

# 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. 2: Traitement des mesures

- Réseaux multi-capteurs

**Partie 1**

- Fusion des mesures

**Partie 2**

## « Différents » filtres de Kalman

1. Fusion de mesures
  - Combinaison des évidences (mesures) de façon optimale
2. Fusion de mesures *dans le temps*
  - Moyenne glissante
3. Fusion de mesures de *capteurs en mouvement*
  - Filtre de Kalman linéaire (systèmes dyn. linéaires)
  - Filtre de Kalman étendu ou EKF (systèmes dyn. non linéaires)

# 1. Fusion de mesures

## Notation:

$x$  : état du système (scalaire, pour plus de simplicité)

$z_i$  : mesure du capteur  $i$

$\sigma_i^2$  : variance de la mesure du capteur  $i$

$\hat{x}, \sigma^2$  : estimation (optimale) de  $x$  et variance de  $\hat{x}$

## Nos hypothèses:

- Deux mesures non corrélées  $z_i = x + r_i, i \in \{1, 2\}$
- Bruits blancs gaussiens à moyenne zéro:  $r_i \sim \mathcal{N}(0, \sigma_i^2)$

## Estimation de l'état optimum:

$$\begin{cases} \hat{x} = z_1 + K(z_2 - z_1) \\ \sigma^2 = (1 - K)\sigma_1^2 \end{cases} \quad \text{avec } K = \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} \quad \begin{array}{l} \text{le gain} \\ \text{de Kalman} \end{array}$$

# 1. Fusion de mesures

## Remarque:

Dans le *problème de localisation d'un robot* nous avons combiné les deux mesures de distance  $z_1$  et  $z_2$  en utilisant l'équation:

$$\begin{aligned} z &= (1 - w)z_1 + w z_2 \\ &= z_1 + w(z_2 - z_1) \end{aligned}$$

avec le poids optimal:

$$w = \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}$$

On retrouve ainsi la 1<sup>re</sup> equation dans la diapo précédente

# 1. Fusion de mesures

En outre, nous avons vu que:

$$\begin{aligned}\text{Var}[z] &= (1 - w)^2 \sigma_1^2 + w^2 \sigma_2^2 \\ &= \left(1 - \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}\right)^2 \sigma_1^2 + \left(\frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}\right)^2 \sigma_2^2 \\ &= \left(1 - \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}\right) \sigma_1^2 \\ &= (1 - w) \sigma_1^2\end{aligned}$$

qui correspond à la 2<sup>e</sup> equation dans la diapo 4

## 2. Fusion de mesures dans le temps

- Introduisons maintenant la *dimension temporelle*
- Les mesures  $z_1$  et  $z_2$  sont prises de *façon séquentielle*, à savoir nous avons  $z(t_1)$ ,  $z(t_2)$  avec  $t_1 < t_2$

Estimation de l'état optimum à l'instant  $t_2$  :

$$\begin{cases} \hat{x}(t_2) = z(t_1) + K(z(t_2) - z(t_1)) \\ \sigma^2 = (1 - K)\sigma_{z(t_1)}^2 \end{cases}$$

avec

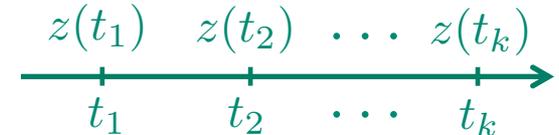
$$K = \frac{\sigma_{z(t_1)}^2}{\sigma_{z(t_1)}^2 + \sigma_{z(t_2)}^2} \quad \text{le gain de Kalman}$$

## 2. Fusion de mesures dans le temps

TD2, Ex. I

Fichier Matlab:  
[MoinCar\\_Rec.m](#)

- Que se passe-t-il, si nous prenons une autre mesure  $z(t_3)$  à l'instant  $t_3 > t_2$ ?



Estimation de l'état optimum à l'instant générique  $t_k$  :

$$\begin{cases} \hat{x}(t_k) = \hat{x}(t_{k-1}) + K(t_{k-1})(z(t_k) - \hat{x}(t_{k-1})) \\ \sigma^2(t_k) = (1 - K(t_{k-1})) \sigma^2(t_{k-1}) \end{cases}$$

←  
*Moyenne  
glissante  
ou mobile*

avec

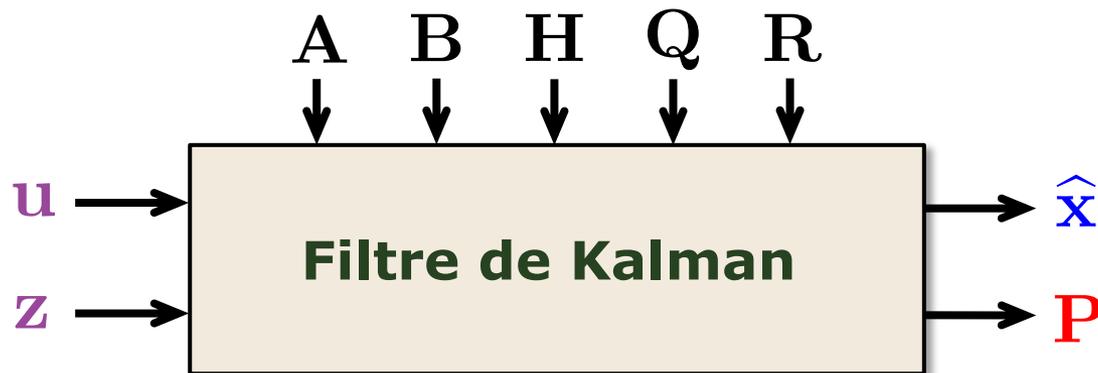
$$K(t_{k-1}) = \frac{\sigma^2(t_{k-1})}{\sigma^2(t_{k-1}) + \sigma_{z(t_k)}^2} \quad \text{le gain de Kalman (variable dans le temps)}$$

### 3. Systèmes dynamiques

Étant donné un *système dynamique linéaire* à temps discret d'état  $x$ :

- Entrée du filtre de Kalman: la commande  $u$  et les mesures  $z$
- Sortie du filtre de Kalman: l'estimation de l'état du système  $\hat{x}$  et la matrice de covariance de l'erreur d'estimation  $P$  associée

Matrices du système dynamique d'état  $x$



# Filtre de Kalman linéaire

- Soit le  *système dynamique à temps discret* ,  $k \in \{1, 2, \dots\}$ :

Équation d'état  $\longrightarrow \mathbf{x}_k = \mathbf{A}_{k-1} \mathbf{x}_{k-1} + \mathbf{B}_{k-1} \mathbf{u}_{k-1} + \mathbf{w}_{k-1}$

Équation de mesure  $\longrightarrow \mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{r}_k$       Entrée de commande (connue)

