

SLAM Monocular en Entornos Grandes

Juan Domingo Tardós Solano
Septiembre 2007

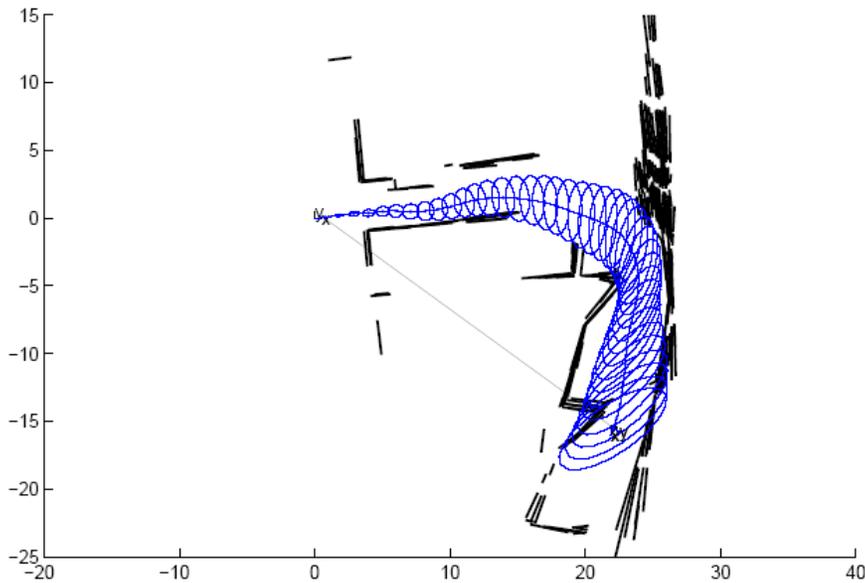
Trabajo conjunto con: José Neira, Pedro Piniés,
Laura Clemente, Andrew Davison e Ian Reid

Índice

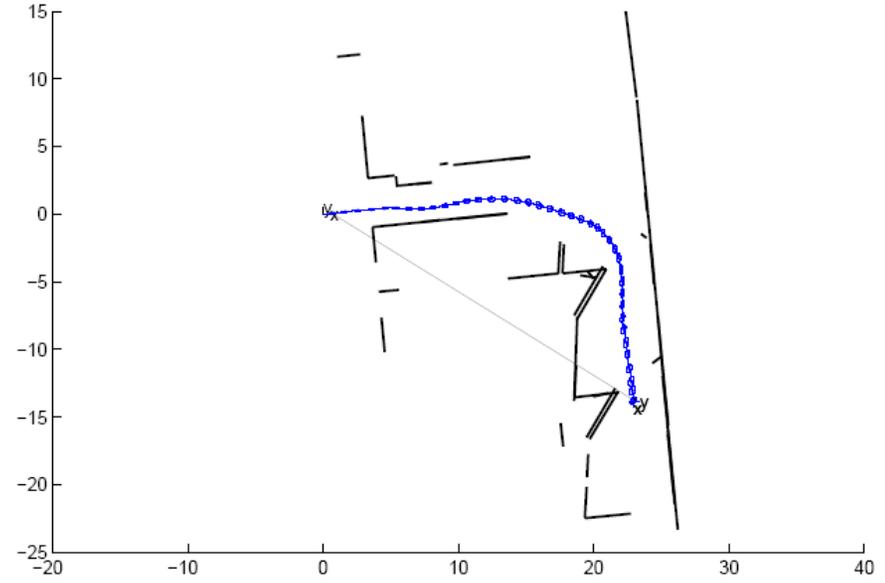
1. Introducción
2. SLAM en entornos grandes
 - Mapas locales
 - CI-SLAM: Mapas Condicionalmente Independientes
 - Caso Gaussiano con covarianzas
 - Exploración y cerrado de bucles
3. Aplicación al SLAM monocular
 - Representación
 - Asociación de datos
 - Cerrado de bucles
 - Resultados experimentales
4. Conclusiones y trabajo futuro

SLAM: Simultaneous Localization and Mapping

- Construir un mapa del entorno, incrementalmente
- Mientras se usa el mapa para localizar el robot



Construcción de mapas con odometría



SLAM

- EKF-SLAM: mapa estocástico + Filtro de Kalman Extendido (EKF)
 - R. Smith, M. Self and P. Cheeseman, “A Stochastic Map for Uncertain Spatial Relationships”, In O. Faugeras and G. Giralt (eds.), Robotics Research, The Fourth Int. Symp., pp. 467-474. The MIT Press, 1988

EKF-SLAM

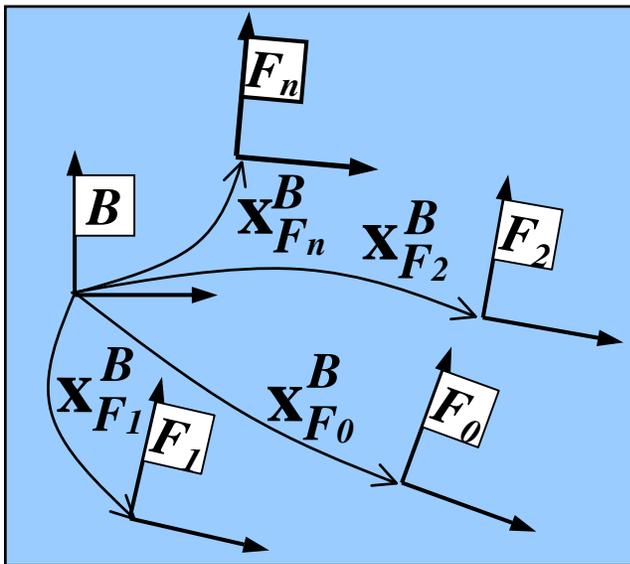
- Información sobre elementos del entorno:

$$\mathcal{F} = \{B, F_0, F_1, \dots, F_n\}$$

$F_0 = \text{Robot}$

- Representada por un mapa estocástico:

$$\mathcal{M}_{\mathcal{F}}^B = (\hat{\mathbf{x}}_{\mathcal{F}}^B, \mathbf{P}_{\mathcal{F}}^B)$$



$$\hat{\mathbf{x}}_{\mathcal{F}}^B = \begin{bmatrix} \hat{\mathbf{x}}_{F_0}^B \\ \vdots \\ \hat{\mathbf{x}}_{F_n}^B \end{bmatrix}$$

$$\mathbf{P}_{\mathcal{F}}^B = \begin{bmatrix} \mathbf{P}_{F_0 F_0}^B & \cdots & \mathbf{P}_{F_0 F_n}^B \\ \vdots & \ddots & \vdots \\ \mathbf{P}_{F_n F_0}^B & \cdots & \mathbf{P}_{F_n F_n}^B \end{bmatrix}$$

Memoria necesaria: $O(n^2)$

EKF-SLAM

Algorithm 1 SLAM:

$$\mathbf{x}_0^B = \mathbf{0}; \mathbf{P}_0^B = \mathbf{0} \{Map\ initialization\}$$

$$[\mathbf{z}_0, \mathbf{R}_0] = \text{get_measurements}$$

$$[\mathbf{x}_0^B, \mathbf{P}_0^B] = \text{add_new_features}(\mathbf{x}_0^B, \mathbf{P}_0^B, \mathbf{z}_0, \mathbf{R}_0)$$

for $k = 1$ to steps do

$$[\mathbf{x}_{R_k}^{R_{k-1}}, \mathbf{Q}_k] = \text{get_odometry}$$

$$[\mathbf{x}_{k|k-1}^B, \mathbf{P}_{k|k-1}^B] = \text{EKF_prediction}(\mathbf{x}_{k-1}^B, \mathbf{P}_{k-1}^B, \mathbf{x}_{R_k}^{R_{k-1}}, \mathbf{Q}_k)$$

$$[\mathbf{z}_k, \mathbf{R}_k] = \text{get_measurements}$$

$$\mathcal{H}_k = \text{data_association}(\mathbf{x}_{k|k-1}^B, \mathbf{P}_{k|k-1}^B, \mathbf{z}_k, \mathbf{R}_k)$$

$$[\mathbf{x}_k^B, \mathbf{P}_k^B] = \text{EKF_update}(\mathbf{x}_{k|k-1}^B, \mathbf{P}_{k|k-1}^B, \mathbf{z}_k, \mathbf{R}_k, \mathcal{H}_k)$$

$$[\mathbf{x}_k^B, \mathbf{P}_k^B] = \text{add_new_features}(\mathbf{x}_k^B, \mathbf{P}_k^B, \mathbf{z}_k, \mathbf{R}_k, \mathcal{H}_k)$$

end for



EKF-SLAM: Movimiento del Robot

$$\mathbf{x}_{R_k}^B = \mathbf{x}_{R_{k-1}}^B \oplus \mathbf{x}_{R_k}^{R_{k-1}}$$

