

# Surveillance Distribuée de Systèmes Multi-agents

UPJV, Département EEA

Master 2 3EA, EC53  
UE alternants

**Fabio MORBIDI**

Laboratoire MIS  
Équipe Perception Robotique  
fabio.morbidi@u-picardie.fr

Mardi, Mercredi et Jeudi  
13h30-16h00 (CM et TD salle CURI 305)  
13h30-17h30 (TP salle CURI 305)

**AU 2022-2023**



# Ch. 3: Estimation distribuée

• Introduction à la théorie des graphes **Partie 1**

• Protocole de consensus **Partie 2**

• Dynamic average consensus estimators **Partie 3**

• Méthode des moindres carrés distribuée **Partie 4**

• Filtre de Kalman distribué **Partie 5**

# Méthode des moindres carrés distribuée

## Introduction

- La méthode des moindres carrés *linéaires* peut être reformulée de *façon distribuée*
- Les estimateurs basés sur la méthode des moindres carrés **ne font aucune hypothèse sur les propriétés statistiques du bruit** qui entache la variable sous-jacente  $\theta$  (au début du Ch. 1, nous avons désigné ce vecteur de paramètres par le symbole  $\beta$ )
  - Pour cette raison, ils sont facilement applicables à un large éventail de problèmes d'estimation distribuée

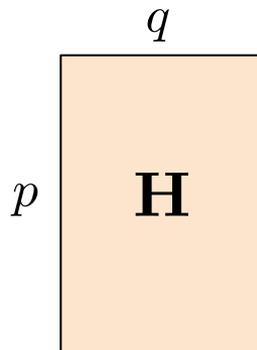
# Méthode des moindres carrés

- Le modèle d'observation consiste en une *fonction linéaire* de la variable  $\theta \in \mathbb{R}^q$  qui est entachée par le bruit additif  $\mathbf{r}$ :

$$\mathbf{z} = \mathbf{H}\theta + \mathbf{r}$$

avec  $\mathbf{z}, \mathbf{r} \in \mathbb{R}^p$  et  $\mathbf{H} \in \mathbb{R}^{p \times q}$  ( $p > q$ ).

- Chaque composante  $z_i$  du vecteur  $\mathbf{z}$  s'appelle **canal de mesure**
- $\mathbf{H}$  est la **matrice d'observation**. On fera l'hypothèse que  $\mathbf{H}$  soit une matrice de rang ligne égal à  $q$ . Cette condition de rang garantit que les canaux de mesure *ne sont pas entièrement redondants*



# Méthode des moindres carrés

- En l'absence d'informations sur les statistiques du bruit de mesure  $\mathbf{r}$ , l'estimation par la méthode des moindres carrés procède à la minimisation de la fonction de coût suivante:

$$S(\boldsymbol{\theta}) = (\mathbf{z} - \mathbf{H}\boldsymbol{\theta})^T (\mathbf{z} - \mathbf{H}\boldsymbol{\theta})$$

- Comme  $S$  est une fonction de  $\boldsymbol{\theta}$  *différentiable* et *convexe*, on peut calculer la valeur minimale en égalant son gradient à zéro, à savoir:

$$\frac{\partial S(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \mathbf{0}$$

- On trouve ainsi que:

$$\hat{\boldsymbol{\theta}} = \underbrace{(\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T}_{\mathbf{H}^\dagger} \mathbf{z} \quad \text{Estimation par moindres carrés linéaires de } \boldsymbol{\theta}$$

*Pseudo-inverse (à gauche) de  $\mathbf{H}$*

# Méthode des moindres carrés pondérés

- Si  $\mathbf{r}$  est un bruit blanc gaussien à moyenne zéro avec matrice de covariance définie positive  $\Sigma$ , à savoir  $\mathbf{r} \sim \mathcal{N}(\mathbf{0}, \Sigma)$ , la minimisation de la *fonction de coût pondérée*:

$$S(\boldsymbol{\theta}) = (\mathbf{z} - \mathbf{H}\boldsymbol{\theta})^T \Sigma^{-1} (\mathbf{z} - \mathbf{H}\boldsymbol{\theta})$$

produit l'estimé optimal de  $\boldsymbol{\theta}$ :

$$\hat{\boldsymbol{\theta}} = \underbrace{(\mathbf{H}^T \Sigma^{-1} \mathbf{H})^{-1} \mathbf{H}^T \Sigma^{-1} \mathbf{z}}_{\mathbf{H}^\dagger}$$