- Le  *bruit de modèle*   $\mathbf{w}_{k-1}$  et le  *bruit de mesure*   $\mathbf{r}_k$  sont supposés à  *moyenne zéro, blancs*  (sans mémoire) et  *gaussiens*  avec matrices de covariance  $\mathbf{Q}_k$  et  $\mathbf{R}_k$ , respectivement. Les bruits de modèle et de mesure sont supposés aussi  *non corrélés* . En résumé, nous avons:

$$\mathbb{E}[\mathbf{w}_k] = \mathbf{0}$$

$$\mathbb{E}[\mathbf{r}_k] = \mathbf{0}$$

$$\mathbb{E}[\mathbf{w}_k \mathbf{w}_j^T] = \mathbf{0}, j \neq k$$

$$\mathbb{E}[\mathbf{r}_k \mathbf{r}_j^T] = \mathbf{0}, j \neq k$$

$$\mathbb{E}[\mathbf{w}_k \mathbf{w}_k^T] = \mathbf{Q}_k$$

$$\mathbb{E}[\mathbf{r}_k \mathbf{r}_k^T] = \mathbf{R}_k$$

$$\mathbb{E}[\mathbf{r}_k \mathbf{w}_j^T] = \mathbf{0}, \forall j, k$$

# Filtre de Kalman linéaire

- Le filtre de Kalman linéaire à temps discret est un *estimateur récursif*

Pour estimer l'état courant  $\mathbf{x}_k$ , on a besoin *uniquement* de connaître l'estimé de l'état précédent et les mesures courantes: l'historique des mesures et des estimés n'est pas nécessaire

- L' « état » du filtre se compose de *deux variables*:

1.  $\hat{\mathbf{x}}_{k|k}$  : estimé de l'état du système  $\mathbf{x}_k$  à l'instant  $k$ , en utilisant l'information jusqu'à l'instant  $k$

2.  $\mathbf{P}_{k|k} = \mathbb{E}[\underbrace{(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k})(\mathbf{x}_k - \hat{\mathbf{x}}_{k|k})^T}_{\tilde{\mathbf{x}}_{k|k}}]$  : matrice de covariance de l'erreur d'estimation de l'état à l'instant  $k$ , en utilisant l'information jusqu'à l'instant  $k$

Erreur d'estimation de l'état  $\mathbf{x}_k$  du système

# Filtre de Kalman linéaire

## Initialisation du filtre:

$\hat{\mathbf{x}}_{0|0} = \mathbb{E}[\mathbf{x}_0]$  où  $\mathbf{x}_0 \in \mathbb{R}^n$  est l'état initial du système

$$\mathbf{P}_{0|0} = \mathbb{E}[(\mathbf{x}_0 - \hat{\mathbf{x}}_{0|0})(\mathbf{x}_0 - \hat{\mathbf{x}}_{0|0})^T] \in \mathbb{R}^{n \times n}$$

---

Pour  $k \in \{1, 2, \dots\}$ :

## Prédiction (ou propagation):

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{A}_{k-1} \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{B}_{k-1} \mathbf{u}_{k-1}$$

$$\mathbf{P}_{k|k-1} = \mathbf{A}_{k-1} \mathbf{P}_{k-1|k-1} \mathbf{A}_{k-1}^T + \mathbf{Q}_{k-1}$$

# Filtre de Kalman linéaire

## Correction (ou mise à jour):

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1})$$

$$\mathbf{P}_{k|k} = (\mathbf{P}_{k|k-1}^{-1} + \mathbf{H}_k^T \mathbf{R}_k^{-1} \mathbf{H}_k)^{-1} = (\mathbf{I}_n - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1}$$

avec

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \quad \text{le gain de Kalman}$$

---

## Remarque:

$\mathbf{P}_{k|k-1}$  est dite la matrice d'estimation *a priori* de la covariance de l'erreur

$\mathbf{P}_{k|k}$  est dite la matrice d'estimation *a posteriori* de la covariance de l'erreur

# Filtre de Kalman étendu (EKF)

- Soit le système dynamique *non linéaire* à temps discret,  $k \in \{1, 2, \dots\}$  :

Équation d'état  $\longrightarrow \mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}) + \mathbf{w}_{k-1}$

Équation de mesure  $\longrightarrow \mathbf{z}_k = \mathbf{h}(\mathbf{x}_k) + \mathbf{r}_k$  Entrée de commande (*connue*)

où  $\mathbf{f}(\cdot, \cdot)$  et  $\mathbf{h}(\cdot)$  sont deux fonctions différentiables génériques

- Comme pour le filtre de Kalman linéaire:

Le **bruit de modèle**  $\mathbf{w}_{k-1}$  et le **bruit de mesure**  $\mathbf{r}_k$  sont supposés *blancs*, à *moyenne zéro*, et *gaussiens* avec matrices de covariance  $\mathbf{Q}_k$  et  $\mathbf{R}_k$ , respectivement. Les bruits de modèle et de mesure sont aussi supposés *non corrélés*

# Filtre de Kalman étendu (EKF)

## Initialisation du filtre:

$\hat{\mathbf{x}}_{0|0} = \mathbb{E}[\mathbf{x}_0]$  où  $\mathbf{x}_0 \in \mathbb{R}^n$  est l'état initial du système

$$\mathbf{P}_{0|0} = \mathbb{E}[(\mathbf{x}_0 - \hat{\mathbf{x}}_{0|0})(\mathbf{x}_0 - \hat{\mathbf{x}}_{0|0})^T]$$

---

Pour  $k \in \{1, 2, \dots\}$ :

## Phase de prédiction:

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{f}(\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_{k-1})$$

$$\mathbf{P}_{k|k-1} = \mathbf{F}_{k-1} \mathbf{P}_{k-1|k-1} \mathbf{F}_{k-1}^T + \mathbf{Q}_{k-1}$$

avec

$$\mathbf{F}_{k-1} = \left. \frac{\partial \mathbf{f}(\mathbf{x}, \mathbf{u}_{k-1})}{\partial \mathbf{x}} \right|_{\mathbf{x} = \hat{\mathbf{x}}_{k-1|k-1}}$$

- Matrice jacobienne de la fonction  $\mathbf{f}$
- On a considéré ici le développement en série de Taylor à l'ordre 1 de  $\mathbf{f}$  en  $\hat{\mathbf{x}}_{k-1|k-1}$

# Filtre de Kalman étendu (EKF)

## Phase de correction:

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{z}_k - \mathbf{h}(\hat{\mathbf{x}}_{k|k-1}))$$

$$\mathbf{P}_{k|k} = (\mathbf{P}_{k|k-1}^{-1} + \mathbf{H}_k^T \mathbf{R}_k^{-1} \mathbf{H}_k)^{-1}$$

avec

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \text{ le gain de Kalman}$$

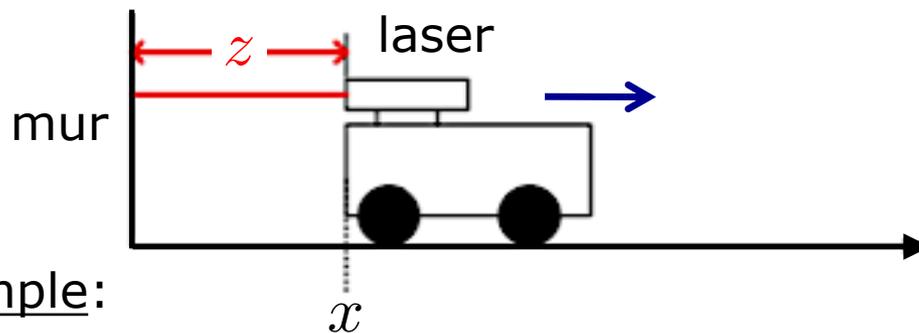
et

$$\mathbf{H}_k = \left. \frac{\partial \mathbf{h}(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x} = \hat{\mathbf{x}}_{k|k-1}}$$