Modelo de odometría (ruido blanco):

$$\begin{aligned} \mathbf{x}_{R_k}^{R_{k-1}} &= \hat{\mathbf{x}}_{R_k}^{R_{k-1}} + \mathbf{v}_k \\ E[\mathbf{v}_k] &= \mathbf{0} \\ E[\mathbf{v}_k \mathbf{v}_j^T] &= \delta_{kj} \mathbf{Q}_k \end{aligned}$$

Predicción del EKF:

$$\hat{\mathbf{x}}_{\mathcal{F}_{k|k-1}}^B = \begin{bmatrix} \hat{\mathbf{x}}_{R_{k-1}}^B \oplus \hat{\mathbf{x}}_{R_k}^{R_{k-1}} \\ \hat{\mathbf{x}}_{F_{1,k-1}}^B \\ \vdots \\ \hat{\mathbf{x}}_{F_{m,k-1}}^B \end{bmatrix} \quad \mathbf{F}_k = \begin{bmatrix} \mathbf{J}_{1 \oplus \left\{ \hat{\mathbf{x}}_{R_{k-1}}^B, \hat{\mathbf{x}}_{R_k}^{R_{k-1}} \right\}} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{I} & & \vdots \\ \vdots & & \cdots & \\ \mathbf{0} & & \cdots & \mathbf{I} \\ \mathbf{J}_{2 \oplus \left\{ \hat{\mathbf{x}}_{R_{k-1}}^B, \hat{\mathbf{x}}_{R_k}^{R_{k-1}} \right\}} & & & \end{bmatrix}$$

$$\mathbf{P}_{\mathcal{F}_{k|k-1}}^B = \mathbf{F}_k \mathbf{P}_{\mathcal{F}_{k-1}}^B \mathbf{F}_k^T + \mathbf{G}_k \mathbf{Q}_k \mathbf{G}_k^T \quad \mathbf{G}_k = \begin{bmatrix} \mathbf{0} \\ \vdots \\ \mathbf{0} \end{bmatrix}$$

Linealización

EKF-SLAM: Actualización

Ecuación de medida:

$$\mathbf{z}_k = \mathbf{h}_k(\mathbf{x}_{\mathcal{F}_k}^B) + \mathbf{w}_k$$

$$\mathbf{h}_k(\mathbf{x}_{\mathcal{F}_k}^B) \simeq \mathbf{h}_k(\hat{\mathbf{x}}_{\mathcal{F}_{k|k-1}}^B) + \mathbf{H}_k(\mathbf{x}_{\mathcal{F}_k}^B - \hat{\mathbf{x}}_{\mathcal{F}_{k|k-1}}^B)$$

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

Linealización

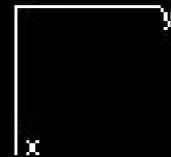
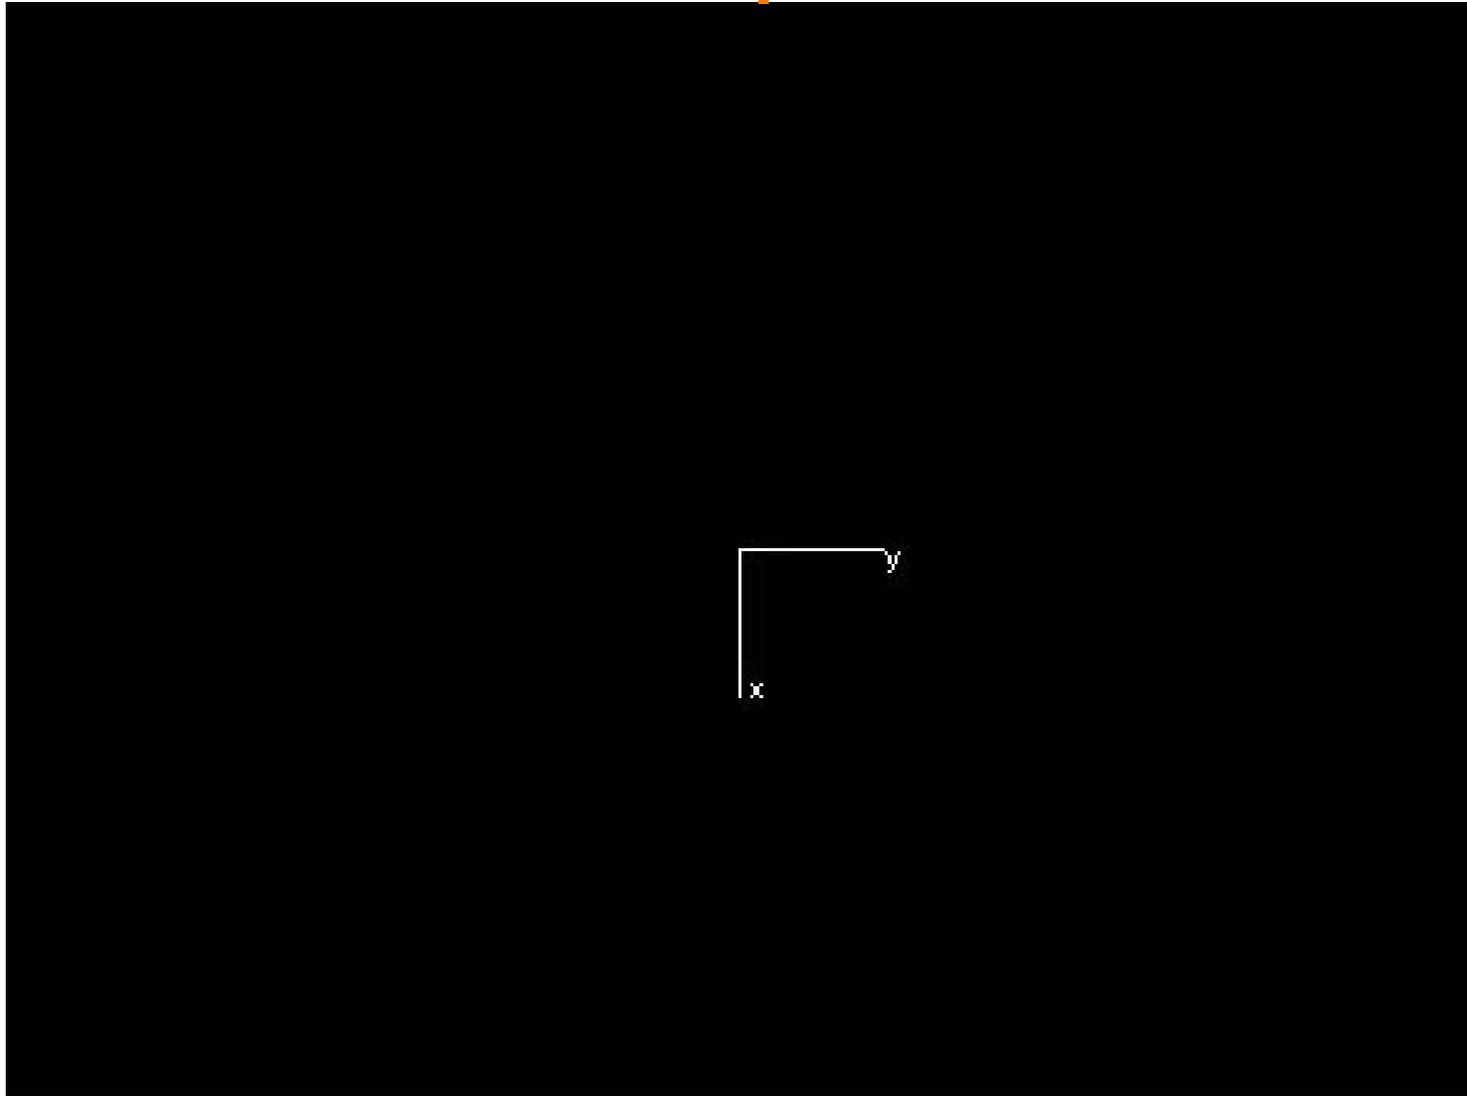
Actualización del EKF:

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

$O(n^2)$  $\mathbf{P}_{\mathcal{F}_k}^B = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{\mathcal{F}_{k|k-1}}^B$

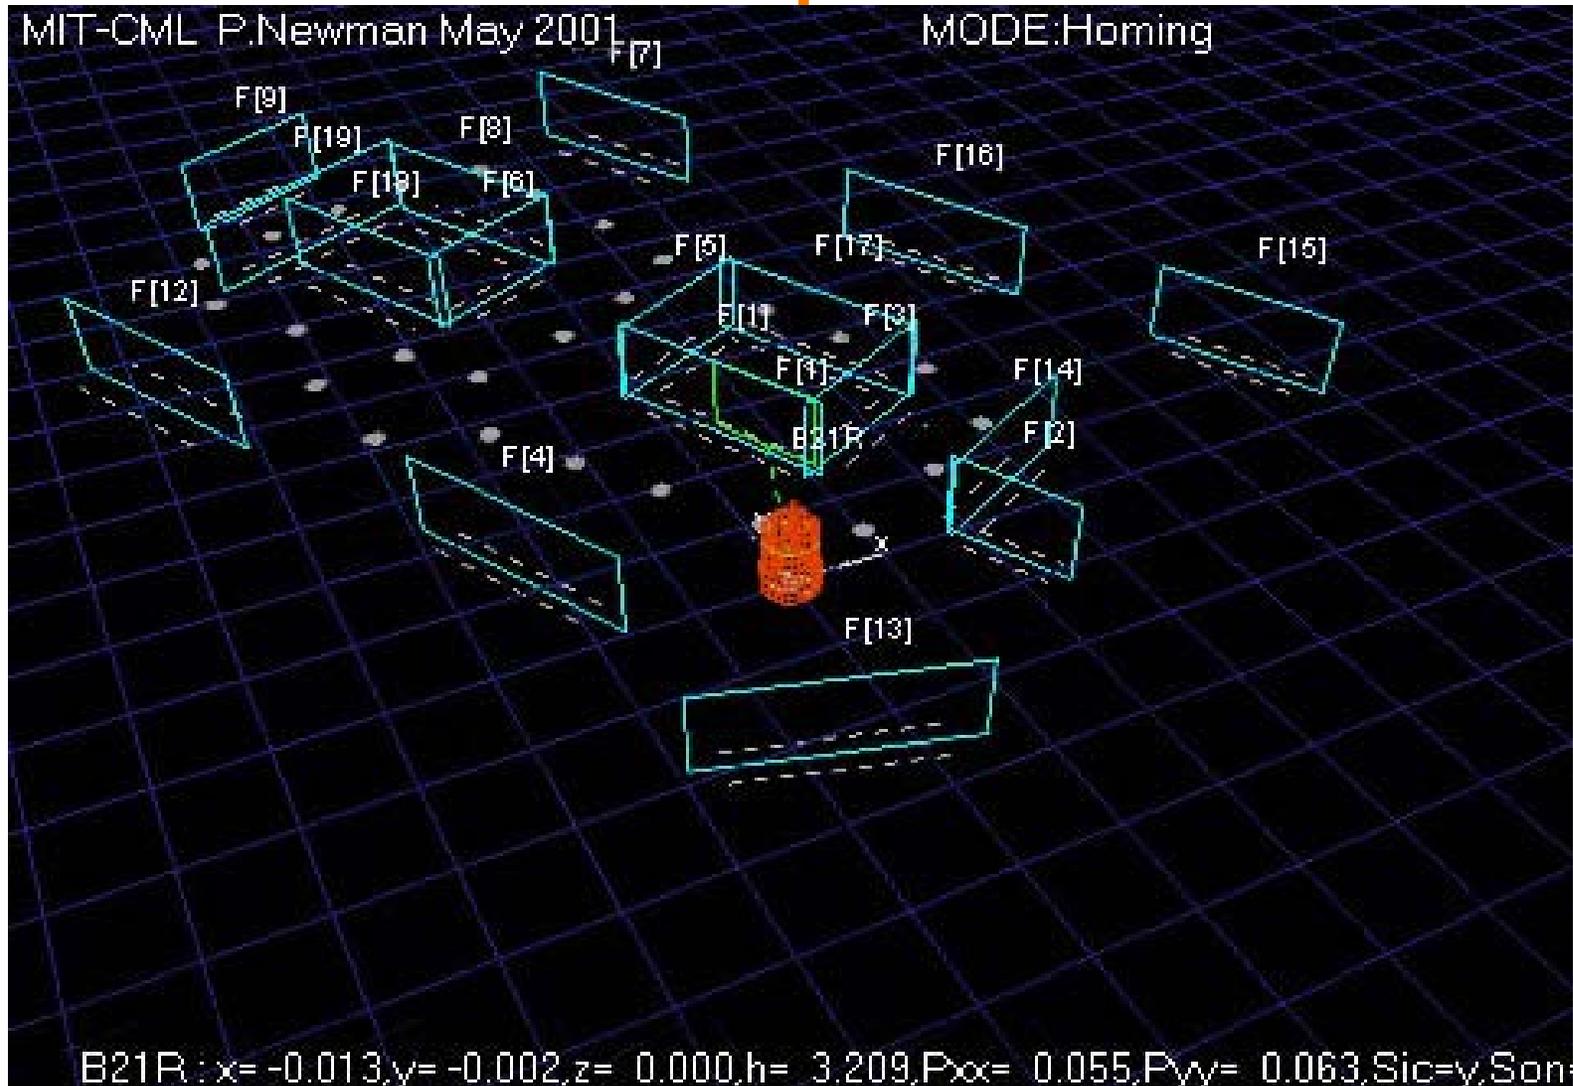
$$\mathbf{K}_k = \mathbf{P}_{\mathcal{F}_{k|k-1}}^B \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_{\mathcal{F}_{k|k-1}}^B \mathbf{H}_k^T + \mathbf{R}_k)^{-1}$$

EKF-SLAM en Tiempo Real con Láser



P. M. Newman, J. J. Leonard, J. Neira and J.D. Tardós: Explore and Return: Experimental Validation of Real Time Concurrent Mapping and Localization. IEEE Int. Conf. Robotics and Automation, May 2002.

EKF-SLAM en Tiempo Real con Láser



P. M. Newman, J. J. Leonard, J. Neira and J.D. Tardós: Explore and Return: Experimental Validation of Real Time Concurrent Mapping and Localization. IEEE Int. Conf. Robotics and Automation, May 2002.