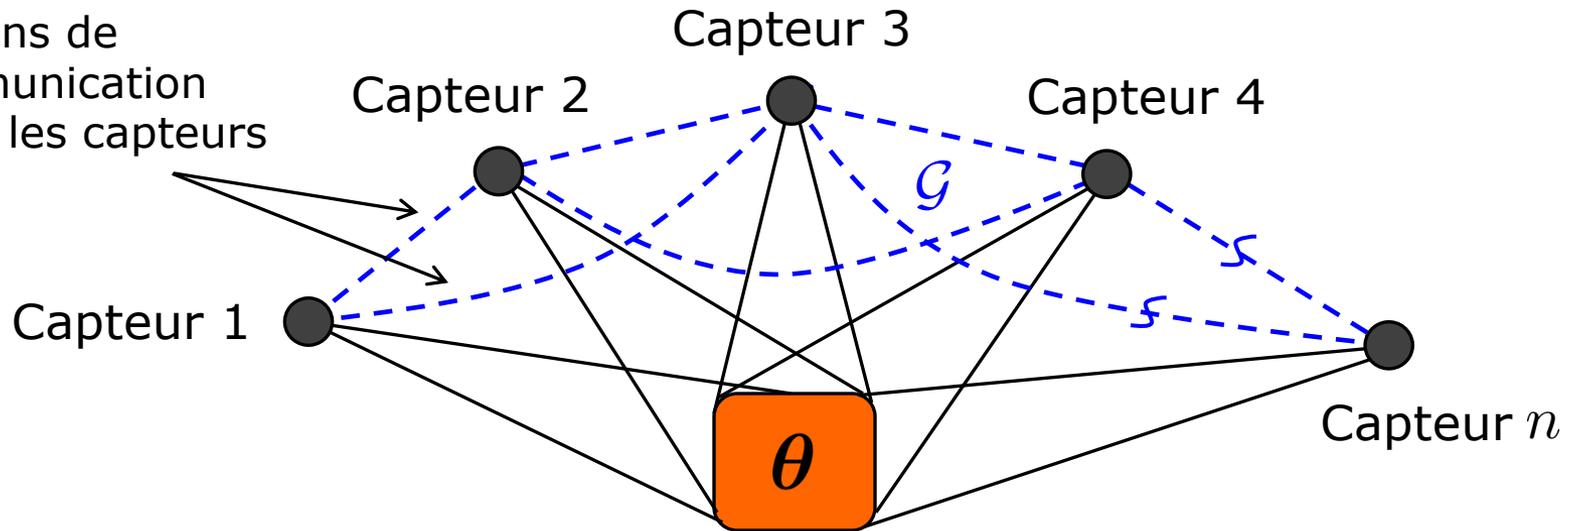
Estimation par moindres carrés pondérés de  $\boldsymbol{\theta}$

*Pseudo-inverse pondérée (à gauche) de  $\mathbf{H}$*

- L'introduction de la matrice  $\Sigma^{-1}$  dans la fonction de coût  $S(\boldsymbol{\theta})$  est motivée par le désir de *biaisier* l'estimé optimal vers ces mesures qui sont les moins incertaines

# Moindres carrés dans un réseau de capteurs

Liaisons de communication entre les capteurs



- Supposons maintenant d'avoir  $n$  capteurs en réseau qui réalisent des mesures de  $\theta$ . Le vecteur d'observation du capteur  $i$  est:

$$\mathbf{z}_i = \mathbf{H}_i \theta + \mathbf{r}_i, \quad i \in \{1, \dots, n\}$$

avec  $\mathbf{z}_i \in \mathbb{R}^{p_i}$  et  $\mathbf{H}_i \in \mathbb{R}^{p_i \times q}$ .

- Par souci de simplicité, on fera l'hypothèse que les matrices de covariance des bruits de mesure  $\mathbf{r}_i$  sont l'identité:  $\Sigma_i = \mathbf{I}_{p_i}, i \in \{1, \dots, n\}$

# Moindres carrés dans un réseau de capteurs

- Considérons maintenant la matrice d'observation *centralisée*:

$$\mathbf{H} = [\mathbf{H}_1^T \quad \mathbf{H}_2^T \quad \dots \quad \mathbf{H}_n^T]^T \in \mathbb{R}^{p \times q},$$

avec  $p = p_1 + p_2 + \dots + p_n$

- En utilisant la matrice  $\mathbf{H}$ , nous pouvons écrire l'estimateur des moindres carrés *centralisé* comme suit:

$$\hat{\boldsymbol{\theta}} = \left( \sum_{i=1}^n \mathbf{H}_i^T \mathbf{H}_i \right)^{-1} \left( \sum_{i=1}^n \mathbf{H}_i^T \mathbf{z}_i \right),$$