- Matrice jacobienne de la fonction  $\mathbf{h}$
- On a considéré ici le développement en série de Taylor à l'ordre 1 de  $\mathbf{h}$  en  $\hat{\mathbf{x}}_{k|k-1}$

# Exemple I : une variable d'état

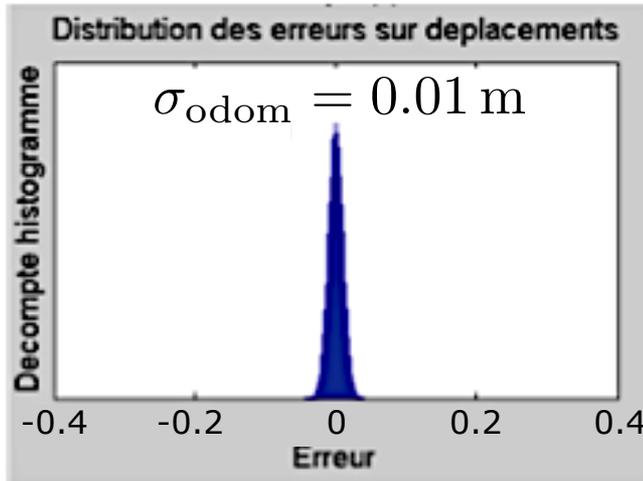
- Un **chariot à roues encodeuses** avance pas-à-pas
- Un **laser** mesure la distance du chariot par rapport à un mur



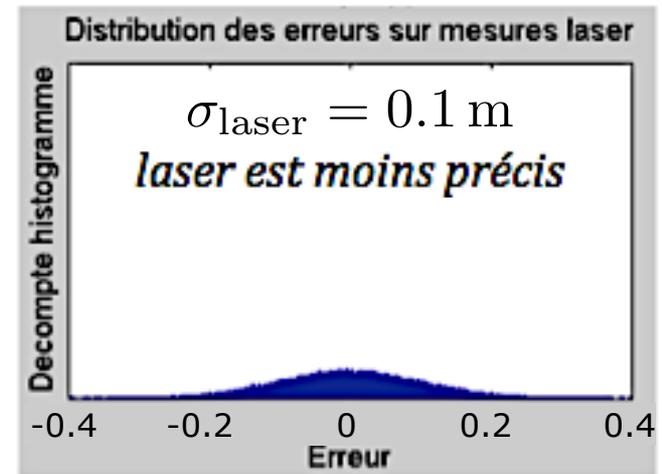
Une variable d'état:  
la **position**  $x$  du chariot

Exemple:

*Note : l'odométrie est souvent une mesure localement très précise, mais dérive.*



Odométrie



Laser

## Exemple I : une variable d'état

Dans cet exemple, nous avons que (cf. la forme générale d'un système dynamique à temps discret, vue précédemment):

$$\mathbf{x}_k = x_k, \mathbf{u}_{k-1} = u_{k-1} = V \Delta k, \mathbf{w}_{k-1} = w_{k-1}, \mathbf{z}_k = z_k, \mathbf{r}_k = r_k$$

$$\mathbf{A}_{k-1} = 1, \mathbf{B}_{k-1} = 1, \mathbf{Q}_k = \sigma_{\text{odom}}^2, \mathbf{H}_k = 1, \mathbf{R}_k = \sigma_{\text{laser}}^2$$

où  $\Delta k$  est le pas de discrétisation (fixe) et  $V$  est la vitesse moyenne du chariot dans cet intervalle de temps

Donc, en conclusion:

Équation d'état:

$$x_k = x_{k-1} + V \Delta k + w_{k-1}$$

Équation de mesure:

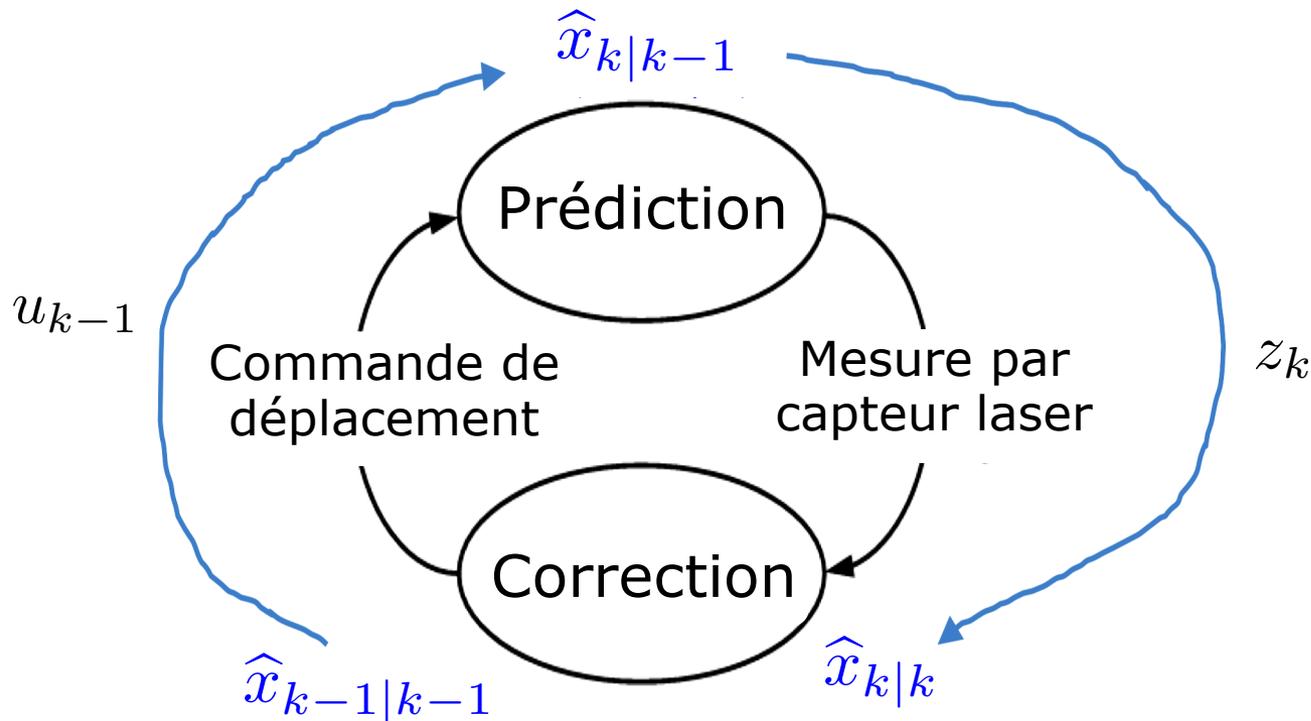
$$z_k = x_k + r_k$$

# Exemple I : une variable d'état

$\hat{x}_{k-1|k-1}$  : estimé de la position du robot **avant** le déplacement

$\hat{x}_{k|k-1}$  : estimé de la position du robot **après** le déplacement  
 $u_{k-1}$  et **avant** la mesure  $z_k$

$\hat{x}_{k|k}$  : estimé de la position du robot **après** la mesure  $z_k$



# Exemple I : une variable d'état

Fichier Matlab (TD2):  
[FiltreKalmanChariot.m](http://FiltreKalmanChariot.m)

