



# Graph-Based SLAM (Least square approach)

Approach for computing solution for overdetermined system  
Minimizes the sum of the squared errors.

## Problem Setting



$$\begin{aligned} x_0 &= 0 \\ x_1 &= x_0 + 1 \\ x_2 &= x_1 - 0.8 \\ x_2 &= x_0 \end{aligned}$$



## 最小二乘优化: (使用闭环)

方程

$$\begin{cases} f_1 = x_0 = 0 \\ f_2 = x_1 - x_0 - 1 = 0 \\ f_3 = x_2 - x_1 + 0.8 = 0 \\ f_4 = x_2 - x_0 = 0 \end{cases} \xrightarrow{\text{优化}} C = \sum_{i=1}^4 f_i^2 = x_0^2 + (x_1 - x_0 - 1)^2 + (x_2 - x_1 + 0.8)^2 + (x_2 - x_0)^2$$

求偏导

$$\begin{cases} \frac{\partial C}{\partial x_0} = 0 \\ \frac{\partial C}{\partial x_1} = 0 \\ \frac{\partial C}{\partial x_2} = 0 \end{cases} \Rightarrow \begin{cases} 3x_0 - x_1 - x_2 = -1 \\ -x_0 + 2x_1 - x_2 = 1.8 \\ -x_0 - x_1 + 2x_2 = -0.8 \end{cases} \Rightarrow \begin{cases} x_0 = 0 \\ x_1 = 0.93 \\ x_2 = 0.07 \end{cases}$$


矩阵形式

$$\begin{bmatrix} 3 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{bmatrix} \begin{bmatrix} x_0 \\ x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} -1 \\ 1.8 \\ -0.8 \end{bmatrix}$$


$$\Omega \mu = \xi$$

$$\mu = \Omega^{-1} \xi$$

## Problem with Landmark



初始为  $x_0$ ，前方 2m 有一个 landmark  
编码器记录向前走了 1m，此时  
landmark 在前方 0.8m





方程  $\begin{cases} x_0 = 0 & \text{initial} \\ x_1 = x_0 + 1 & \text{1 forward} \\ l_0 = x_0 + 2 & \text{first observation} \\ l_0 = x_1 + 0.8 & \text{second observation} \end{cases}$

$\begin{cases} f_1 = x_0 = 0 \\ f_2 = x_1 - x_0 - 1 \\ f_3 = l_0 - x_0 - 2 \\ f_4 = l_0 - x_1 - 0.8 \end{cases}$

最小二乘法:

这里的权重均为1 (假设所有传感器一样准)

$$C = \sum_{i=1}^4 f_i^2 = x_0^2 + (x_1 - x_0 - 1)^2 + (l_0 - x_0 - 2)^2 + (l_0 - x_1 - 0.8)^2$$

$$\begin{cases} \frac{\partial C}{\partial x_0} = 0 \Rightarrow 2x_0 - 2(x_1 - x_0 - 1) - 2(l_0 - x_0 - 2) = 0 \\ \frac{\partial C}{\partial x_1} = 0 \Rightarrow 2(x_1 - x_0 - 1) - 2(l_0 - x_1 - 0.8) = 0 \\ \frac{\partial C}{\partial x_2} = 0 \Rightarrow 2(l_0 - x_0 - 2) + 2(l_0 - x_1 - 0.8) = 0 \end{cases} \Rightarrow \begin{cases} x_0 = 0 \\ x_1 = 1.01 \\ x_2 = 1.9 \end{cases}$$

矩阵形式

$$\begin{bmatrix} 3 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{bmatrix} \begin{bmatrix} x_0 \\ x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} -3 \\ 0.2 \\ 2.8 \end{bmatrix}$$

$$\Omega \mu = \zeta$$

$$\mu = \Omega^{-1} \zeta$$

权重也可不一样: 权重为 edge 的信息矩阵


information matrix

图优化的后端:  
(Graph Optimization)

优化目标:

$$x^* = \underset{x}{\operatorname{argmin}} F(x)$$

$$F(x) = \sum_{\langle i,j \rangle \in E} e(x_i, x_j, z_{ij})^T \underbrace{\Omega_{ij}}_{F_{ij}} e(x_i, x_j, z_{ij})$$