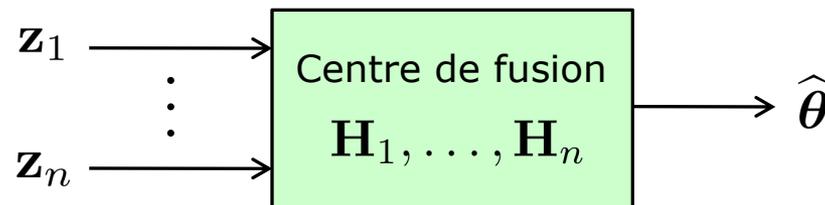
pourvu que les bruits additifs  $\mathbf{r}_i$  soient *statistiquement indépendants*

# Moindres carrés dans un réseau de capteurs

- La **nature additive** de l'équation,

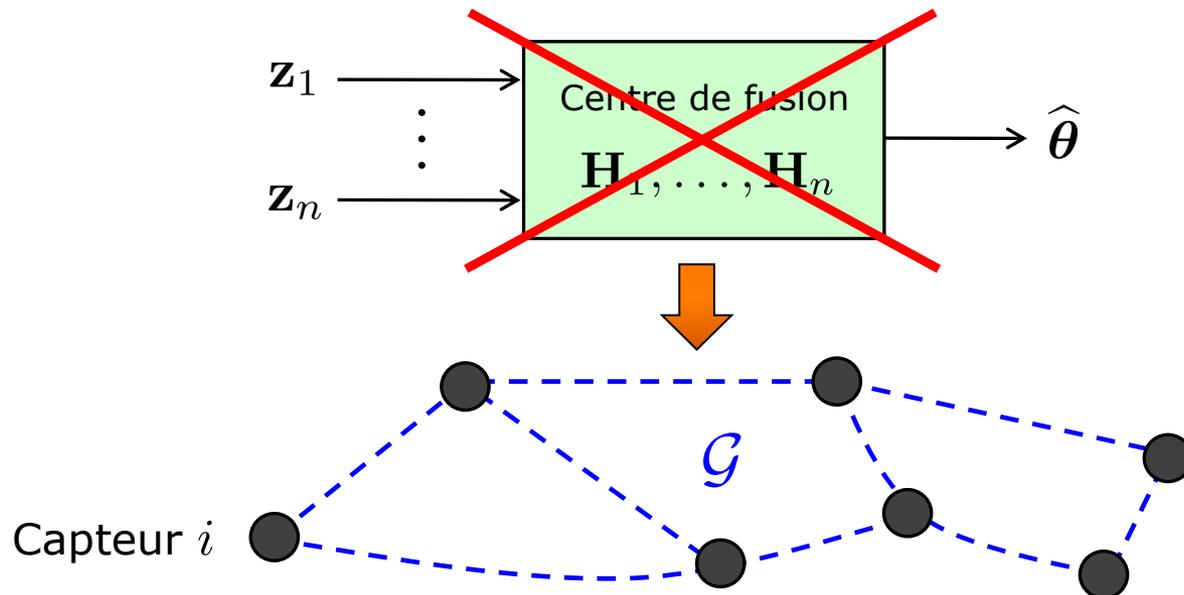
$$\hat{\theta} = \left( \sum_{i=1}^n \mathbf{H}_i^T \mathbf{H}_i \right)^{-1} \left( \sum_{i=1}^n \mathbf{H}_i^T \mathbf{z}_i \right),$$

suggère que si chaque capteur fournit la mesure brute  $\mathbf{z}_i$  à un **centre de fusion** qui a une connaissance préalable de chaque matrice d'observation  $\mathbf{H}_i$ , alors le centre de fusion peut calculer efficacement l'estimé aux moindres carrés  $\hat{\theta}$



# Moindres carrés dans un réseau de capteurs

- Cependant, pour améliorer la *scalabilité* et la *modularité*, et pour avoir un estimateur *moins vulnérable aux pannes*, il est souhaitable de calculer  $\hat{\theta}$  **sans besoin** d'un centre de fusion
- Le **protocole de consensus** vient au secours, car il nous permet de concevoir un algorithme distribué pour les moindres carrés, qui utilise le réseau de communication  $\mathcal{G}$  des capteurs pour calculer  $\hat{\theta}$  *sans besoin d'un centre de fusion*



