarrow \boxed{Q_{ff} = Q} \quad \bullet$$

$$Q_{tt} = (B^T W) Q_{ff} (B^T W)^T = B^T W Q W^T (B^T)^T = B^T \underbrace{W Q W^T}_{I} B = B^T W B = N$$

$$\rightarrow \boxed{Q_{tt} = N} \quad \bullet$$

Pasamos a desarrollar ahora  $Q_{\Delta\Delta} \rightarrow \bullet$

$$Q_{\Delta\Delta} = (N^{-1}) \cdot \underbrace{Q_{tt}}_N \cdot (N^{-1})^T = N^{-1} \cdot \underbrace{N}_N \cdot (N^{-1})^T = \underbrace{N^{-1} \cdot N \cdot N^{-1}}_I = N^{-1} \rightarrow \boxed{\Sigma_{\Delta\Delta} = \sigma_0^2 \cdot Q_{\Delta\Delta}} \quad \bullet$$

$$N^T = (B^T W B)^T = (W B)^T (B^T)^T = \boxed{B^T W B = N}$$

$$\bullet \boxed{Q_{\Delta\Delta} = N^{-1}} \quad \bullet$$

•  $\Sigma_{\Delta\Delta} = \sigma_0^2 Q_{\Delta\Delta}$  •

•  $v = f - BW^{-1}t = f - BN^{-1}B^T Wf \rightarrow v = (I - BN^{-1}B^T W)f \Rightarrow$

•  $Q_{vv} = (I - BN^{-1}B^T \cdot W) \underbrace{Q_{ff}}_Q (I - BN^{-1}B^T W)^T =$

$(IQ - BN^{-1}B^T WQ)(I^T - (BN^{-1}B^T W)^T) \Rightarrow$

$(B^T W)^T (BN^{-1})^T = WB(N^{-1})^T B^T = WBN^{-1}B^T$

$$\begin{aligned} Q_{vv} &= (IQ - BN^{-1}B^T WQ)(I - WBN^{-1}B^T) = \\ &= \underbrace{I \cdot Q \cdot I}_Q - \underbrace{B \cdot N^{-1} \cdot B^T \cdot W \cdot Q \cdot I}_{B \cdot N^{-1} \cdot B^T} - \underbrace{I \cdot Q \cdot W \cdot B \cdot N^{-1} \cdot B^T}_{B \cdot N^{-1} \cdot B^T} \\ &\quad + \underbrace{B \cdot N^{-1} \cdot B^T \cdot W \cdot Q \cdot W \cdot B \cdot N^{-1} \cdot B^T}_{\underbrace{I}_{N}_{I}}_{B \cdot N^{-1} \cdot B^T} \end{aligned}$$

$= Q - BN^{-1}B^T - BN^{-1}B^T + BN^{-1}B^T \rightarrow Q_{vv} = Q - BN^{-1}B^T$  •

•  $\Rightarrow \Sigma_{vv} = \sigma_0^2 Q_{vv}$  •

1

Si trabajamos con  $\bar{l}$  ajustada  $\Rightarrow B\Delta = d - \bar{l} \Rightarrow \bar{l} = -B\Delta + d$  (tipo  $(y=ax+b)$ )

$Q_{\bar{l}\bar{l}} = (-B) \underbrace{Q_{\Delta\Delta}}_{N^{-1}} (-B)^T = BN^{-1}B^T \Rightarrow Q_{\bar{l}\bar{l}} = BN^{-1}B^T \Rightarrow \Sigma_{\bar{l}\bar{l}} = \sigma_0^2 Q_{\bar{l}\bar{l}}$  •

2

Por 1 y 2  $\Rightarrow Q_{\bar{l}\bar{l}} = Q - Q_{vv}$  •

Las varianzas de las observaciones ajustadas son menores que las de las observaciones realizadas. OPTIMIZACION FINALIZADA

Con la propagación de cofactores del AMC+M de las magnitudes, podemos calcular las  $\sigma^2$  o  $\sigma$  de las magnitudes ajustadas, de las observaciones ajustadas y de los residuales de cada observación.