ROBOT 2001, Universidad de Zaragoza, Zaragoza, Sept 2001

Estado del arte en SLAM

- Resuelto en entornos de interior medios, con láser o ultrasonidos Castellanos et al., 1999
Tardós et al., 2002
- SLAM con visión en 2D Castellanos et al., 2001
- Entornos grandes Estrada et al., 2005
 - Cerrado de bucles grandes ←
 - Eficiencia computacional
- Entornos complejos ←
 - Entornos dinámicos
 - Entornos de exterior
- SLAM con visión en 3D ←

Índice

1. Introducción
2. SLAM en entornos grandes
 - Mapas locales
 - CI-SLAM: Mapas Condicionalmente Independientes
 - Caso Gaussiano con covarianzas
 - Exploración y cerrado de bucles
3. Aplicación al SLAM monocular
 - Representación
 - Asociación de datos
 - Cerrado de bucles
 - Resultados experimentales
4. Conclusiones y trabajo futuro

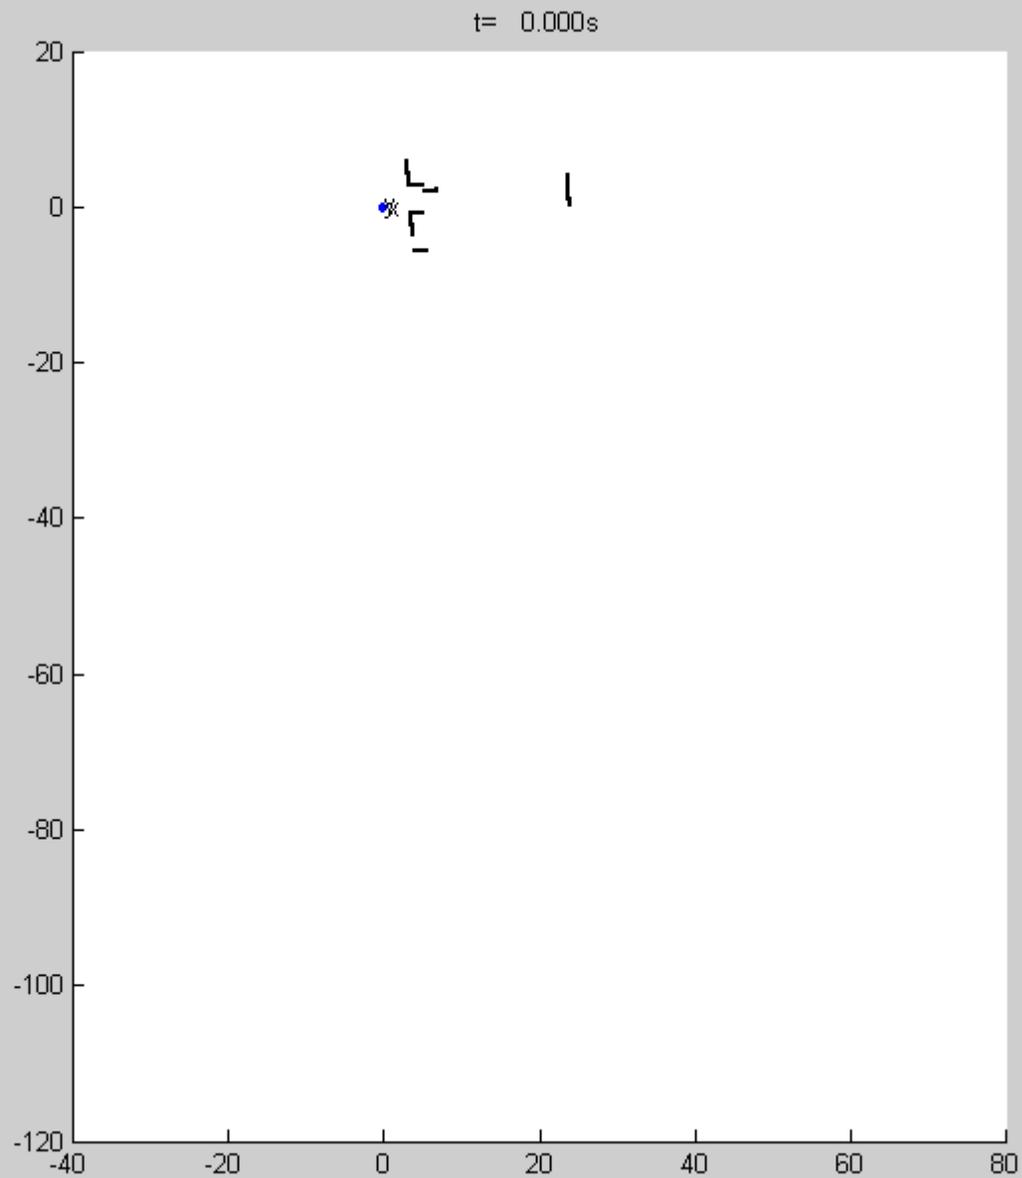
SLAM en entornos grandes: Complejidad Computacional

- Decoupled Stochastic Mapping (Leonard and Feder, 2000) (Jensfelt 2001) $O(1)$
- Suboptimal SLAM (Guivant and Nebot 2001) $O(n)$
- Sparse Weight Filter (Julier 2001) $O(n)$
- Sparse Information Filter (Thrun et al 2004) $O(1)$ *amort.*
- Postponement (Knight, Davidson and Reed 2001)
- Compressed Filter (Guivant and Nebot 2001)
- Constrained Local Submap Filter (Williams 2001)
- Map Joining (Tardós et. al, 2002)

Soluciones aproximadas

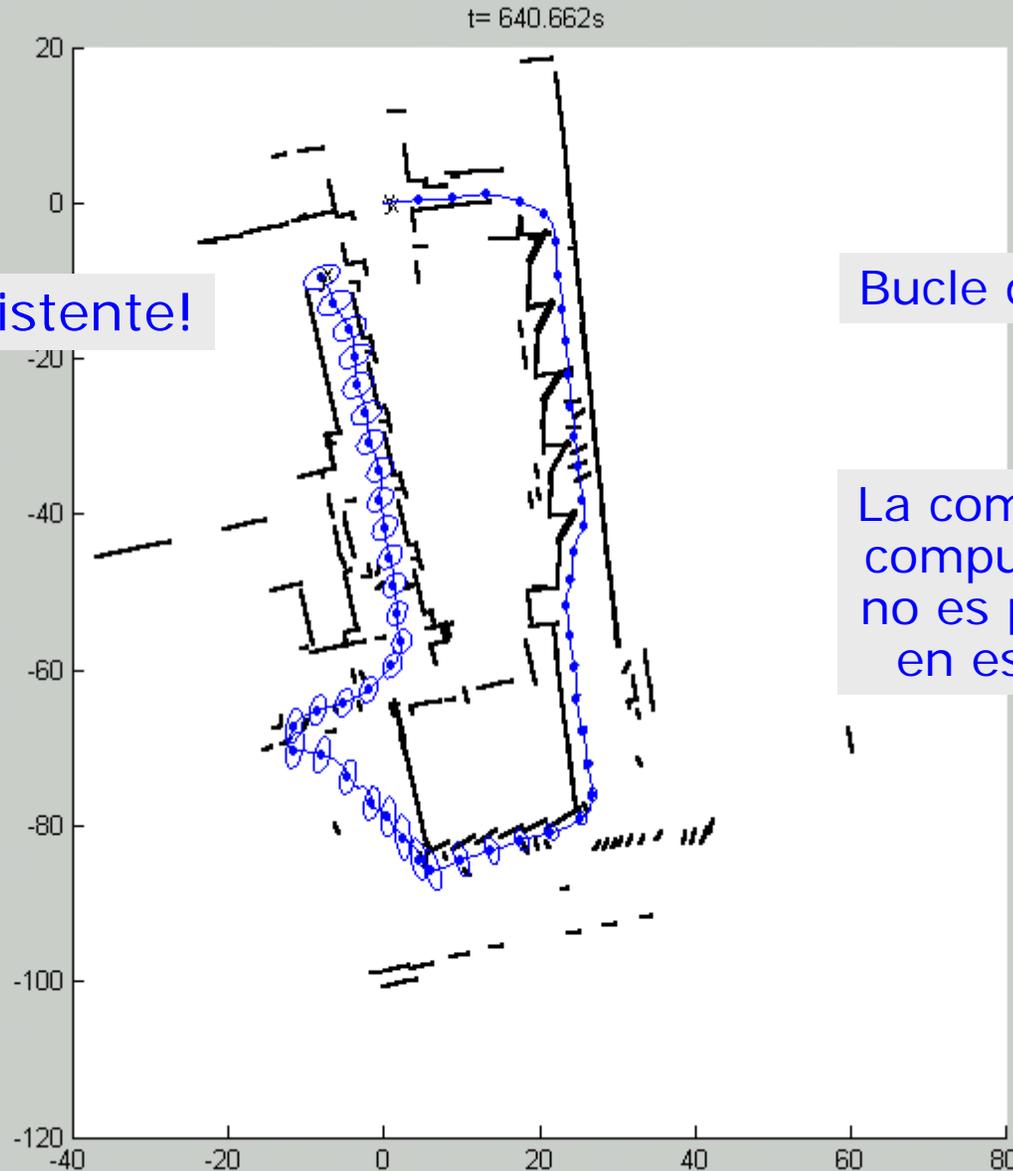
**Soluciones “óptimas” mas
eficientes que EKF-SLAM,
pero $O(n^2)$**