Les équations du filtre de Kalman sont alors:

## Prédiction:

$$\hat{x}_{k|k-1} = \hat{x}_{k-1|k-1} + V \Delta k$$

$$P_{k|k-1} = P_{k-1|k-1} + \sigma_{\text{odom}}^2$$

## Correction:

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k (z_k - \hat{x}_{k|k-1})$$

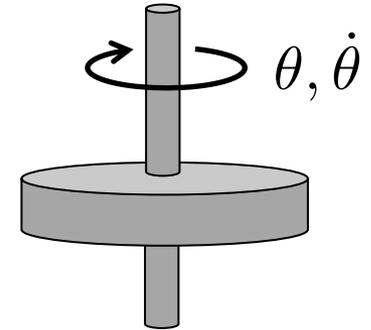
$$P_{k|k} = (1 - K_k) P_{k|k-1}$$

avec

$$K_k = P_{k|k-1} (P_{k|k-1} + R_k)^{-1} = \frac{P_{k|k-1}}{P_{k|k-1} + \sigma_{\text{laser}}^2}$$

## Exemple II : deux variables d'état

Un **gyroscope** et un **compas magnétique** sont placés sur un plateau rotatif



Le plateau tourne librement autour de son axe vertical

- Les mesures de *vitesse* fournies par le gyroscope sont entachées par un bruit blanc gaussien:

$$\mathcal{N}(\mu_{\text{gyro}}, \sigma_{\text{gyro}}^2) = \mathcal{N}(0.1, 0.2^2) \text{ deg/s} \quad (\text{avec biais})$$

- Les mesures de *position* fournies par le compas sont aussi entachées par un bruit blanc gaussien:

$$\mathcal{N}(\mu_{\text{comp}}, \sigma_{\text{comp}}^2) = \mathcal{N}(0, 10^2) \text{ deg} \quad (\text{sans biais})$$

- Les deux mesures sont supposées *non corrélées*

## Exemple II : deux variables d'état

**Objectif:** fusionner ensemble les deux mesures

- Les mesures du gyroscope (capteur proprioceptif) sont précises, mais elles **dérivent** (cf. l'odométrie dans l'Exemple I)
- Les mesures du compas (capteur extéroceptif) **ne dérivent pas**, mais elles sont fortement bruitées

On peut donc conclure que:

- Les mesures du gyroscope sont "*bonnes*" à **court terme**
- Les mesures du compas sont "*bonnes*" à **long terme**

## Exemple II : deux variables d'état

- L'état du système consiste en la position et en la vitesse angulaire du plateau:

$$\mathbf{x} = \begin{bmatrix} \theta \\ \dot{\theta} \end{bmatrix}$$

- Étant un capteur proprioceptif, les mesures du gyroscope équivalent à une commande:  $u_k = \dot{\theta}_{\text{gyro}}(k)$ . On peut donc définir le système dynamique suivant:

$$\mathbf{x}_k = \underbrace{\begin{bmatrix} 1 & \Delta k \\ 0 & 0 \end{bmatrix}}_{\mathbf{A}} \mathbf{x}_{k-1} + \underbrace{\begin{bmatrix} 0 \\ 1 \end{bmatrix}}_{\mathbf{B}} u_{k-1} + \mathbf{w}_{k-1} \quad (\text{I})$$

où  $\Delta k$  est le pas de discrétisation (fixe) et Surestime, afin de prendre en compte le biais

$$\mathbb{E}[\mathbf{w}_k] = [0, \mu_{\text{gyro}}]^T, \quad \mathbf{Q} = \mathbb{E}[\mathbf{w}_k \mathbf{w}_k^T] = \text{diag}(0, \overbrace{16 \sigma_{\text{gyro}}^2})$$

## Exemple II : deux variables d'état

- Les "vraies mesures" sont effectuées uniquement par le compas (capteur extéroceptif)
- En d'autres termes, nous ne voulons pas que le gyroscope intervienne dans la phase de correction du filtre de Kalman. Donc, on peut définir simplement:

$$z_k = \overbrace{[1 \quad 0]}^{\mathbf{H}} \mathbf{x}_k + r_k \quad (\text{II})$$

avec

$$\mathbb{E}[r_k] = \mu_{\text{comp}} = 0, \quad R = \mathbb{E}[r_k^2] = \sigma_{\text{comp}}^2$$

Grâce à l'équation d'état (I) et de mesure (II) ainsi trouvées, nous pouvons écrire les équations du filtre de Kalman pour la fusion des mesures du gyroscope et du compas

## Exemple II : deux variables d'état

Les équations du filtre de Kalman sont:

Fichier Matlab (TD2):  
[FiltreKalmanGyroCompas.m](#)

### Prédiction:

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{A} \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{B} u_{k-1}$$

$$\mathbf{P}_{k|k-1} = \mathbf{A} \mathbf{P}_{k-1|k-1} \mathbf{A}^T + \text{diag}(0, 16 \sigma_{\text{gyro}}^2)$$

### Correction:

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (z_k - \mathbf{H} \hat{\mathbf{x}}_{k|k-1})$$

$$\mathbf{P}_{k|k} = (\mathbf{I}_2 - \mathbf{K}_k \mathbf{H}) \mathbf{P}_{k|k-1}$$