# Moindres carrés dans un réseau de capteurs

- Considérons le scénario *le plus simple possible*:
  - Estimation d'une variable **scalaire**  $\theta \in \mathbb{R}$ .
  - Les "matrices" d'observation sont  $H_i = 1, \forall i$ .
- Sous ces hypothèses, nous avons que l'équation de mesure est:

$$z_i = \theta + r_i, \quad i \in \{1, \dots, n\}$$

et

$$\hat{\theta} = \frac{1}{n} \sum_{i=1}^n z_i \quad \text{Estimation par moindres carrés centralisée de } \theta$$

- Cette dernière expression (une moyenne arithmétique) nous permet d'utiliser le *protocole de consensus* (en temps discret) pour calculer la solution du problème des moindres carrés de *façon distribuée*

# Moindres carrés dans un réseau de capteurs

- Soit

$$\mathbf{W} = \text{diag}(w_1, \dots, w_m),$$

une *matrice diagonale de pondération* où  $w_j > 0$  est le poids de l'arête  $e_j$  du graphe  $\mathcal{G}$  (indexé de manière cohérente, selon l'ordre des colonnes de la matrice d'incidence  $\mathbf{D}(\mathcal{G})$  correspondante)

- Considérons maintenant l'itération suivante réalisée par le capteur  $i$  :

$$\hat{\theta}_i(k+1) = \hat{\theta}_i(k) + \Delta \sum_{j \in \mathcal{N}(i)} w_{ij} (\hat{\theta}_j(k) - \hat{\theta}_i(k)), \quad i \in \{1, \dots, n\},$$

avec

- $\hat{\theta}_i(k)$  : estimé local du capteur  $i$  de la variable  $\theta$  à l'instant  $k$
- $\Delta \in (0, 1)$  : incrément pour la mise à jour de l'estimé de  $\theta$
- $w_{ij}$  : poids de l'arête reliant le sommet  $i$  au sommet  $j$
- $\mathcal{N}(i)$  : ensemble des sommets adjacents à  $i$  dans le graphe  $\mathcal{G}$

# Moindres carrés dans un réseau de capteurs

- Soit

$$\mathbf{L}_w(\mathcal{G}) = \mathbf{D}(\mathcal{G})\mathbf{W}\mathbf{D}^T(\mathcal{G}),$$

la *matrice laplacienne pondérée* de  $\mathcal{G}$  et définissons la matrice des "itérations" (ou de Perron) suivante:

$$\mathbf{M}_w(\mathcal{G}) = \mathbf{I}_n - \Delta \mathbf{L}_w(\mathcal{G}).$$

- Nous pouvons ainsi récrire de façon compacte les itérations vues dans la diapo précédente comme:

$$\hat{\boldsymbol{\theta}}(k+1) = \mathbf{M}_w(\mathcal{G}) \hat{\boldsymbol{\theta}}(k),$$

avec  $\hat{\boldsymbol{\theta}} \triangleq [\hat{\theta}_1, \dots, \hat{\theta}_n]^T$ .

- Donc

$$\hat{\boldsymbol{\theta}}(k) = \mathbf{M}_w^k(\mathcal{G}) \hat{\boldsymbol{\theta}}(0), \quad k \in \{1, 2, \dots\},$$

où  $\hat{\boldsymbol{\theta}}(0)$  est l'estimé initial de  $\boldsymbol{\theta}$ .

- La convergence de cette séquence dépend du comportement des puissances de  $\mathbf{M}_w(\mathcal{G})$ , qui dépend à son tour du spectre de  $\mathbf{M}_w(\mathcal{G})$

# Moindres carrés dans un réseau de capteurs

## Proposition (Résultat principal)

Soit la séquence,

$$\hat{\boldsymbol{\theta}}(k) = \mathbf{M}_w^k(\mathcal{G}) \hat{\boldsymbol{\theta}}(0), \quad k \in \{1, 2, \dots\},$$

initialisée avec  $\hat{\boldsymbol{\theta}}(0) = [z_1, z_2, \dots, z_n]^T$ , où  $z_i$  est l'observation du capteur  $i$ . Alors,

$$\lim_{k \rightarrow \infty} \hat{\boldsymbol{\theta}}(k) = \left( \frac{1}{n} \sum_{i=1}^n z_i \right) \mathbf{1},$$