$x_i$ : 图顶点的参数向量  
 $z_{ij}$ : 测量值, perception  
 $\Omega_{ij}$ : 该误差所占权重的矩阵  
 $e(x_i, x_j, z_{ij})$ :  $x_i, x_j$  之间的关系与  $z_{ij}$  之间的吻合度

$x_1, x_2, \dots, x_n$  为  $n$  个 node  
 每个 node 是一个 2D or 3D 位置

$$e(x_i, x_j, z_{ij}) \xrightarrow{\text{def}} e_{ij}(x_i, x_j) \xrightarrow{\text{def}} e_{ij}(x)$$

$$\therefore F(x) = e_{12}^T \Omega_{12} e_{12} + e_{23}^T \Omega_{23} e_{23} + e_{31}^T \Omega_{31} e_{31} + e_{24}^T \Omega_{24} e_{24} + \dots$$



假设 sensor 采样呈多元高斯分布:

不同时刻的采样 (互不相关)

$$f_x(x_1, x_2, \dots, x_k) = \frac{1}{\sqrt{(2\pi)^k |\Sigma|}} \exp\left(-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu)\right)$$

知识补充: 协方差, 协方差矩阵

协方差: 衡量两个变量相关性, 协方差 =  $\begin{cases} \text{正, 正相关} \\ 0, \text{独立} \\ \text{负, 负相关} \end{cases}$

方差: 
$$\text{Var}(X) = \frac{\sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})}{n-1}$$

协方差: 
$$\text{Cov}(X, Y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n-1}$$

这里  $X, Y$  为 2 个变量空间, 也可认为是 2 个特征空间  
 $(X$  为  $x$  特征集合)  
 $(Y$  为  $y$  特征集合)

e.g. 4 个样本

$$\begin{aligned} x_1 &= (1, 2) \\ x_2 &= (3, 6) \\ x_3 &= (4, 2) \\ x_4 &= (5, 2) \end{aligned} \Rightarrow Z = \begin{bmatrix} 1 & 2 \\ 3 & 6 \\ 4 & 2 \\ 5 & 2 \end{bmatrix} \Rightarrow X = \begin{bmatrix} 1 \\ 3 \\ 4 \\ 5 \end{bmatrix} \quad Y = \begin{bmatrix} 2 \\ 6 \\ 2 \\ 2 \end{bmatrix}$$

协方差矩阵反映所有变量两两之间的关系

$$\text{Cov}(X, Y) = \text{Cov}(Z) = \begin{bmatrix} \text{Cov}(X, X) & \text{Cov}(X, Y) \\ \text{Cov}(Y, X) & \text{Cov}(Y, Y) \end{bmatrix}$$

其中:  $\bar{x} = 3.25 \quad \bar{y} = 3$

$$\text{Cov}(X, X) = \frac{1}{4-1} \left[ (1-3.25)^2 + (3-3.25)^2 + (4-3.25)^2 + (5-3.25)^2 \right] = 2.9167$$

$$\text{Cov}(X, Y) = \text{Cov}(Y, X) = \frac{1}{4-1} \times \left[ (1-3.25)(2-3) + (3-3.25)(6-3) + \dots \right] = -0.3333$$

$$\text{Cov}(Y, Y) = 4$$

$$\therefore \text{协方差矩阵 } \text{Cov}(Z) = \begin{bmatrix} 2.9167 & -0.3333 \\ -0.3333 & 4 \end{bmatrix} = \Sigma$$

总结得  $\Sigma_{ij} = \frac{(\text{样本矩阵第 } i \text{ 列} - \text{第 } i \text{ 列均值})^T (\text{样本矩阵第 } j \text{ 列} - \text{第 } j \text{ 列均值})}{\text{样本数} - 1}$



# 知识补充: 高斯分布 扩展到多维

一维高斯分布:  $N(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2}$

高维高斯分布:  $N(\vec{x}|\vec{\mu}, \Sigma) = \frac{1}{(2\pi)^{\frac{D}{2}}} \cdot \frac{1}{|\Sigma|^{\frac{1}{2}}} \cdot e^{-\frac{1}{2}(\vec{x}-\vec{\mu})^T \Sigma^{-1}(\vec{x}-\vec{\mu})}$