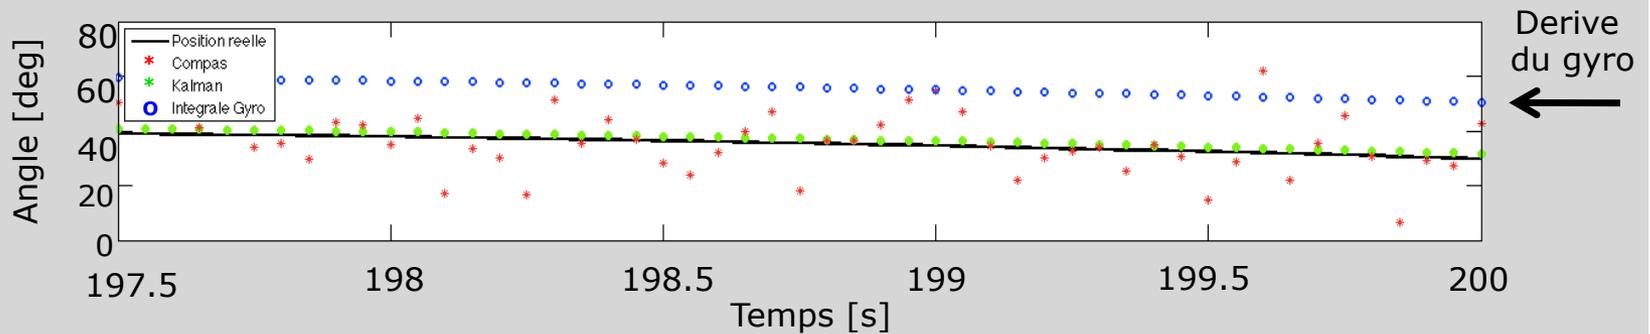
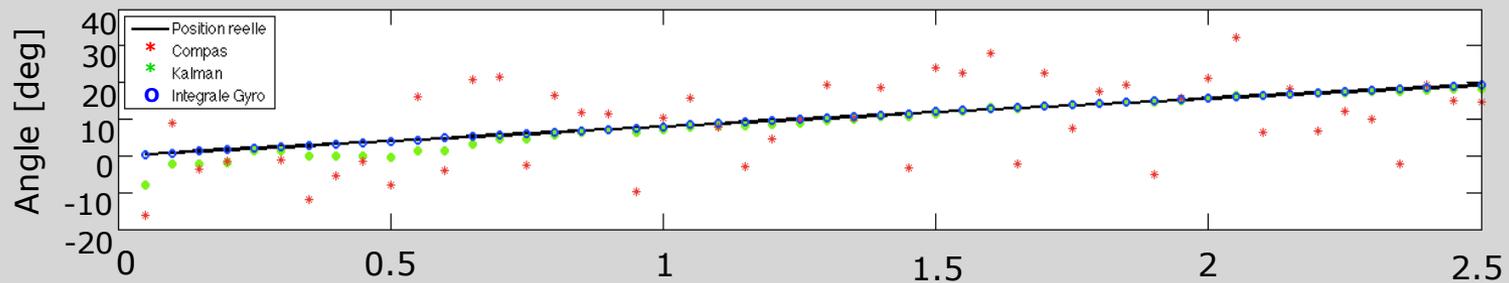
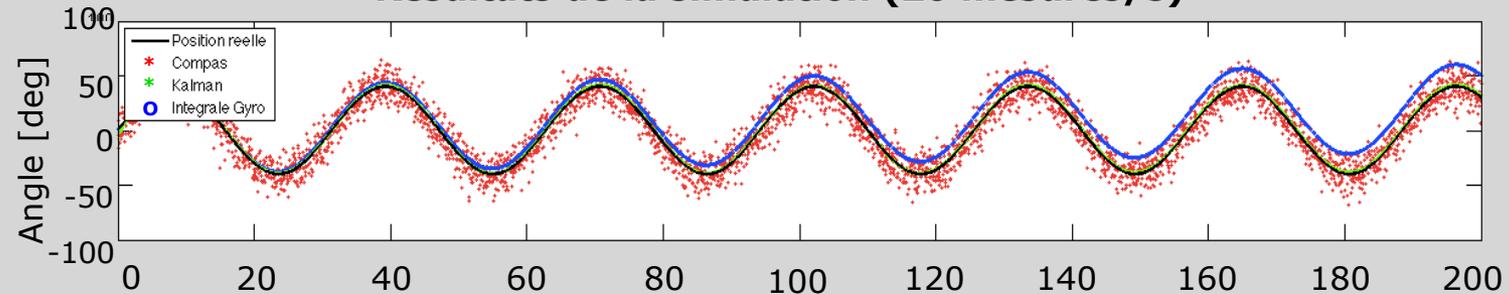
avec

$$\mathbf{K}_k = \frac{\mathbf{P}_{k|k-1} \mathbf{H}^T}{\mathbf{H} \mathbf{P}_{k|k-1} \mathbf{H}^T + \sigma_{\text{comp}}^2} \quad (\text{vecteur } 2 \times 1)$$

# Exemple II : simulation

- Position angulaire réelle  $\theta$  du plateau
- Compas
- Estim. Kalman
- Intégrale des mesures du gyroscope

Résultats de la simulation (20 mesures/s)

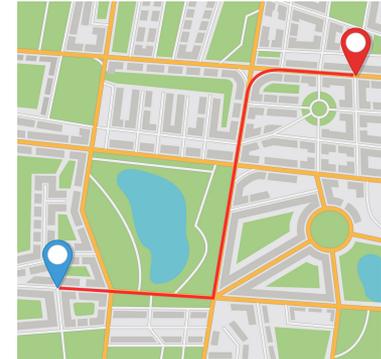


# Exemple III : navigation par fusion INS/GNSS

## Système de navigation inertielle (INS) pour une voiture

- Avantages:

- Autonome
- Grande précision pour une navigation à court terme



- Inconvénient majeur:

L'erreur de positionnement augmente sans cesse au fil du temps, à cause de l'accumulation des erreurs du gyroscope et de l'accéléromètre avec le temps (entre autres)

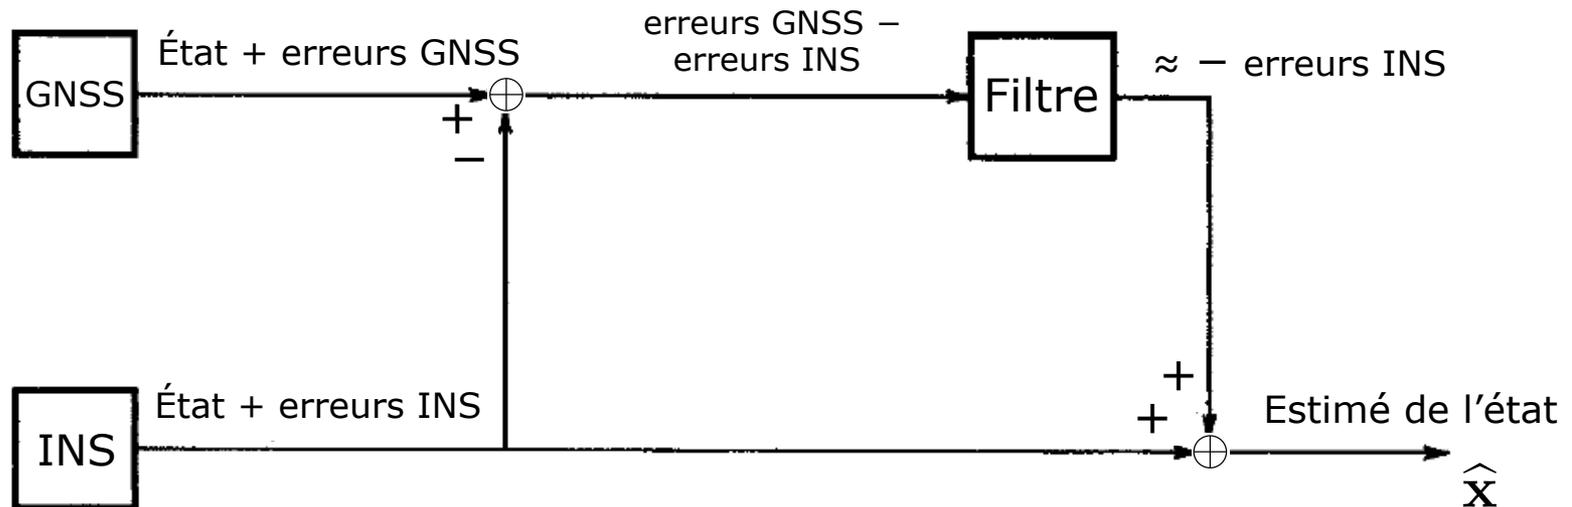
Pour cette raison, pour une navigation à long terme, un INS est souvent couplé avec un  *système d'aide à la navigation* , par exemple:

- Système de radio-navigation (ex. LORAN, OMEGA, TACAN)
- Système de navigation par satellites ou GNSS (ex. GPS, GLONASS)

*"Inertial Measurement Unit Error Modeling Tutorial: Inertial Navigation System State Estimation with Real-Time Sensor Calibration"*, J.A. Farrell, F.O. Silva, F. Rahman, J. Wendel, IEEE Control Syst. Mag., vol. 42, n. 6, pp. 40-66, 2022