Otra forma de llegar a lo mismo pero más desarrollada es:

**ANEXO:**

$$v = -B\Delta + f \rightarrow v = -B(N^{-1} \cdot t) + f = -B(N^{-1})(B^+ w f) + f =$$

$$\rightarrow v = (I - BN^{-1}B^+) f \quad \checkmark$$

$$\hat{\ell} = \ell + v \rightarrow \hat{\ell} = \ell + (f - B\Delta) = -B\Delta + (\ell + f) = -B\Delta + d \quad \checkmark$$

$$Q_{ff} = (B^+ w) Q_{ff} (B^+ w)^+ = B^+ w Q w^+ (B^+)^+ = B^+ w Q w B = B^+ w B = N$$

$$\rightarrow Q_{ff} = N \quad \checkmark$$

$$Q_{\Delta\Delta} = N^{-1} Q_{ff} (N^{-1})^+ = N^{-1} \cdot N (N^{-1})^+ = (N^{-1})^+ = (N^+)^- = N^{-1} \text{ por ser simétrica}$$

$$\text{dem: } N = N^+ \rightarrow (B^+ w B)^+ = B^+ w^+ (B^+)^+ = B^+ w B \quad \checkmark$$

$$\rightarrow Q_{\Delta\Delta} = N^{-1} \quad \checkmark$$

$$Q_{vv} \neq * = (I - BN^{-1}B^+) \cdot Q_{ff} \cdot (I - BN^{-1}B^+)^+ =$$

$$= (I - BN^{-1}B^+) \cdot Q \cdot [I^+ - (BN^{-1}B^+)^+] =$$

$$= (I - BN^{-1}B^+) \cdot Q \cdot (I - w^+ (B^+)^+ (N^{-1})^+ B^+) =$$

$$= (I - BN^{-1}B^+) \cdot Q \cdot (I - w B N^{-1} B^+) =$$

$$= (I Q - BN^{-1} B^+ w Q) (I - w B N^{-1} B^+) =$$

$$= I Q I - \underbrace{BN^{-1} B^+ w Q I}_{I} - \underbrace{I Q w B N^{-1} B^+}_{I} + \underbrace{BN^{-1} B^+ w Q w B N^{-1} B^+}_{I} =$$

$$= Q - 2BN^{-1}B^+ + BN^{-1}B^+$$

$$= Q - BN^{-1}B^+$$

$$\rightarrow Q_{vv} = Q - BN^{-1}B^+ \quad \checkmark$$

$$\rightarrow Q_{\hat{\ell}\hat{\ell}} = (-B) Q_{\Delta\Delta} (-B)^+ = BN^{-1}B^+ \quad \checkmark \rightarrow \text{por ser } \hat{\ell} = -B\Delta + d \text{ (ext+b)}$$

$$Q_{\hat{\ell}\hat{\ell}} = Q - Q_{vv} \leftrightarrow Q_{vv} = Q - Q_{\hat{\ell}\hat{\ell}} \quad \checkmark$$

## APLICACIONES ALGORITMO Y PROPAGACION AMMC + M

$$N = B^T W B$$

$$t = B^T W f$$

$$\Delta = N^{-1} t$$

$$v = f - B \Delta$$

$$\bar{l} = l + v$$

$$Q = W^{-1}$$

$$Q_{\Delta\Delta} = N^{-1} \Rightarrow \Sigma_{\Delta\Delta} = \sigma_0^2 Q_{\Delta\Delta}$$

$$Q_{vv} = Q - B N^{-1} B^T \Rightarrow \Sigma_{vv} = \sigma_0^2 Q_{vv}$$

$$Q_{\bar{l}\bar{l}} = B N^{-1} B^T \Rightarrow \Sigma_{\bar{l}\bar{l}} = \sigma_0^2 Q_{\bar{l}\bar{l}}$$

$$\sigma_0^2 = \frac{\mathbf{v}^t W \mathbf{v}}{r}$$

*Ej. de la recta: se desea determinar  $y = ax + b$ .*

*Se realizan 3 observaciones de la coordenada y. La x se conoce sin error.*

Consider the data for Examples 3-5 and 4-1 in which a straight line with the equation  $y = ax + b$  is fitted to three points:  $x_1 = 2, y_1 = 3.2$ ;  $x_2 = 4, y_2 = 4.0$ ;  $x_3 = 6, y_3 = 5.0$ . All coordinates are in centimeters. The  $y$ -coordinates are the observations, which are assumed to be (1) uncorrelated and of equal precision, and (2) uncorrelated with variances  $0.10 \text{ cm}^2, 0.08 \text{ cm}^2$ , and  $0.08 \text{ cm}^2$ , respectively. Compute the least squares estimates  $\hat{a}, \hat{b}$  of the two parameters for each of the two cases.

