

Teorie chyb a vyrovnávací počet 2

Téma č. 8: Vyrovnání podmínkových s neznámými

1. Definice problému.
2. Odvození.
3. Řešení.
4. Směrodatné odchylky.
5. Příklad

1. Definice problému

Tento obecný typ vyrovnání nastává, když v podmínkových rovnicích vystupují kromě vyrovnaných měření ještě další, přímo neměřené neznámé, které též chceme určit.

Tvar podmínkové rovnice:

$$\varphi(\bar{\mathbf{l}}^T, \mathbf{x}^T) = \mathbf{0}$$

Ve shodě s vyrovnání měření podmínkových můžeme podmínky linearizovat:

$$\mathbf{A}^T \cdot \mathbf{v} + \mathbf{B} \cdot d\mathbf{x} + \mathbf{u} = \mathbf{0}$$

$$\mathbf{A} = \begin{pmatrix} a_{11} & \dots & a_{r1} \\ \vdots & \vdots & \vdots \\ a_{1n} & \dots & a_{rn} \end{pmatrix}, \mathbf{B} = \begin{pmatrix} A_1 & B_1 & \dots & K_1 \\ \vdots & \vdots & \vdots & \vdots \\ A_r & B_r & \dots & K_r \end{pmatrix}, d\mathbf{x} = \begin{pmatrix} dx_1 \\ \vdots \\ dx_k \end{pmatrix}, \mathbf{u} = \begin{pmatrix} U_1 \\ \vdots \\ U_r \end{pmatrix}.$$

2. Řešení

Použijeme Lagrangeova postupu hledání minima.

$$\bar{\Omega} = \mathbf{v}^T \cdot \mathbf{P} \cdot \mathbf{v} - 2 \cdot \mathbf{k}^T \cdot (\mathbf{A}^T \cdot \mathbf{v} + \mathbf{B} \cdot \mathbf{dx} + \mathbf{u}) = \min.,$$

$$\frac{\partial \bar{\Omega}}{\partial \mathbf{v}} = 2 \cdot \mathbf{P} \cdot \mathbf{v} - 2 \cdot \mathbf{A} \cdot \mathbf{k} = \mathbf{0} \quad \mathbf{v} = \mathbf{P}^{-1} \cdot \mathbf{A} \cdot \mathbf{k}$$

$$\frac{\partial \bar{\Omega}}{\partial \mathbf{dx}} = -2 \cdot \mathbf{B}^T \cdot \mathbf{k} = \mathbf{0} \quad \mathbf{B}^T \cdot \mathbf{k} = \mathbf{0}$$

Po dosazení:

$$\begin{pmatrix} \mathbf{A}^T \cdot \mathbf{P}^{-1} \cdot \mathbf{A} & \mathbf{B} \\ \mathbf{B}^T & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{k} \\ \mathbf{dx} \end{pmatrix} + \begin{pmatrix} \mathbf{u} \\ \mathbf{0} \end{pmatrix} = \mathbf{0}$$

$$\mathbf{N} \cdot \mathbf{y} + \mathbf{n} = \mathbf{0}$$

$$\mathbf{y} = -\mathbf{N}^{-1} \cdot \mathbf{n}$$

2. Směrodatné odchylky

$$N^{-1} = \begin{pmatrix} Q_{kk} & Q_{kx} \\ Q_{xk} & Q_{xx} \end{pmatrix}$$

$$dx = -Q_{xk} \cdot u$$

$$k = -Q_{kk} \cdot u$$

$$v = P^{-1} \cdot A \cdot k$$

$$s_0 = \sqrt{\frac{v^T \cdot P \cdot v}{r-k}}$$

$$M_{x_i} = \sigma_0 \cdot (-Q_{xx})$$

$$\sigma_{x_i} = \sigma_0 \cdot \sqrt{-Q_{xx_{ii}}}$$

$$Q_{\bar{i}} = P^{-1} - P^{-1} \cdot A \cdot Q_{kk} \cdot A^T \cdot P^{-1},$$

$$\sigma_{\bar{i}} = \sigma_0 \cdot \sqrt{Q_{\bar{i}i}}$$

(podle situace se použije σ_0 nebo s_0)

4. Příklad

Aproximace bodů rovinou – případ v_x v_y v_z .

😊 **Konec** 😊