## Exemple III : navigation par fusion INS/GNSS

- L'intégration INS/GNSS est souvent réalisée grâce à un **filtre complémentaire**
- Le *filtre de Kalman* (étendu) peut être utilisé dans certains schémas de filtrage complémentaire



Architecture en *boucle ouvert* pour la fusion INS/GNSS basée sur le filtre de Kalman

Pour plus de détails, voir la Sect. 12.10 du livre de Bar-Shalom *et al.*

## Exemple IV : Projet ANR CityVIP (2009-2011)

*“Déplacement sûr de véhicules individuels adaptés à l’environnement urbain”* (source: D. Bétaille, IFSTTAR)

### Problématique de la géolocalisation en ville

- Le milieu urbain cumule:
  - l’intérêt d’un positionnement précis et intègre
  - mais plusieurs difficultés ...
  - pour le positionnement GNSS:
    - les masquages de satellites
    - les trajets multiples
  - pour le positionnement par traitement de vidéos:
    - les problèmes d’ombres et d’éblouissements
    - les problèmes de réflexions

Mais le milieu urbain est fortement structuré et la connaissance d’une **carte** est d’un précieux secours

## Exemple IV : Projet ANR CityVIP (2009-2011)

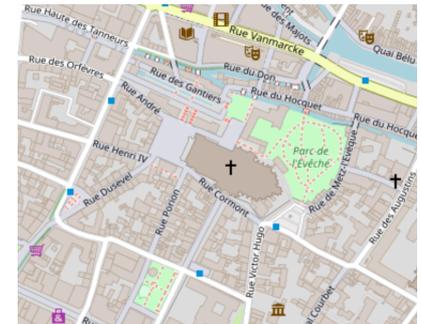
### Objectifs du projet CityVIP

- Développer un système de localisation adapté aux véhicules urbains:
    - *précis* (erreur inférieure à 1 m à 95%)
    - *intègre* (estimation sûre d'un majorant de l'erreur)
    - *bas coût* (utilisation de capteurs bas de gamme)
  - Le système de localisation exploite:
    - un récepteur GPS bas de gamme (*u-blox*)
    - les codeurs CAN des roues arrière du véhicule
    - une caméra vidéo N&B standard (*Marlin*)
    - une carte numérique 3D précise d'un centre urbain
- ... et on tire le meilleur parti de toutes ces sources d'information (fusion)

# Exemple IV : Projet ANR CityVIP (2009-2011)

## Coopération des modules actualisant la pose

- Intégration de *mesures proprioceptives* (odométrie)
- Mise en correspondance avec la carte numérique 3D (« map matching »)
- Utilisation de *données satellitaires* en couplage lâche ou serré:
  - ⇒ Test préalable de validité
    - ✓ Force du signal
    - ✓ Visibilité directe
- Fusion avec la localisation par *vision*



# Exemple IV : Projet ANR CityVIP (2009-2011)

## Modèle du véhicule

- Pose du véhicule dans le repère ENU (East-North-Up):

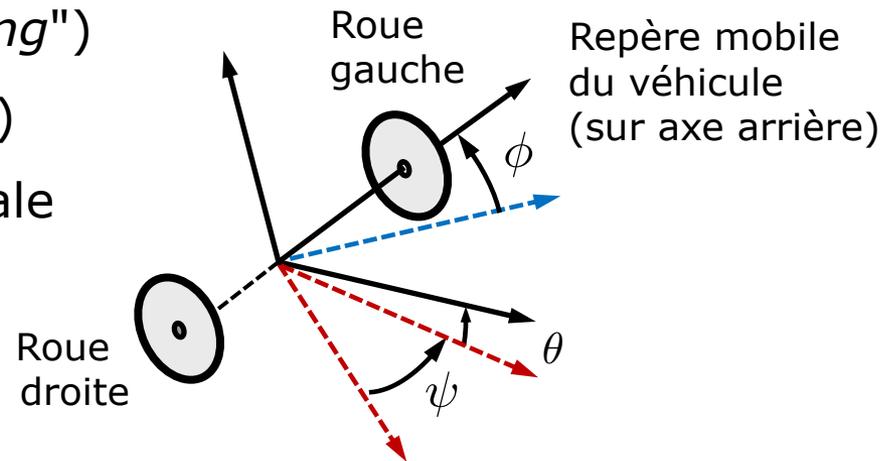
$$\mathbf{x} = [x, y, z, \psi, \theta, \phi]^T$$

$(x, y, z)$  : coordonnées du point central de l'essieu arrière

$\psi$  : angle de cap ("*heading*")

$\theta$  : inclinaison (de la rue)

$\phi$  : inclinaison transversale  
(de la rue)



"About non-line-of-sight satellite detection and exclusion in a 3D map-aided localization algorithm", S. Peyraud, D. Bétaille, S. Renault, M. Ortiz, F. Mougel, D. Meizel, F. Peyret, Sensors, vol. 13, n. 1, pp. 829-847, 2013

## Exemple IV : Projet ANR CityVIP (2009-2011)

### Modèle du véhicule

- Modèle cinématique du véhicule (*non linéaire* à temps continu):

$$\dot{\mathbf{x}} = \mathbf{G}(\mathbf{x})\mathbf{u}, \quad \mathbf{G}(\mathbf{x}) = \begin{bmatrix} \cos \psi \cos \theta & 0 \\ \sin \psi \cos \theta & 0 \\ -\sin \theta & 0 \\ 0 & \frac{\cos \phi}{\cos \theta} \\ 0 & -\sin \phi \\ 0 & \tan \theta \cos \phi \end{bmatrix}$$

où  $\mathbf{u} = [v, \omega]^T$  est l'entrée du système (connue à partir des mesures odométriques): la vitesse longitudinale  $v$  et la vitesse angulaire  $\omega$  du véhicule

- Ce modèle est discrétisé (méthode d'Euler explicite)

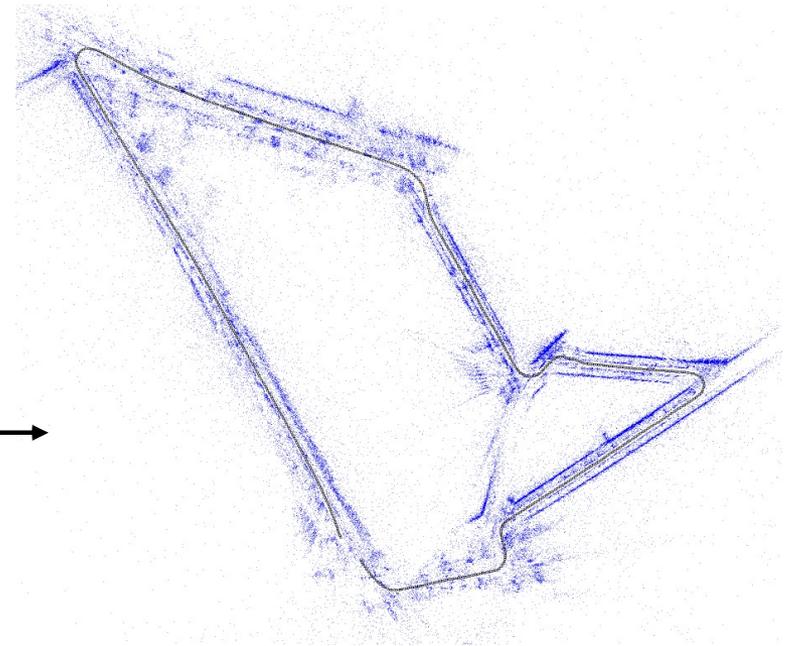
# Exemple IV : Projet ANR CityVIP (2009-2011)