Consistencia del EKF-SLAM



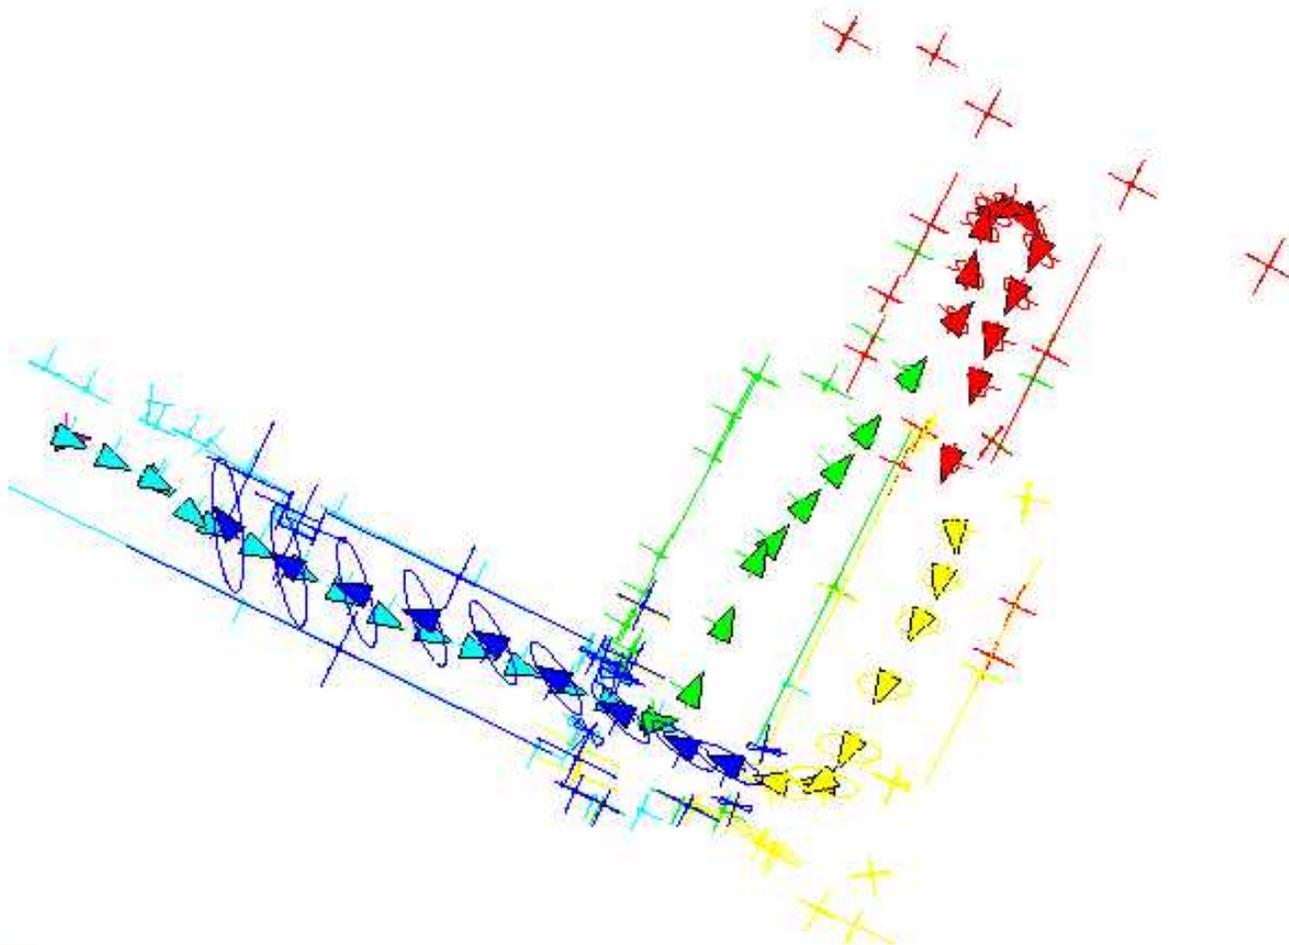
Consistencia del EKF-SLAM

¡Inconsistente!



Técnicas basadas en Mapas Locales

- Mejoran la eficiencia y la consistencia
- Dos mapas locales que no comparten información son Independientes e incorrelados (Tardós et al. 2002)



Idea: Independencia Condicional

- **Independencia**

- **x** e **y** son independientes si:

$$p(\mathbf{x}, \mathbf{y}) = p(\mathbf{x})p(\mathbf{y})$$

$$p(\mathbf{x}|\mathbf{y}) = p(\mathbf{x})$$

- La variable **y** no proporciona información sobre **x**
- **Los mapas no pueden compartir información**

- **Independencia Condicional**

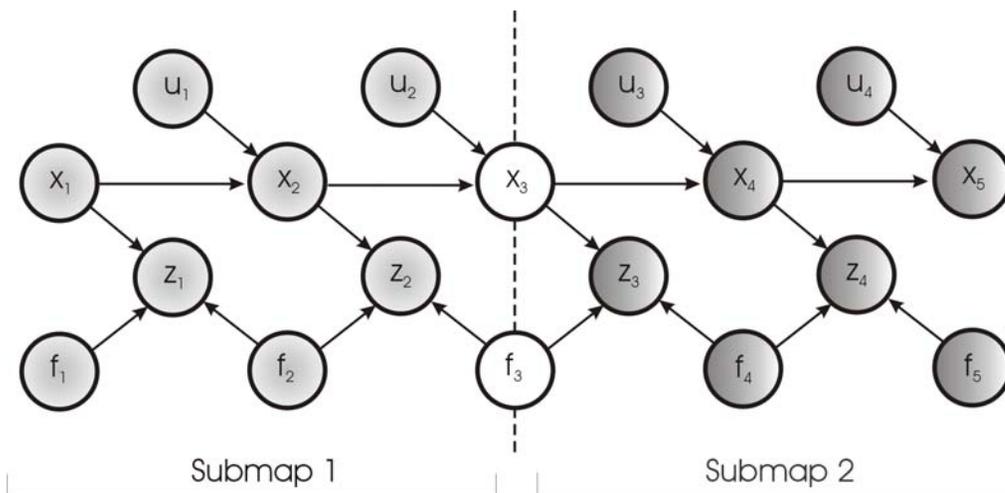
- **x** e **y** son independientes, dado **z** si:

$$p(\mathbf{x}, \mathbf{y}|\mathbf{z}) = p(\mathbf{x}|\mathbf{z})p(\mathbf{y}|\mathbf{z})$$

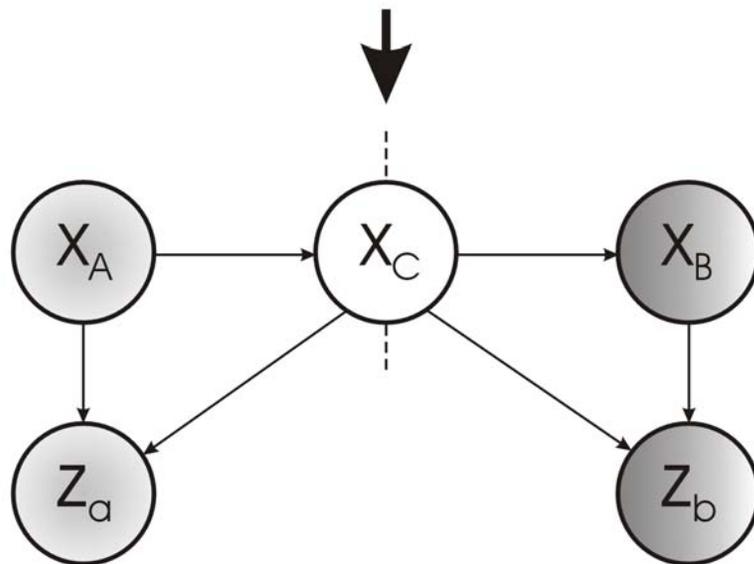
$$p(\mathbf{x}|\mathbf{y}, \mathbf{z}) = p(\mathbf{x}|\mathbf{z})$$