$\vec{x}$  为维度为  $D$  的向量

$\vec{\mu}$  为向量的平均值

$\Sigma$  为所有向量  $\vec{x}$  的协方差矩阵

二维情况:

$\vec{x} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$ ,  $\vec{\mu} = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix}$ ,  $\vec{\sigma} = \begin{bmatrix} \sigma_1^2 \\ \sigma_2^2 \end{bmatrix}$  假设  $x_1, x_2$  独立

$$f(\vec{x}) = f(x_1) \cdot f(x_2)$$

$$= \frac{1}{\sqrt{2\pi\sigma_1^2}} e^{-\frac{1}{2\sigma_1^2}(x_1-\mu_1)^2} \times \frac{1}{\sqrt{2\pi\sigma_2^2}} e^{-\frac{1}{2\sigma_2^2}(x_2-\mu_2)^2}$$

$$= \frac{1}{2\pi^{\frac{1}{2}} \sqrt{\sigma_1^2 \sigma_2^2}} e^{-\frac{1}{2} \left[ \left( \frac{x_1-\mu_1}{\sigma_1} \right)^2 + \left( \frac{x_2-\mu_2}{\sigma_2} \right)^2 \right]}$$

对于  $\vec{x}$  而言, 协方差矩阵:  $\Sigma = \begin{bmatrix} \sigma_1^2 & \sigma_1^2 \sigma_2^2 \\ \sigma_2^2 & \sigma_2^2 \end{bmatrix} = \begin{bmatrix} \sigma_1^2 & 0 \\ 0 & \sigma_2^2 \end{bmatrix}$

$$\det(\Sigma) = |\Sigma| = \sigma_1^2 \sigma_2^2$$

$$\therefore f(\vec{x}) = \frac{1}{2\pi^{\frac{1}{2}} |\Sigma|^{\frac{1}{2}}} e^{-\frac{1}{2} \left[ \left( \frac{x_1-\mu_1}{\sigma_1} \right)^2 + \left( \frac{x_2-\mu_2}{\sigma_2} \right)^2 \right]}$$

$$\Sigma^{-1} = \frac{1}{\sigma_1^2 \sigma_2^2} \begin{bmatrix} \sigma_2^2 & 0 \\ 0 & \sigma_1^2 \end{bmatrix}$$

$$\begin{aligned} \exp \left[ -\frac{1}{2}(\vec{x}-\vec{\mu})^T \Sigma^{-1}(\vec{x}-\vec{\mu}) \right] &= \exp \left[ -\frac{1}{2} [x_1-\mu_1 \quad x_2-\mu_2] \frac{1}{\sigma_1^2 \sigma_2^2} \begin{bmatrix} \sigma_2^2 & 0 \\ 0 & \sigma_1^2 \end{bmatrix} \begin{bmatrix} x_1-\mu_1 \\ x_2-\mu_2 \end{bmatrix} \right] \\ &= \exp \left[ -\frac{1}{2} [x_1-\mu_1 \quad x_2-\mu_2] \frac{1}{\sigma_1^2 \sigma_2^2} \begin{bmatrix} \sigma_2^2(x_1-\mu_1) \\ \sigma_1^2(x_2-\mu_2) \end{bmatrix} \right] \\ &= \exp \left[ -\frac{1}{2} \left[ \left( \frac{x_1-\mu_1}{\sigma_1} \right)^2 + \left( \frac{x_2-\mu_2}{\sigma_2} \right)^2 \right] \right] \end{aligned}$$



SLAM 中的优化目标: 已知观测  $z$  后计算  $x$  的条件概率分布

$$P(x|z) = \frac{P(z|x) P(x)}{P(z)} \propto \underbrace{P(z|x)}_{\text{似然}} \underbrace{P(x)}_{\text{先验}}$$

最大后验

$$x^*_{MAP} = \operatorname{argmax} P(x|z) = \operatorname{argmax} P(z|x) P(x)$$

最大似然

$$x^*_{MLE} = \operatorname{argmax} P(z|x) \quad \text{"目前位姿下可能产生什么样的观测"}$$

→ 正态噪声的 Covariance Matrix

$$x \sim N(\mu, \Sigma)$$

回到

$$f_x(x_1, x_2, \dots, x_k) = \frac{1}{\sqrt{(2\pi)^k |\Sigma|}} \exp\left(-\frac{1}{2}(x-\mu)^T \Sigma^{-1} (x-\mu)\right)$$