si et seulement si le réseau  $\mathcal{G}$  est *connexe* et la valeur propre la plus forte de  $\mathbf{L}_w(\mathcal{G})$  satisfait la condition:

$$\lambda_n(\mathbf{L}_w(\mathcal{G})) < \frac{2}{\Delta}$$

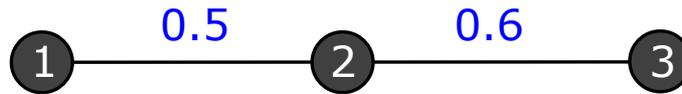
Preuve : Elle ressort de l'observation que le spectre de  $\mathbf{M}_w(\mathcal{G})$  est simplement:

$$1 - \Delta \lambda_i(\mathbf{L}_w(\mathcal{G})), \quad i \in \{1, \dots, n\}$$

# Moindres carrés dans un réseau de capteurs

## Exercice:

- Soit le graphe chaîne pondéré suivant ( $\mathcal{G} = P_3$ ):



- Vérifier que la matrice laplacienne pondérée de  $\mathcal{G}$  et la matrice des itérations correspondante, pour  $\Delta = 1$ , sont:

$$\mathbf{L}_w(\mathcal{G}) = \begin{bmatrix} 0.5 & -0.5 & 0 \\ -0.5 & 1.1 & -0.6 \\ 0 & -0.6 & 0.6 \end{bmatrix}, \quad \mathbf{M}_w(\mathcal{G}) = \begin{bmatrix} 0.5 & 0.5 & 0 \\ 0.5 & -0.1 & 0.6 \\ 0 & 0.6 & 0.4 \end{bmatrix}.$$

- Vérifier que la valeur propre la plus forte de  $\mathbf{L}_w(\mathcal{G})$  satisfait la condition:

$$\lambda_3(\mathbf{L}_w(\mathcal{G})) < \frac{2}{\Delta} = 2$$

et que chaque élément de la matrice  $\mathbf{M}_w^k(\mathcal{G})$  converge vers  $1/3$  lorsque  $k \rightarrow \infty$

# Moindres carrés dans un réseau de capteurs

**Corollaire** (*Choix de la matrice de pondération  $\mathbf{W}$* )

Supposons que le  $j$ -ème élément diagonal de la matrice  $\mathbf{W}$ , qui correspond au poids sur l'arête  $e_j = uv$ , soit défini comme suit:

$$[\mathbf{W}]_{jj} = \frac{1}{\max\{d(u), d(v)\}},$$

où  $d(u)$  dénote le degré du sommet  $u$ . Alors, pour tout  $\Delta \in (0, 1)$ , l'itération,

$$\hat{\theta}_i(k+1) = \hat{\theta}_i(k) + \Delta \sum_{j \in \mathcal{N}(i)} w_{ij} (\hat{\theta}_j(k) - \hat{\theta}_i(k)),$$

converge vers la valeur calculée par l'estimateur des moindres carrés centralisé

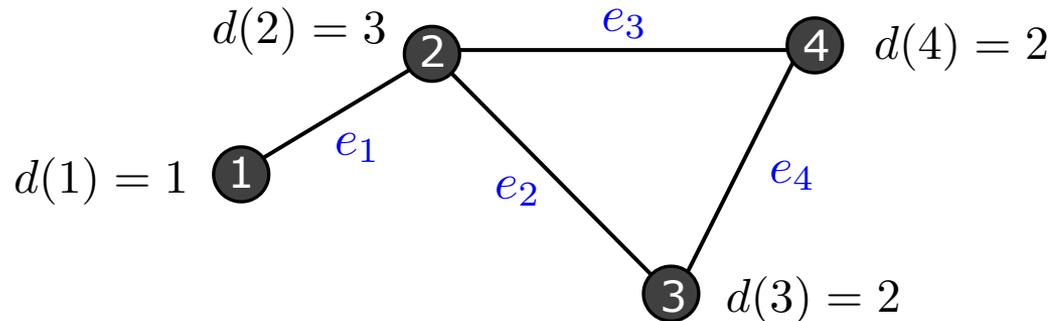
**Remarque:**

Dans la littérature, la formule précédente est connue sous le nom de *règle de pondération de Metropolis-Hastings*

TD3, ex. IV.1  
Fichier Matlab:  
[MoinCar\\_Distr.m](#)

# Moindres carrés dans un réseau de capteurs

Exemple (Règle de Metropolis-Hastings):