- Si **z** es conocida, **y** no aporta información adicional sobre **x**
- **Los mapas comparten información (z)**

Mapas Absolutos Condicionalmente Independientes



- Ambos mapas comparten x_3 y f_3
- No son independientes
- Son **Condicionalmente Independientes**, dados x_3 y f_3



$$p(\mathbf{x}_A | \mathbf{x}_B, \mathbf{x}_C, \mathbf{z}_a, \mathbf{z}_b) = p(\mathbf{x}_A | \mathbf{x}_C, \mathbf{z}_a)$$

$$p(\mathbf{x}_B | \mathbf{x}_A, \mathbf{x}_C, \mathbf{z}_a, \mathbf{z}_b) = p(\mathbf{x}_B | \mathbf{x}_C, \mathbf{z}_b)$$

Conocido x_C , x_A y z_a no aportan información adicional sobre x_B y z_b

¿Puede reconstruirse el mapa global óptimo?

1. Construimos el primer mapa

$$p(\mathbf{x}_A, \mathbf{x}_C | \mathbf{z}_a) \quad \text{Es óptimo, de momento}$$

2. Nos quedamos con la parte común (marginalización)

$$p(\mathbf{x}_C | \mathbf{z}_a) = \int p(\mathbf{x}_A, \mathbf{x}_C | \mathbf{z}_a) d\mathbf{x}_A$$

3. Seguimos con el segundo mapa

4. Mapa global óptimo: $p(\mathbf{x}_B, \mathbf{x}_C | \mathbf{z}_a, \mathbf{z}_b)$ ¡¡Es óptimo!!

$$\begin{aligned} p(\mathbf{x}_A, \mathbf{x}_B, \mathbf{x}_C | \mathbf{z}_a, \mathbf{z}_b) &= p(\mathbf{x}_A | \mathbf{x}_B, \mathbf{x}_C, \mathbf{z}_a, \mathbf{z}_b) p(\mathbf{x}_B, \mathbf{x}_C | \mathbf{z}_a, \mathbf{z}_b) \\ &= p(\mathbf{x}_A | \mathbf{x}_C, \mathbf{z}_a) p(\mathbf{x}_B, \mathbf{x}_C | \mathbf{z}_a, \mathbf{z}_b) \\ &= \underbrace{\frac{p(\mathbf{x}_A, \mathbf{x}_C | \mathbf{z}_a)}{p(\mathbf{x}_C | \mathbf{z}_a)}}_{\text{del mapa 1}} \underbrace{p(\mathbf{x}_B, \mathbf{x}_C | \mathbf{z}_a, \mathbf{z}_b)}_{=\text{mapa 2}} \end{aligned}$$

Caso Gaussiano: EKF-SLAM

- Mapa 1

$$p(\mathbf{x}_A, \mathbf{x}_C | \mathbf{z}_a) = \mathcal{N} \left(\begin{bmatrix} \hat{\mathbf{x}}_{A_a} \\ \hat{\mathbf{x}}_{C_a} \end{bmatrix}, \begin{bmatrix} P_{A_a} & P_{AC_a} \\ P_{CA_a} & P_{C_a} \end{bmatrix} \right)$$

- Mapa 2

$$p(\mathbf{x}_C, \mathbf{x}_B | \mathbf{z}_a, \mathbf{z}_b) = \mathcal{N} \left(\begin{bmatrix} \hat{\mathbf{x}}_{C_{ab}} \\ \hat{\mathbf{x}}_{B_{ab}} \end{bmatrix}, \begin{bmatrix} P_{C_{ab}} & P_{CB_{ab}} \\ P_{BC_{ab}} & P_{B_{ab}} \end{bmatrix} \right)$$

- Mapa global óptimo:

$$p(\mathbf{x}_A, \mathbf{x}_B, \mathbf{x}_C | \mathbf{z}_a, \mathbf{z}_b) = \mathcal{N} \left(\begin{bmatrix} \hat{\mathbf{x}}_{A_{ab}} \\ \hat{\mathbf{x}}_{C_{ab}} \\ \hat{\mathbf{x}}_{B_{ab}} \end{bmatrix}, \begin{bmatrix} P_{A_{ab}} & P_{AC_{ab}} & P_{AB_{ab}} \\ P_{CA_{ab}} & P_{C_{ab}} & P_{CB_{ab}} \\ P_{BA_{ab}} & P_{BC_{ab}} & P_{B_{ab}} \end{bmatrix} \right)$$

- Correlaciones:

$$\begin{aligned} K &= P_{AC_a} P_{C_a}^{-1} \\ P_{AC_{ab}} &= K P_{C_{ab}} \\ P_{A_{ab}} &= P_{A_a} + K(P_{CA_{ab}} - P_{CA_a}) \\ \hat{\mathbf{x}}_{A_{ab}} &= \hat{\mathbf{x}}_{A_a} + K(\hat{\mathbf{x}}_{C_{ab}} - \hat{\mathbf{x}}_{C_a}) \end{aligned}$$

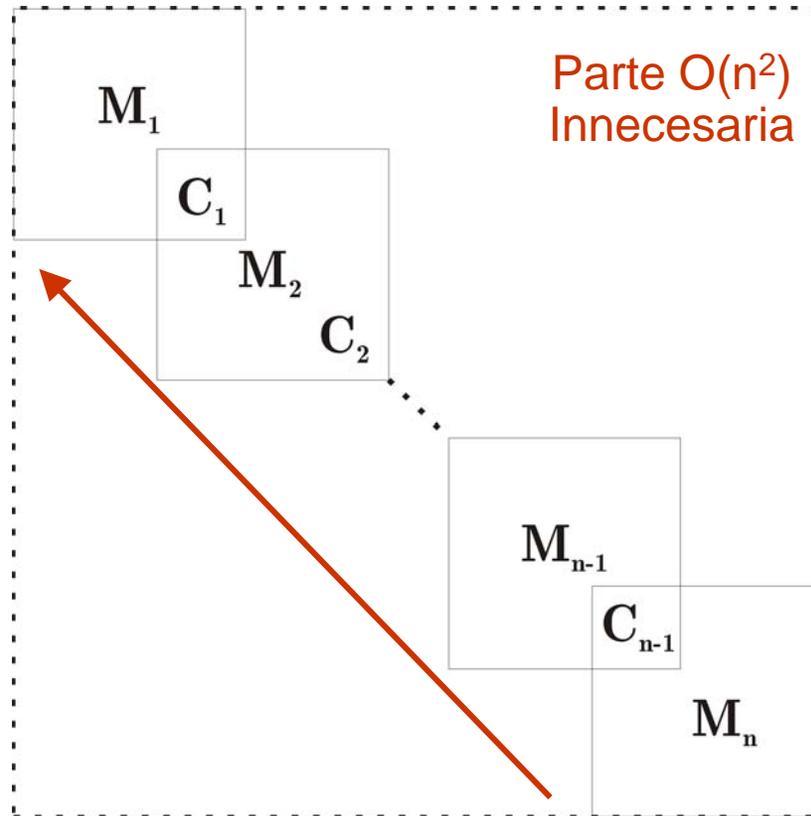
$$P_{AB_{ab}} = K P_{CB_{ab}}$$

Pero son $O(n^2)$ y ¡¡no hacen falta!!