取对数

$$l_{ij} \propto \underbrace{[z_{ij} - \hat{z}_{ij}(x_i, x_j)]^T}_{e_{ij}} \Omega_{ij} [z_{ij} - \hat{z}_{ij}(x_i, x_j)]$$

note:  $\Omega_{ij} = \Sigma^{-1}$  (测量值  $x_i, x_2, \dots, x_k$  的协方差越小, 信息矩阵权值越大)

问题转化为求解非线性最小二乘

$\left\{ \begin{array}{l} \text{Gauss-Newton} \\ \text{Levenberg-Marquardt} \end{array} \right.$

在初始值  $\check{x}$  附近开始迭代求最优解

$$e_{ij}(\check{x}_i + \Delta x_i, \check{x}_j + \Delta x_j) = e_{ij}(\check{x} + \Delta x)$$

$$\approx e_{ij} + J_{ij} \Delta x$$

$J_{ij}$ : 误差函数  $e_{ij}(x)$  在  $\check{x}$  附近的 Jacobian Matrix

∴ 最小二乘其中项:  $F_{ij}(\check{x} + \Delta x) = e_{ij}(\check{x} + \Delta x)^T \Omega_{ij} e_{ij}(\check{x} + \Delta x)$

$e_{ij}(\check{x})$  简写为  $e_{ij}$   
仅与  $x_i, x_j$  有关

$$\approx (e_{ij} + J_{ij} \Delta x)^T \Omega_{ij} (e_{ij} + J_{ij} \Delta x)$$

$$= (e_{ij}^T + \Delta x^T J_{ij}^T) \Omega_{ij} (e_{ij} + J_{ij} \Delta x)$$



$$\begin{aligned}
&= e_{ij}^T \Omega_{ij} e_{ij} + e_{ij}^T \Omega_{ij} J_{ij} \Delta x + \underbrace{(J_{ij} \Delta x)^T}_{\substack{\text{均为 } n \times 1 \text{ 矩阵} \\ A^T B = B^T A}} \Omega_{ij} e_{ij} + J_{ij}^T \Delta x^T \Omega_{ij} J_{ij} \Delta x \\
&= \underbrace{e_{ij}^T \Omega_{ij} e_{ij}}_{c_{ij}} + \underbrace{2 e_{ij}^T \Omega_{ij} J_{ij} \Delta x}_{b_{ij}^T} + \underbrace{\Delta x^T J_{ij}^T \Omega_{ij} J_{ij} \Delta x}_{H_{ij}} \\
&= c_{ij} + 2 b_{ij}^T \Delta x + \Delta x^T H_{ij} \Delta x
\end{aligned}$$

$b_{ij}$  为列向量  
 $\Delta x$  为列向量  
 $e_{ij}$  为列向量  
 $c_{ij}$  为一个数值

误差平方和:  $F(\check{x} + \Delta x) = \sum_{c_{ij} \in C} F_{ij}(\check{x} + \Delta x)$

$$\begin{aligned}
&\approx \sum_{c_{ij} \in C} c_{ij} + 2 b_{ij}^T \Delta x + \Delta x^T H_{ij} \Delta x \\
&= c + 2 b^T \Delta x + \Delta x^T H \Delta x
\end{aligned}$$

$$c = \sum c_{ij}$$

$$b = \sum b_{ij}$$

$$H = \sum H_{ij}$$

对  $F(\check{x} + \Delta x)$  两边求导:

$$0 = 2b + 2H \Delta x$$

$$\therefore H \Delta x^* = -b \quad (\text{G-N 法})$$

$H$  为系统的信息矩阵

不断迭代 (Euclidean Space 欧氏空间中)

$$x^* = \check{x} + \Delta x^*$$

非欧空间

$$x_{i+1}^* = \check{x}_i \oplus \Delta x_{i+1}^*$$

$$= \begin{bmatrix} x + \Delta x \cos \theta - \Delta y \sin \theta \\ y + \Delta x \sin \theta + \Delta y \cos \theta \\ \text{normAngle}(\theta + \Delta \theta) \end{bmatrix}$$