**Solution**

The three condition equations corresponding to the three points are (see also Example 4-1)

$$\begin{aligned} y_1 + v_1 - ax_1 - b &= 0 & \text{or} & & v_1 - 2a - b &= -y_1 = -3.2 \\ y_2 + v_2 - ax_2 - b &= 0 & \text{or} & & v_2 - 4a - b &= -y_2 = -4.0 \\ y_3 + v_3 - ax_3 - b &= 0 & \text{or} & & v_3 - 6a - b &= -y_3 = -5.0 \end{aligned}$$

and in the form  $\mathbf{v} + \mathbf{B}\Delta = \mathbf{f}$  they become

$$\begin{bmatrix} v_1 \\ v_2 \\ v_3 \end{bmatrix} + \begin{bmatrix} -2 & -1 \\ -4 & -1 \\ -6 & -1 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} -3.2 \\ -4.0 \\ -5.0 \end{bmatrix}.$$

Punto	X	Y
1	2	3.2
2	4	4.0
3	6	5.0

$$\sigma_1^2 = 0.10, \sigma_2^2 = 0.08, \sigma_3^2 = 0.08$$

$$\sigma_0^2 = 0.10$$

$$W = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1.25 & 0 \\ 0 & 0 & 1.25 \end{bmatrix} \quad N = \begin{bmatrix} 69 & 14.5 \\ 14.5 & 3.5 \end{bmatrix} \quad \Delta = \begin{bmatrix} 0.452 \\ 2.256 \end{bmatrix} \quad B = \begin{bmatrix} -2 & -1 \\ -4 & -1 \\ -6 & -1 \end{bmatrix}$$

$$Q = W^{-1} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 0.8 & 0 \\ 0 & 0 & 0.8 \end{bmatrix} \Rightarrow Q_{\Delta\Delta} = \begin{bmatrix} 0.112 & -0.464 \\ -0.464 & 2.208 \end{bmatrix} \Rightarrow$$

$$\begin{aligned} \Sigma_{\Delta\Delta} = 0.10 \cdot Q_{\Delta\Delta} &= \begin{bmatrix} 0.0112 & -0.0464 \\ -0.0464 & 0.2208 \end{bmatrix} \Rightarrow \sigma_a^2 = 0.0112 \Rightarrow \sigma_a = 0.106 \\ &\Rightarrow \sigma_b^2 = 0.2208 \Rightarrow \sigma_b = 0.470 \end{aligned}$$

$$\Rightarrow \Sigma_{\bar{u}} = \begin{bmatrix} 0.08 & 0.032 & -0.016 \\ 0.032 & 0.0288 & 0.0256 \\ -0.016 & 0.0256 & 0.0672 \end{bmatrix}$$

$$\Rightarrow \Sigma_{vv} = \begin{bmatrix} 0.02 & -0.032 & 0.016 \\ -0.032 & 0.0512 & -0.0256 \\ 0.016 & -0.0256 & 0.0218 \end{bmatrix}$$

$$\sigma_{Y_1}^2 = 0.0800 \quad \sigma_{Y_1} = 0.3$$

$$\Rightarrow \sigma_{Y_2}^2 = 0.0288 \rightarrow \sigma_{Y_2} = 0.2 \quad \text{varianzas ajustadas}$$

$$\sigma_{Y_3}^2 = 0.0672 \quad \sigma_{Y_3} = 0.3$$

Las varianzas ajustadas y propagadas son mejores que las observadas.

$$\sigma_{v_1}^2 = -0.020 \quad \sigma_{v_1} = 0.11$$

$$\Rightarrow \sigma_{v_2}^2 = 0.0512 \rightarrow \sigma_{v_2} = 0.23$$

$$\sigma_{v_3}^2 = 0.0128 \quad \sigma_{v_3} = 0.11$$



Ej. de la red de nivelación: (3.7 + 6.8 M & G) para Observaciones con Pesos Iguales

• Esto es una red de nivelación donde A es un repere de cota conocida 281.13 m, y se ha nivelado con el método directo...

(observ)	(A)	ΔN (li)
B	A	11.973
D	B	10.940
D	A	22.932
B	C	21.040
D	C	31.891
A	C	8.983

Hay que calcular las elevaciones de B, C y D.