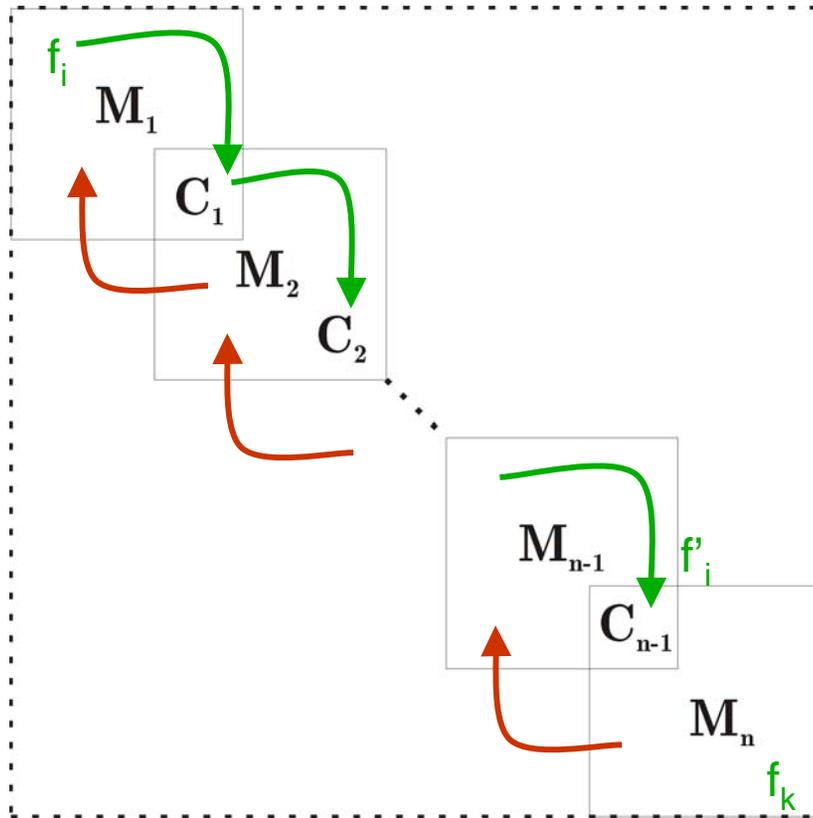
Elementos de la matriz de Covarianza del mapa óptimo que se calculan:

Mapas locales óptimos en $O(1)$



Mapa global óptimo en $O(n)$

Cerrado de Bucle



Mapa global óptimo en $O(n)$

- Detectar el cerrado de bucle ($f_i = f_k$)
- Pasar f_i a la parte común con el resto de mapas
- Imponer $f'_i = f_k$ en el mapa actual
- Retro-propagar la corrección

SLAM para Entornos Grandes

Método	Publicación	Memoria	T local	T parcial	T Bucle	Aproxim.	Coord.	Form
EKF	Smith 1986	$O(n^2)$	$O(n^2)$	$O(n^2)$	$O(n^2)$		Abs	Cov
CEKF	Guivant 2001	$O(n^2)$	$O(n)$	$O(n^2)$	$O(n^2)$		Abs	Cov
Postpon.	Knight 2001	$O(n^2)$	$O(n)$	$O(n^2)$	$O(n^2)$		Abs	Cov
SEIF	Thrun 2004	$O(n)$	$O(1)$	$O(1)$ amort.	$O(n^2)$	Sparsif.	Abs	Inf
ESEIF	Walter 2007	$O(n+p)$	$O(1)$	$O((n+p)^2)$	$O((n+p)^2)$	Sparsif.	Abs	Inf
ESDF	Eustice 2006	$O(p)$	$O(1)$	$O(p^2)$	$O(p^2)$		Abs	Inf
TJTF	Paskin 2003	$O(n)$	$O(1)$	$O(n)$	$O(n)$	Sparsif.	Abs	Inf
Treemap	Frese 2006	$O(n)$	$O(1)$	$O(\log n)$	$O(n)$	Sparsif.	Abs	Inf
Map Joining	Tardós 2002	$O(n^2)$	$O(1)$	$O(n^2)$	$O(n^2)$		Local	Cov
CLSF	Williams 2002	$O(n^2)$	$O(1)$	$O(n^2)$	$O(n^2)$		Local	Cov
D&C SLAM	Paz 2007	$O(n^2)$	$O(1)$	$O(n)$ amort.	$O(n)$ amort.		Local	Cov
CTS	Newman 2003	$O(n)$	$O(1)$	$O(1)$	--	FD, Loop	Local	Cov
Atlas	Bosse 2004	$O(n)$	$O(1)$	$O(1)$	--	FD, Loop	Local	Cov
H-SLAM	Estrada 2005	$O(n)$	$O(1)$	$O(1)$	$O(n)$	FD	Local	Cov
CI-SLAM	Piniés 2007	$O(n)$	$O(1)$	$O(1)$	$O(n)$		Local	Cov



Reduce los errores de linealización

Podemos usar Joint Compatibility

Índice

1. Introducción
2. SLAM en entornos grandes
 - Mapas locales
 - CI-SLAM: Mapas Condicionalmente Independientes
 - Caso Gaussiano con covarianzas
 - Exploración y cerrado de bucles
3. Aplicación al SLAM monocular
 - Representación
 - Asociación de datos
 - Cerrado de bucles
 - Resultados experimentales
4. Conclusiones y trabajo futuro

SLAM Monocular Puro



**web-cam, portátil y
cable firewire**

Representación con Inverse Depth

$$\mathbf{x} = \begin{pmatrix} \mathbf{x}_c \\ y_1 \\ y_2 \\ \dots \\ y_n \end{pmatrix}$$

$$\mathbf{x}_c = \begin{pmatrix} \mathbf{r}^{BC} \\ \Psi^{BC} \\ \mathbf{v}^B \\ \mathbf{w}^C \end{pmatrix}$$

Estado de la Cámara:

- Posición
- Orientación
- Velocidad Lineal
- Velocidad Angular

Estado de los puntos:

$$y_i = \begin{pmatrix} x_i \\ y_i \\ z_i \\ \theta_i \\ \phi_i \\ \rho_i \end{pmatrix}$$

- Posición de la cámara cuando el punto se vió por primera vez

- Acimut
- Elevación
- **Inverse depth**

- Incertidumbre bien modelada con una Gaussiana
- Inicialización inmediata de los puntos

J.M.M. Montiel, J. Civera, A.J. Davison: **Unified inverse depth parametrization for monocular SLAM**. Robotics: Science and Systems, Philadelphia, Aug 2006



Puntos: detector de Shi-Tomasi



- Puntos de imagen característicos, patrón 11x11
- Predicción de la posición del punto en la siguiente imagen
- Búsqueda precisa por correlación normalizada SSD

A.J. Davidson and D.W. Murray: **Simultaneous Localization and Map Building using Active Vision**. IEEE Trans. on PAMI 24 (7), 865-880, 2002

Compatibilidad Conjunta

- Dada una hipótesis $\mathcal{H} = [j_1, j_2, \dots, j_s]$
- Ecuación de medida conjunta:

$$\mathbf{z}_{\mathcal{H}} = \mathbf{h}_{\mathcal{H}}(\mathbf{x}^B) + \mathbf{w}_{\mathcal{H}}$$
$$\mathbf{h}_{\mathcal{H}} = \begin{bmatrix} \mathbf{h}_{1j_1} \\ \mathbf{h}_{2j_2} \\ \vdots \\ \mathbf{h}_{sj_s} \end{bmatrix}$$

- La hipótesis conjunta es compatible si:

$$D_{\mathcal{H}}^2 = (\mathbf{z}_{\mathcal{H}} - \mathbf{h}_{\mathcal{H}}(\hat{\mathbf{x}}^B))^T \mathbf{C}_{\mathcal{H}}^{-1} (\mathbf{z}_{\mathcal{H}} - \mathbf{h}_{\mathcal{H}}(\hat{\mathbf{x}}^B)) < \chi_{d,\alpha}^2$$