- Les poids sur les quatre arêtes  $e_1, e_2, e_3, e_4$  sont:

$$[\mathbf{W}]_{11} = \frac{1}{\max\{1, 3\}} = \frac{1}{3}$$

$$[\mathbf{W}]_{22} = \frac{1}{\max\{3, 2\}} = \frac{1}{3}$$

$$[\mathbf{W}]_{33} = \frac{1}{\max\{3, 2\}} = \frac{1}{3}$$

$$[\mathbf{W}]_{44} = \frac{1}{\max\{2, 2\}} = \frac{1}{2}$$

- La matrice de pondération cherchée est donc:

$$\mathbf{W} = \text{diag} (1/3, 1/3, 1/3, 1/2)$$

# Moindres carrés dans un réseau de capteurs : cas vectoriel

- On peut généraliser le résultat précédent pour une **variable vectorielle**  $\theta \in \mathbb{R}^q$ .
- On fera l'hypothèse que la matrice d'observation  $\mathbf{H}_i \in \mathbb{R}^{p_i \times q}$  du capteur  $i$  soit arbitraire, pourvu que  $\mathbf{H} = [\mathbf{H}_1^T \ \mathbf{H}_2^T \ \cdots \ \mathbf{H}_n^T]^T$  soit de *rang plein ligne*
- Chaque capteur  $i$  stocke deux quantités, la matrice  $\mathbf{P}_i \in \mathbb{R}^{q \times q}$  et le vecteur  $\hat{\theta}_i \in \mathbb{R}^q$ , et il effectue *localement* les itérations suivantes:

$$\mathbf{P}_i(k+1) = \mathbf{P}_i(k) + \Delta \sum_{j \in \mathcal{N}(i)} w_{ij} (\mathbf{P}_j(k) - \mathbf{P}_i(k)),$$
$$\hat{\theta}_i(k+1) = \hat{\theta}_i(k) + \Delta \sum_{j \in \mathcal{N}(i)} w_{ij} (\hat{\theta}_j(k) - \hat{\theta}_i(k)),$$

$i \in \{1, \dots, n\},$

avec l'initialisation,

$$\mathbf{P}_i(0) = \mathbf{H}_i^T \mathbf{H}_i, \quad \hat{\theta}_i(0) = \mathbf{H}_i^T \mathbf{z}_i, \quad i \in \{1, \dots, n\},$$

où  $\mathbf{z}_i \in \mathbb{R}^{p_i}$  dénote le vecteur d'observation du capteur  $i$

# Moindres carrés dans un réseau de capteurs : cas vectoriel

- Nous avons que (cf. la discussion dans le cas scalaire):

$$\lim_{k \rightarrow \infty} \mathbf{P}_i(k) = \frac{1}{n} \sum_{i=1}^n \mathbf{H}_i^T \mathbf{H}_i,$$

$$\lim_{k \rightarrow \infty} \hat{\boldsymbol{\theta}}_i(k) = \frac{1}{n} \sum_{i=1}^n \hat{\boldsymbol{\theta}}_i(0) = \frac{1}{n} \sum_{i=1}^n \mathbf{H}_i^T \mathbf{z}_i,$$

si l'incrément  $\Delta$  et les poids  $w_{ij}$  respectent les conditions imposées par la Proposition vue dans le cas scalaire

- Chaque capteur peut ainsi calculer *localement* l'estimé fourni par la méthode des moindres carrés centralisée. En fait, nous avons que:

$$\hat{\boldsymbol{\theta}} = \lim_{k \rightarrow \infty} \mathbf{P}_i^{-1}(k) \hat{\boldsymbol{\theta}}_i(k).$$

# Moindres carrés dans un réseau de capteurs : cas vectoriel

TD3, ex. IV.2

## Remarque:

- Dans la limite précédente:

$$\hat{\theta} = \lim_{k \rightarrow \infty} \mathbf{P}_i^{-1}(k) \hat{\theta}_i(k), \quad i \in \{1, \dots, n\}$$

la matrice  $\mathbf{P}_i(k)$  *n'est pas nécessairement inversible* pour toute valeur de  $k$ .

- Par conséquent, le capteur  $i$  peut calculer son estimé local de  $\theta$  seulement lorsque  $\mathbf{P}_i(k)$  devient *non singulière*

Pour plus de détails, voir:

"Distributed linear parameter estimation over wireless sensor networks",  
A. Das, M. Mesbahi, IEEE Trans. Aerospace and Electronic Systems, vol. 45,  
n. 4, pp. 1293-1306, 2009