∴ 误差函数  $e_{ij}$  仅与  $x_i, x_j$  有关 ∴  $J_{ij}$  中仅与  $x_i, x_j$  有关项不为 0

$$J_{ij} = \left[ \begin{array}{c|c|c|c|c} 0 & \frac{\partial e_{ij}(x_i)}{\partial x_i} & 0 & \frac{\partial e_{ij}(x_j)}{\partial x_j} & 0 \\ \hline & A_{ij} & & B_{ij} & \end{array} \right]$$


$$b_{ij}^T = e_{ij}^T \Omega_{ij} J_{ij}$$

$$= e_{ij}^T \Omega_{ij} [0 \dots A_{ij} \dots 0 \dots B_{ij} \dots 0]$$

$$= [0 \dots e_{ij}^T \Omega_{ij} A_{ij} \dots 0 \dots e_{ij}^T \Omega_{ij} B_{ij} \dots 0]$$

$$\hookrightarrow b_{ij} = \begin{bmatrix} 0 \\ \vdots \\ A_{ij}^T \Omega_{ij} e_{ij} \\ B_{ij}^T \Omega_{ij} e_{ij} \\ \vdots \end{bmatrix}$$


$$b_{ij} = J_{ij}^T \Omega_{ij} e_{ij}$$




$$H_{ij} = J_{ij}^T \Omega_{ij} J_{ij}$$

$$= \begin{bmatrix} \vdots \\ A_{ij}^T \\ \vdots \\ B_{ij}^T \\ \vdots \end{bmatrix} \Omega_{ij} [ \dots A_{ij} \dots B_{ij} \dots ]$$

$$H_{ij} = J_{ij}^T \Omega_{ij} J_{ij}$$







**Algorithm 1** Computes the mean  $\mathbf{x}^*$  and the information matrix  $\mathbf{H}^*$  of the multivariate Gaussian approximation of the robot pose posterior from a graph of constraints.

**Require:**  $\check{\mathbf{x}} = \check{\mathbf{x}}_{1:T}$ : initial guess.  $\mathcal{C} = \{\langle \mathbf{e}_{ij}(\cdot), \Omega_{ij} \rangle\}$ : constraints

**Ensure:**  $\mathbf{x}^*$ : new solution,  $\mathbf{H}^*$  new information matrix

// find the maximum likelihood solution

**while**  $\neg$ converged **do**

$\mathbf{b} \leftarrow \mathbf{0}$      $\mathbf{H} \leftarrow \mathbf{0}$

**for all**  $\langle \mathbf{e}_{ij}, \Omega_{ij} \rangle \in \mathcal{C}$  **do**

        // Compute the Jacobians  $\mathbf{A}_{ij}$  and  $\mathbf{B}_{ij}$  of the error function

$\mathbf{A}_{ij} \leftarrow \frac{\partial \mathbf{e}_{ij}(\mathbf{x})}{\partial \mathbf{x}_i} \Big|_{\mathbf{x}=\check{\mathbf{x}}}$      $\mathbf{B}_{ij} \leftarrow \frac{\partial \mathbf{e}_{ij}(\mathbf{x})}{\partial \mathbf{x}_j} \Big|_{\mathbf{x}=\check{\mathbf{x}}}$ .

        // compute the contribution of this constraint to the linear system

$\mathbf{H}_{[ii]} += \mathbf{A}_{ij}^T \Omega_{ij} \mathbf{A}_{ij}$      $\mathbf{H}_{[ij]} += \mathbf{A}_{ij}^T \Omega_{ij} \mathbf{B}_{ij}$

$\mathbf{H}_{[ji]} += \mathbf{B}_{ij}^T \Omega_{ij} \mathbf{A}_{ij}$      $\mathbf{H}_{[jj]} += \mathbf{B}_{ij}^T \Omega_{ij} \mathbf{B}_{ij}$

        // compute the coefficient vector

$\mathbf{b}_{[i]} += \mathbf{A}_{ij}^T \Omega_{ij} \mathbf{e}_{ij}$      $\mathbf{b}_{[j]} += \mathbf{B}_{ij}^T \Omega_{ij} \mathbf{e}_{ij}$