## Localisation par vision: construction de la base d'amers visuels (*hors ligne*)



Séquence vidéo de référence

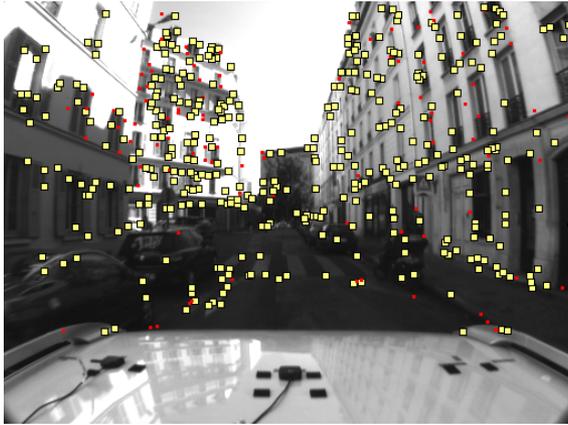
Trajectoire de référence



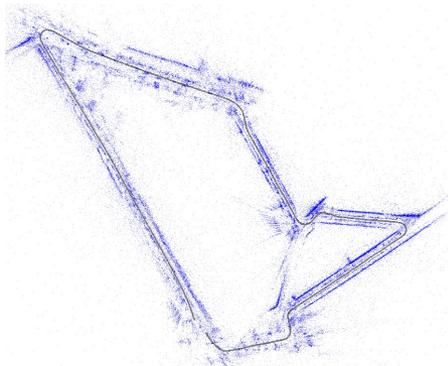
Base d'amers visuels  
géo-référencés (points  
3D + descripteurs  
associés)

# Exemple IV : Projet ANR CityVIP (2009-2011)

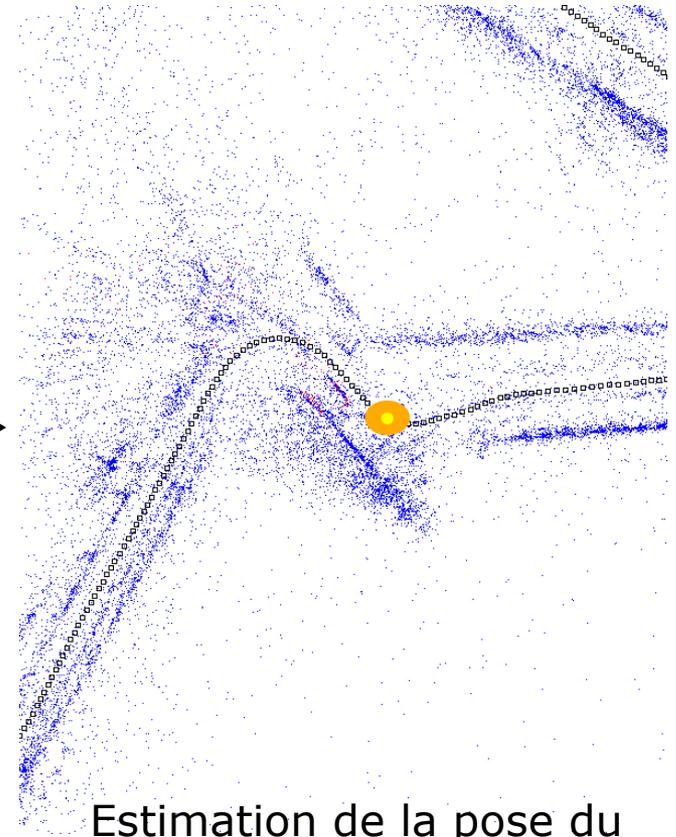
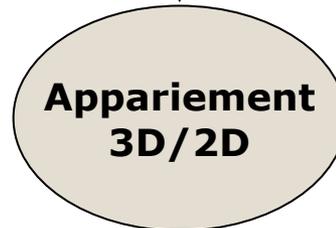
## Localisation par vision: exécution *en temps réel*



Points d'intérêt sur l'image courante (points jaunes)



Base d'amers visuels géo-référencés



Estimation de la pose du véhicule et incertitude associée (ellipse jaune)

# Exemple IV : Projet ANR CityVIP (2009-2011)

## Intégration dans le véhicule « VERT »

Mesure de  
référence des  
trajectoires



Baie d'acquisition  
(RT-Maps, Aroccam)