$M_0 = 3 \quad n = 6 \rightarrow v = 3$

Si todo estuviera bien, no habría discrepancia al cerrar la nivelación:  $A \rightarrow B \rightarrow D \rightarrow A = 0.019$   
 $(-11.973 - 10.940 + 22.932)$

para facilitar los cálculos, la elevación de A = A.:

$$\begin{cases} B + l_1 - A = B + l_1 + v_1 - 281.13\phi = \phi \\ D + l_2 - B = D + l_2 + v_2 - B = \phi \\ D + l_3 - A = D + l_3 + v_3 - 281.13\phi = \phi \\ B + l_4 - C = B + l_4 + v_4 - C = \phi \\ D + l_5 - C = D + l_5 + v_5 - C = \phi \\ A + l_6 - C = 281.13\phi + l_6 + v_6 - C = \phi \end{cases}$$

$$\begin{cases} v_1 = 269.157 - B \\ v_2 = B - D - 10.940 \\ v_3 = 258.198 - D \\ v_4 = C - B - 21.040 \\ v_5 = C - D - 31.891 \\ v_6 = C - 290.113 \end{cases} \rightarrow \phi = v_1^2 + v_2^2 + v_3^2 + v_4^2 + v_5^2 + v_6^2 \text{ mínimo}$$


$$= (269.157 - B)^2 + (B - D - 10.940)^2 + (258.198 - D)^2 + (C - B - 21.040)^2 + (C - D - 31.891)^2 + (C - 290.113)^2$$

$$\frac{\partial \phi}{\partial B} = -2(269.157 - B) + 2(B - D - 10.940) - 2(C - B - 21.040) = 0$$

$$\frac{\partial \phi}{\partial C} = 2(C - B - 21.040) + 2(C - D - 31.891) + 2(C - 290.113) = 0$$

$$\frac{\partial \phi}{\partial D} = -2(B - D - 10.940) - 2(258.198 - D) - 2(C - D - 31.891) = 0$$

$$\begin{cases} 3B - C - D = 259.057 \\ -B + 3C - D = 343.044 \\ -B - C + 3D = 215.367 \end{cases} \rightarrow \begin{cases} B = 269.131 \text{ m} \\ C = 290.128 \text{ m} \\ D = 258.209 \text{ m} \end{cases}$$



$B = \tau_1, C = \tau_2, D = \tau_3$

$$W = I \Delta = \begin{bmatrix} \tau_1 \\ \tau_2 \\ \tau_3 \end{bmatrix} \quad B = \begin{bmatrix} 1 & 0 & 0 \\ -1 & 0 & 1 \\ 0 & 0 & 1 \\ 1 & -1 & 0 \\ 0 & -1 & 1 \\ 0 & -1 & 0 \end{bmatrix} \quad N = \begin{bmatrix} 3 & -1 & -1 \\ -1 & 3 & -1 \\ -1 & -1 & 3 \end{bmatrix}$$

A los efectos de poder calcular las varianzas de las cotas ajustadas aseguramos  $\sigma_0^2 = 0.0016m^2$ .

$$Q_{\Delta\Delta} = N^{-1} = \begin{bmatrix} 1/2 & 1/4 & 1/4 \\ 1/4 & 1/2 & 1/4 \\ 1/4 & 1/4 & 1/2 \end{bmatrix} \Rightarrow \Sigma_{\Delta\Delta} = 0.0016 \cdot N^{-1} = \begin{bmatrix} 0.0008 & 0.0004 & 0.0004 \\ 0.0004 & 0.0008 & 0.0004 \\ 0.0004 & 0.0004 & 0.0008 \end{bmatrix}$$

$$\Rightarrow \sigma_{l_1}^2 = 0.0008 \rightarrow \begin{cases} \sigma_B = 0.028m \\ \sigma_C = 0.028m \\ \sigma_D = 0.028m \end{cases}$$

para Observaciones con Ponderadas según Distancias, Ajustadas y Propagadas:

- Hay que resolver el problema de la red de nivelación (p. 23) tomando el caso de observaciones de igual precisión y de observaciones con peso  $w$ .