**end for**

    // keep the first node fixed

$\mathbf{H}_{[11]} += \mathbf{I}$

    // solve the linear system using sparse Cholesky factorization

$\Delta \mathbf{x} \leftarrow \text{solve}(\mathbf{H} \Delta \mathbf{x} = -\mathbf{b})$

    // update the parameters

$\check{\mathbf{x}} += \Delta \mathbf{x}$

**end while**

$\mathbf{x}^* \leftarrow \check{\mathbf{x}}$

$\mathbf{H}^* \leftarrow \mathbf{H}$

// release the first node

$\mathbf{H}_{[11]}^* -= \mathbf{I}$

**return**  $\langle \mathbf{x}^*, \mathbf{H}^* \rangle$



构建误差函数:

$$e_{ij}(x_i, x_j) = \text{tr} \left( Z_{ij}^{-1} (x_i^{-1} \cdot x_j) \right)$$

$Z_{ij}^{-1}$ :  $x_i$  observed from  $x_j$   
(virtual observation)

$x_j$  in the reference of  $x_i$   $\hat{z}_{ij}$   
(graph)

如果  $Z_{ij} = x_i^{-1} x_j$  则 error 为 0, 从图上看以及实际观察一样

设  $z_{ij}$  ( $j$  到  $i$  的变换矩阵为:

$$x_i^{-1} x_j = \begin{bmatrix} R & t \\ 0 & 1 \end{bmatrix}$$

measurement

$$\text{设 } z_{ij} = \begin{bmatrix} R' & t' \\ 0 & 1 \end{bmatrix}$$

误差计算:

$$\begin{aligned} Z_{ij}^{-1} (x_i^{-1} x_j) &= \begin{bmatrix} R' & t' \\ 0 & 1 \end{bmatrix}^{-1} \begin{bmatrix} R & t \\ 0 & 1 \end{bmatrix} = \begin{bmatrix} R'^T & -R'^T t' \\ 0 & 1 \end{bmatrix} \begin{bmatrix} R & t \\ 0 & 1 \end{bmatrix} \\ &= \begin{bmatrix} R'^T R & R'^T t - R'^T t' \\ 0 & 1 \end{bmatrix} \\ &= \begin{bmatrix} R'^T R & R'^T (t - t') \\ 0 & 1 \end{bmatrix} \end{aligned}$$

知识补充

分块矩阵求导

$$\begin{aligned} \begin{bmatrix} R & t \\ 0 & 1 \end{bmatrix}^{-1} &= \left[ \begin{bmatrix} I & t \\ 0 & 1 \end{bmatrix} \begin{bmatrix} R & 0 \\ 0 & 1 \end{bmatrix} \right]^{-1} = \left[ \begin{bmatrix} R & 0 \\ 0 & 1 \end{bmatrix}^{-1} \begin{bmatrix} I & t \\ 0 & 1 \end{bmatrix}^{-1} \right] \\ &= \left[ \begin{bmatrix} R^T & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} I & -t \\ 0 & 1 \end{bmatrix} \right] \\ &= \begin{bmatrix} R^T & -R^T t \\ 0 & 1 \end{bmatrix} \end{aligned}$$



$$Z_{ij}^{-1}(x_i^{-1}x_j) = \begin{bmatrix} R^T R & R^T (t-t') \\ 0 & 1 \end{bmatrix}$$

将  $x_i^{-1}x_j$  化为

$$\begin{bmatrix} R_i^T (t_j - t_i) \\ \theta_j - \theta_i \end{bmatrix}$$

转为误差向量:

$$\Delta e_{ij} = R_z^T \left[ R_i^T \left( \begin{bmatrix} x_j \\ y_j \end{bmatrix} - \begin{bmatrix} x_i \\ y_i \end{bmatrix} \right) - \begin{bmatrix} x_z \\ y_z \end{bmatrix} \right]$$

$$\frac{\partial e_{ij}(x_i)}{\partial x_i} = A_{ij} = \begin{bmatrix} -R_z^T R_i^T & R_z^T \frac{\partial R_i^T}{\partial \theta_i} (t_j - t_i) \\ 0 & -1 \end{bmatrix}$$

2x2      (x2)

$$\frac{\partial e_{ij}(x_j)}{\partial x_j} = B_{ij} = \begin{bmatrix} R_z^T R_i^T & 0 \\ 0 & 1 \end{bmatrix}$$