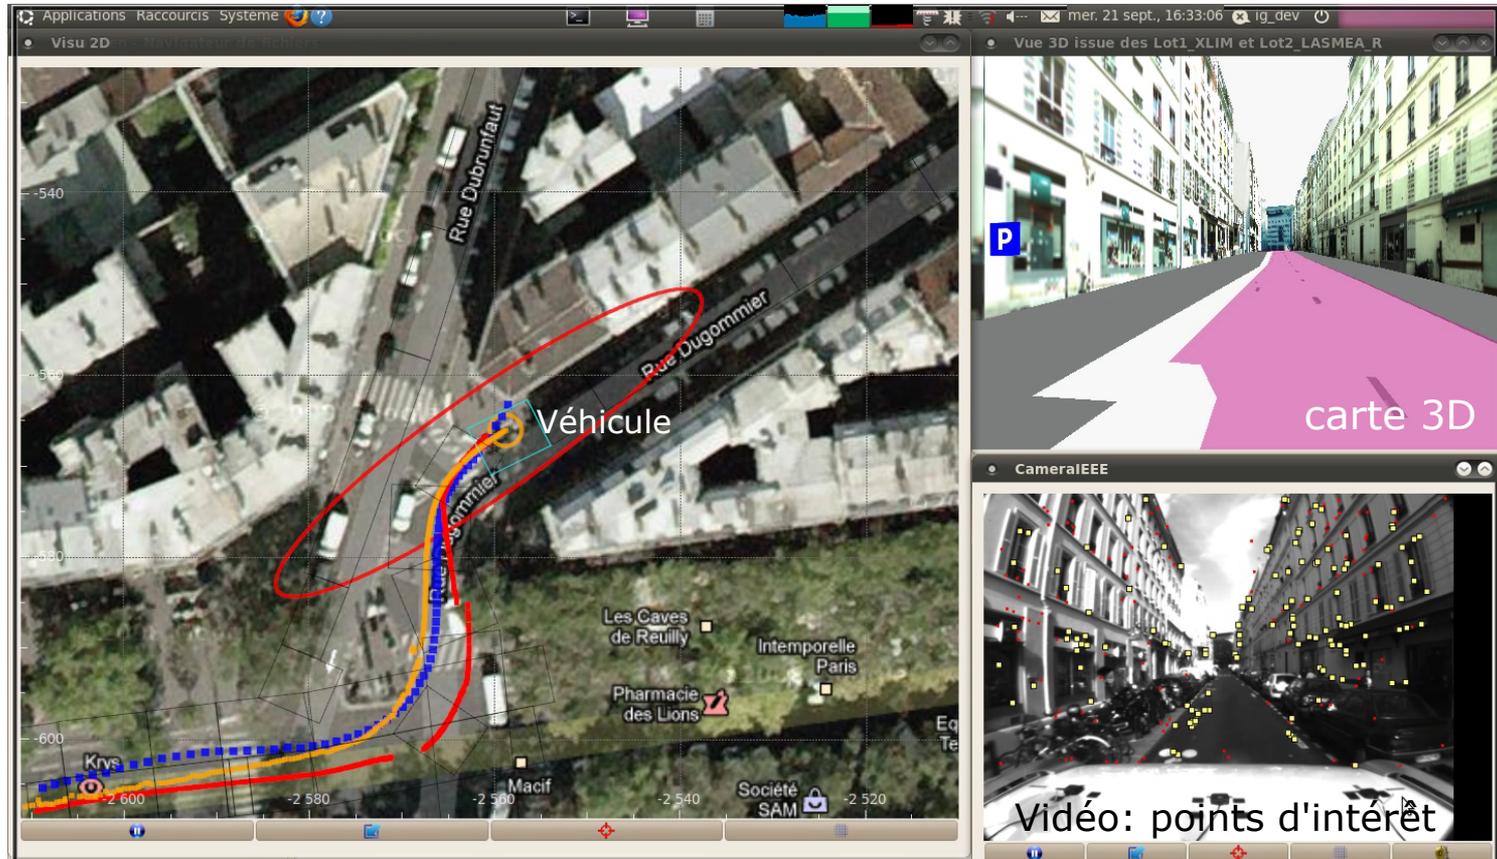


Récepteur GPS  
bas coût

Codeurs  
de roues

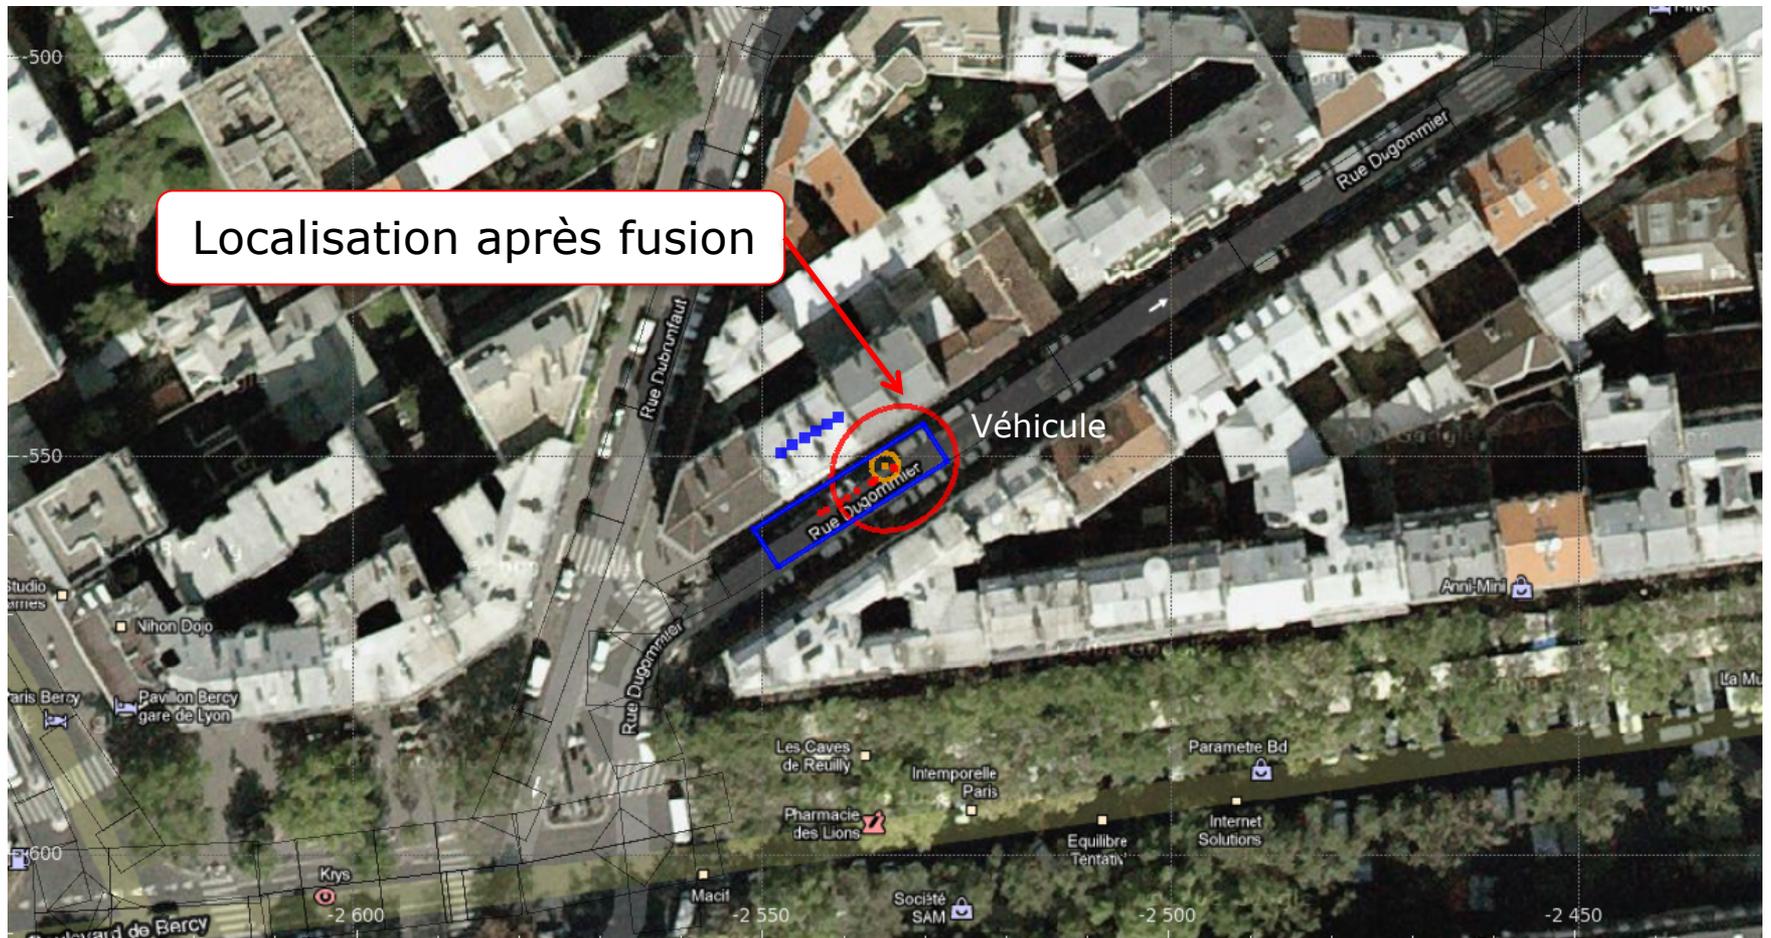


# Exemple IV : Projet ANR CityVIP (2009-2011)



**Résultats:** localisation globale par fusion multi-capteurs et carte 3D

## Exemple IV : Projet ANR CityVIP (2009-2011)



**Résultats:** localisation globale par fusion multi-capteurs et carte 3D  
lot 1 (carte) / lot 2 (vision)