$$B = \begin{bmatrix} 1 & \emptyset & \emptyset \\ -1 & \emptyset & 1 \\ \emptyset & \emptyset & 1 \\ 1 & -1 & \emptyset \\ \emptyset & -1 & 1 \\ \emptyset & -1 & \emptyset \end{bmatrix} \quad f = \begin{bmatrix} 269.157 \\ -1\emptyset.94\emptyset \\ 258.198 \\ -21.\emptyset4\emptyset \\ -31.891 \\ -29\emptyset.113 \end{bmatrix}$$

$$(a) N = B'B = \begin{bmatrix} 3 & -1 & -1 \\ -1 & 3 & -1 \\ -1 & -1 & 3 \end{bmatrix}$$

$$T = B'f = \begin{bmatrix} 259.057 \\ 343.\emptyset44 \\ 215.367 \end{bmatrix}$$

$$N^{-1} = \begin{bmatrix} 3 & -1 & -1 \\ -1 & 3 & -1 \\ -1 & -1 & 3 \end{bmatrix}^{-1} = \frac{1}{4} \begin{bmatrix} 2 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 2 \end{bmatrix}$$

$$\Delta = N^{-1}T = \frac{1}{4} \begin{bmatrix} 2 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 2 \end{bmatrix} \begin{bmatrix} 259.057 \\ 343.\emptyset44 \\ 215.367 \end{bmatrix} = \begin{bmatrix} 269.131 \\ 29\emptyset.128 \\ 258.2\emptyset9 \end{bmatrix} \left. \vphantom{\Delta} \right\} \text{elevaciones de los puntos B, C y D.}$$

	$l_1$	$l_2$	$l_3$	$l_4$	$l_5$	$l_6$
(b) observ.	<del>24</del>	<del>12</del>	<del>15</del>	<del>28</del>	<del>20</del>	<del>20</del>
Dist.	24	12	15	28	20	20
reciprocal	0.050	0.083	0.067	0.036	0.050	0.039
Peso	1.400	2.333	1.867	1.000	1.400	1.037

Si menor recíprocal le asignas peso = 1, el resto en forma proporcional.

$$W = \begin{bmatrix} 1.400 & & & & & \\ & 2.333 & & & & \\ & & 1.867 & & & \\ & & & 1.000 & & \\ & & & & 1.400 & \\ & & & & & 1.077 \end{bmatrix}$$

$$N = B^T W B = \begin{bmatrix} 1 & -1 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & -1 & -1 & -1 \\ 0 & 1 & 1 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ -1 & 0 & 1 \\ 0 & 0 & 1 \\ 1 & -1 & 0 \\ 0 & -1 & 1 \\ 0 & -1 & 0 \end{bmatrix} = \begin{bmatrix} 4.733 & -1.000 & -2.333 \\ -1.000 & 3.477 & -1.400 \\ -2.333 & -1.400 & 5.600 \end{bmatrix}$$

$$t = B^T W f = B^T W \begin{bmatrix} 269.157 \\ -10.940 \\ 258.198 \\ -21.040 \\ -31.891 \\ 290.113 \end{bmatrix} = \begin{bmatrix} 381.2028 \\ 378.1391 \\ 411.8852 \end{bmatrix}$$

$$N^{-1} = \begin{bmatrix} 0.337902 & 0.171085 & 0.183543 \\ 0.171085 & 0.406418 & 0.172880 \\ 0.183543 & 0.172880 & 0.290256 \end{bmatrix}$$

los 3 parámetros buscados son  $\Delta = N^{-1}t =$

$$= \begin{bmatrix} 269.135 \\ 290.124 \\ 258.205 \end{bmatrix}$$

- Ref. ex. 4-7 de una red, calcular la matriz covarianza para el ajuste de las elevaciones B, C, D, para el caso de observaciones ponderadas, dando la varianza referencial de  $\sigma_0 = 0.016 \text{ m}^2$ . Calcular también las desviaciones estándar en el ajuste de elevaciones de B, C, D.

aplicado ... con datos del problema  $\Rightarrow$

$$Q_{\Delta\Delta} = N^{-1} = \begin{bmatrix} 0.337902 & 0.171088 & 0.183543 \\ & 0.406418 & 0.172880 \\ & & 0.298256 \end{bmatrix} \text{ m}^2$$

la matriz referida es:

$$\Sigma_{\Delta\Delta} = \sigma_0^2 Q_{\Delta\Delta} = (0.016) N^{-1} = 10^{-4}$$

las desviaciones estándar son:

$$\sigma_B = (10^{-4}) \sqrt{5.406} = 0.023 \text{ m}$$

$$\sigma_C = (10^{-4}) \sqrt{6.502} = 0.025 \text{ m}$$

$$\sigma_D = (10^{-4}) \sqrt{4.773} = 0.022 \text{ m}$$

Hay un resumen en 9.5 #

### RESUMEN EJECUTIVO ALGORITMO y PROPAGACION MMC + M

$$N = B^T \cdot W \cdot B$$

$$t = B^T \cdot W \cdot f$$

$$\Delta = N^{-1} \cdot t$$

$$v = f - B \cdot \Delta$$

$$\bar{l} = l + v$$

$$Q = W^{-1}$$

$$Q_{\Delta\Delta} = N^{-1} \Rightarrow \Sigma_{\Delta\Delta} = \sigma_0^2 \cdot Q_{\Delta\Delta}$$

$$Q_{vv} = Q - B \cdot N^{-1} \cdot B^T \Rightarrow \Sigma_{vv} = \sigma_0^2 \cdot Q_{vv}$$

$$Q_{\bar{l}\bar{l}} = B \cdot N^{-1} \cdot B^T \Rightarrow \Sigma_{\bar{l}\bar{l}} = \sigma_0^2 \cdot Q_{\bar{l}\bar{l}}$$

## ● PROPAGACIÓN DE COFACTORES PARA AMC + C ●

Ecuaciones de condición  $\rightarrow Av = f$   
con  $f = d - l$  donde  $d =$  datos numéricos  
 $l =$  observaciones.

### ANEXO:

Dem. que  $Q_e$  es simétrico  $\Rightarrow Q_e = Q_e^+$

$$Q_e^+ = (AQA^+)^+ = (A^+)^+ Q^+ A^+ = AQA^+ = Q_e \checkmark$$

Dem. que  $Q_e^{-1}$  es simétrico  $\Rightarrow Q_e^{-1} = (Q_e^{-1})^+$

$$((AQA^+)^-)^+ = ((AQA^+)^+)^{-1} = Q_e^{-1} \checkmark$$

Δhace trópicos  $\hat{l} = l + v$

$$\hat{l} = l + QA^+k = l + QA^+w_e f = l + QA^+w_e [(-A)l + d] \rightarrow$$

$$\hat{l} = (I - QA^+w_e A)l + QA^+w_e d$$

$$\rightarrow Q\hat{l}\hat{l} = (I - QA^+w_e A) Q_{ll} (I - QA^+w_e A)^+$$

$$= (I - QA^+w_e A) Q (I^+ - A^+w_e^+ A Q^+)$$

$$= (I - QA^+w_e A) Q (I - A^+w_e A Q)$$

$$= (IQ - QA^+w_e A Q) (I - A^+w_e A Q)$$

$$= IQI - IQA^+w_e A Q - QA^+w_e A QI + QA^+w_e A QA^+w_e A Q =$$

$$Q\hat{l}\hat{l} = Q - 2QA^+w_e A Q + QA^+w_e A Q \rightarrow$$

$$Q\hat{l}\hat{l} = Q - QA^+w_e A Q \rightarrow$$

$Q\hat{l}\hat{l} = Q - Q_{uv}$  notando que  $\hat{l} = l + v$ , está bien que no se conserve el signo, así  $Q\hat{l}\hat{l}$  justamente es menor a  $Q_{ll}$  ✓

$$\sigma_0^2 Q\hat{l}\hat{l} = \sigma_0^2 Q - \sigma_0^2 Q_{uv}$$

$\sum \hat{l}\hat{l} = \sum ll - \sum uv$  las varianzas de los resultados corregidos son menores que la de las observaciones.

Presentado de otra forma llegamos a la misma definición:

● **Algoritmo AMC+C:**

$$\begin{aligned} Q_e &= AQA^T (=Q_{ff}) \\ W_e &= Q_e^{-1} \\ k &= W_e f \\ v &= QA^T k \\ \bar{l} &= l + v \\ \sigma_0^2 &= \frac{v^t W v}{r} \end{aligned}$$

Trabajaremos con funciones lineales:

Matriz cofactor asociada a las observaciones  $\Rightarrow Q_{ll} = Q = W^{-1}$  pues simplifica la notación.

$Q_e$  ya es una matriz cofactor  $\Rightarrow W_e$  es la matriz peso correspondiente.

$$f = -Al + d \text{ (propagación lineal)} \Rightarrow Q_{ff} = (-A)Q_{ll}(-A)^T = AQA^T \Rightarrow Q_{ff} = AQA^T = Q_e \bullet$$

$$Q_{kk} = \underbrace{(W_e)}_{Q_e^{-1}} \underbrace{Q_{ff}}_{Q_e} (W_e)^{-T} = W_e \bullet Q_{kk} = W_e \quad \text{del algoritmo: } K = \text{inv}(Q_e). f \bullet$$

$$Q_{vv} = \underbrace{(QA^T)}_{W_e} \underbrace{Q_{kk}}_{(A^T)^T \cdot Q^T} \underbrace{(QA^T)^T}_{(A^T)^T \cdot Q^T} = QA^T W_e A Q \Rightarrow * Q_{vv} = QA^T W_e A Q \bullet$$

Todos los Cofactores y Pesos son simétricos, y para obtener la Matriz Cofactor de  $\bar{l} = l + v$ , debemos tratarla como una función lineal de  $l$ .

$$\sigma_0^2 = \frac{v^t W v}{r}$$

$$\Sigma_{vv} = \sigma_0^2 Q_{vv} \bullet$$

Demostración que  $(W_e)^T = W_e$

$$W_e = Q_e^{-1} \Rightarrow Q_e^T = (AQA^T)^T = \underbrace{(A^T)^T}_A \underbrace{(AQ)^T}_{Q^T \cdot A^T} = AQA^T = Q_e \Rightarrow Q_e^T = Q_e \bullet$$

Y demostraremos que  $Q_e^{-1}$  es simétrica.

$$W_e^T = \left( \underbrace{(AQA^T)^{-1}}_{Q_e} \right)^T = \left( \underbrace{(AQA^T)^T}_{Q_e} \right)^{-1} = Q_e^{-1} = W_e \Rightarrow (W_e)^T = W_e \bullet$$

Ahora trataremos:  $\bar{l} = l + v = l + QA^T k$  ●

$$\bar{l} = l + QA^T W_e f = l + QA^T W_e (d - Al) = l + QA^T W_e d - QA^T W_e Al$$

$$\bar{l} = (I - QA^T W_e A)l + QA^T W_e d \quad (\text{forma lineal})$$

$$Q_{\bar{l}\bar{l}} = (I - QA^T W_e A) Q_{ll} (I - QA^T W_e A)^T = (I - QA^T W_e A) Q \begin{pmatrix} I & - (QA^T W_e A) \\ & (W_e A)^T \cdot (Q \cdot A^T)^T \end{pmatrix}^T$$

$$Q_{\bar{l}\bar{l}} = (IQ - QA^T W_e AQ)(I - QA^T W_e A)^T = (IQ - QA^T W_e AQ)(I^T - A^T W_e^T A Q^T)$$

$$= \underbrace{IQI}_{Q} - IQA^T W_e AQ - QA^T W_e AQI + QA^T W_e \underbrace{AQA^T W_e AQ}_I$$

$$Q_{\bar{l}\bar{l}} = Q - QA^T W_e AQ - QA^T W_e AQ + QA^T W_e AQ$$

$$Q_{\bar{l}\bar{l}} = Q - QA^T W_e AQ \Rightarrow Q_{\bar{l}\bar{l}} = Q - Q_{vv} \Rightarrow \Sigma_{\bar{l}\bar{l}} = \sigma_0^2 Q_{\bar{l}\bar{l}} \bullet$$

$$\sigma_0 Q_{\bar{l}\bar{l}} = \sigma_0 Q - \sigma_0 Q_{vv} \Rightarrow$$

$$\bullet \bullet \Sigma_{\bar{l}\bar{l}} = \Sigma_{ll} - \Sigma_{vv} \bullet \bullet \sigma_{\bar{l}\bar{l}}^2 = \sigma_{ll}^2 - \sigma_{vv}^2 \bullet \bullet$$

Lo que demuestra que luego de un ajuste con su correspondiente propagación de errores o varianzas, la precisión del resultado final es mejor que las precisiones iniciales, incluyendo el factor de Escala  $\sigma_0^2 = \frac{v^T W v}{r}$  explicitando tácitamente la necesidad de obtener observaciones redundantes en cualquier operación de Agrimensura, para luego proceder a la depuración y ajuste de las observaciones.