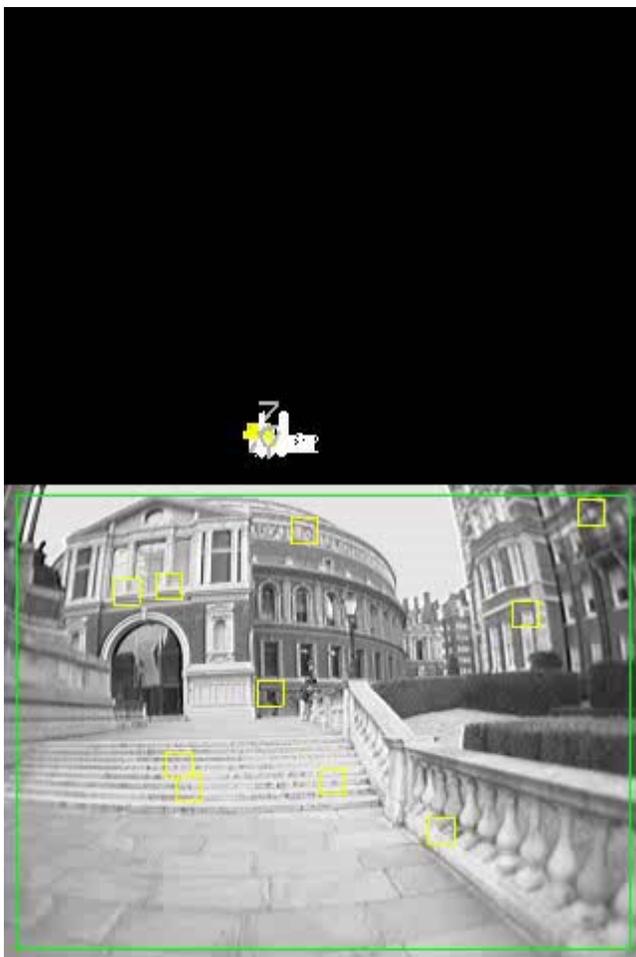
$$\mathbf{C}_{\mathcal{H}} = \mathbf{H}_{\mathcal{H}} \mathbf{P}^B \mathbf{H}_{\mathcal{H}}^T + \mathbf{R}_{\mathcal{H}}$$

$d = \text{length}(\mathbf{z})$

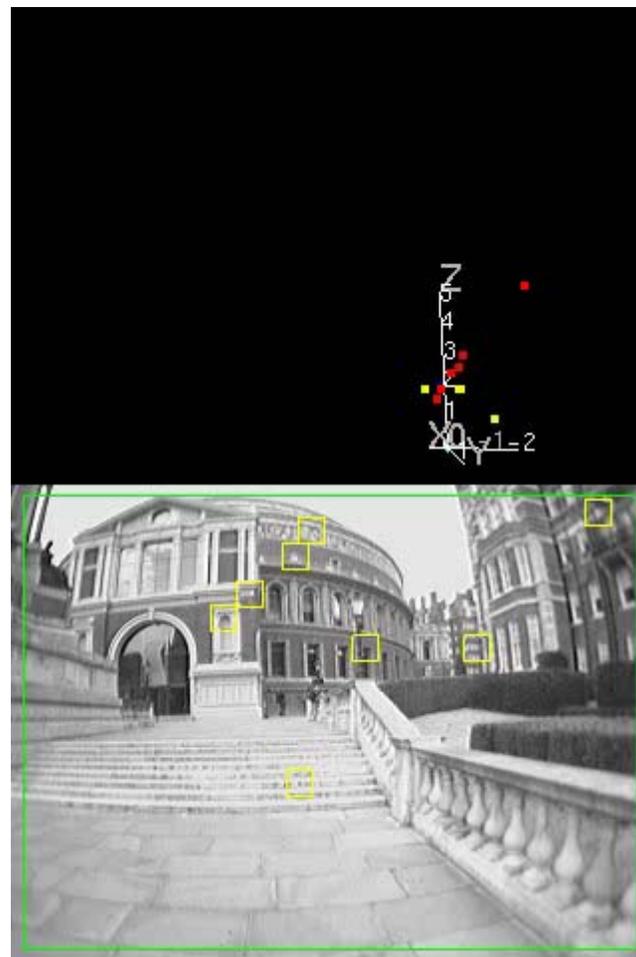
J. Neira, J.D. Tardós. **Data Association in Stochastic Mapping using the Joint Compatibility Test**, IEEE Trans. Robotics and Automation, Vol. 17, No. 6, Dec 2001, pp 890 –897



Nearest Neighbor .vs. Joint Compatibility

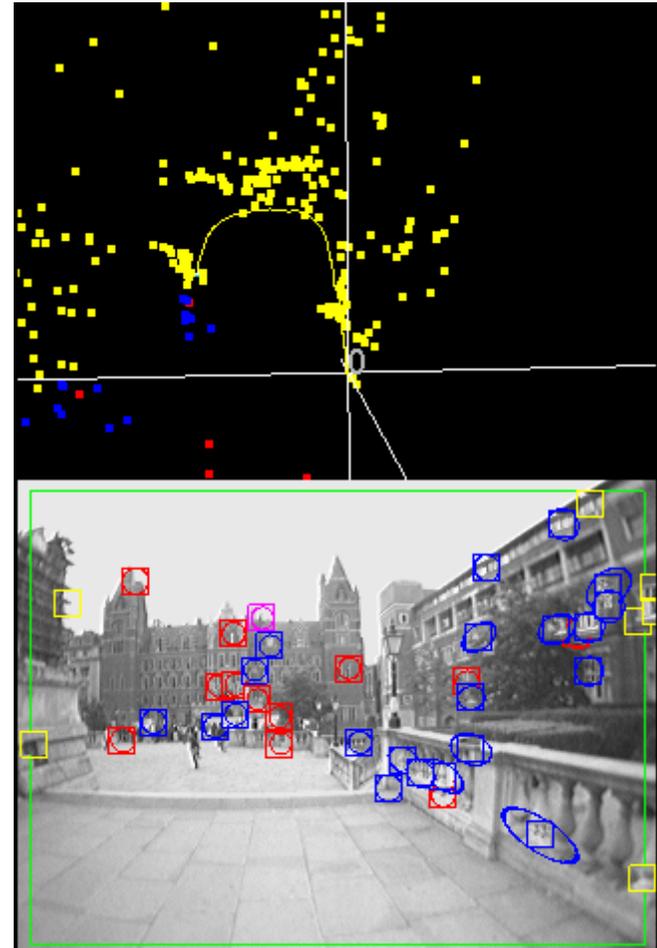
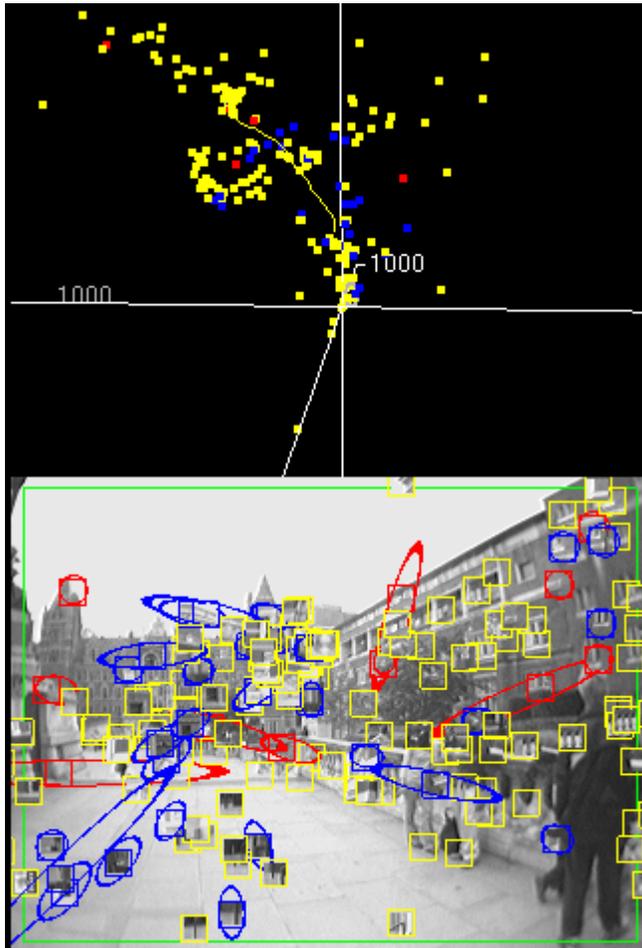


Individual Tracks



Jointly Compatible Tracks

Nearest Neighbor .vs. Joint Compatibility

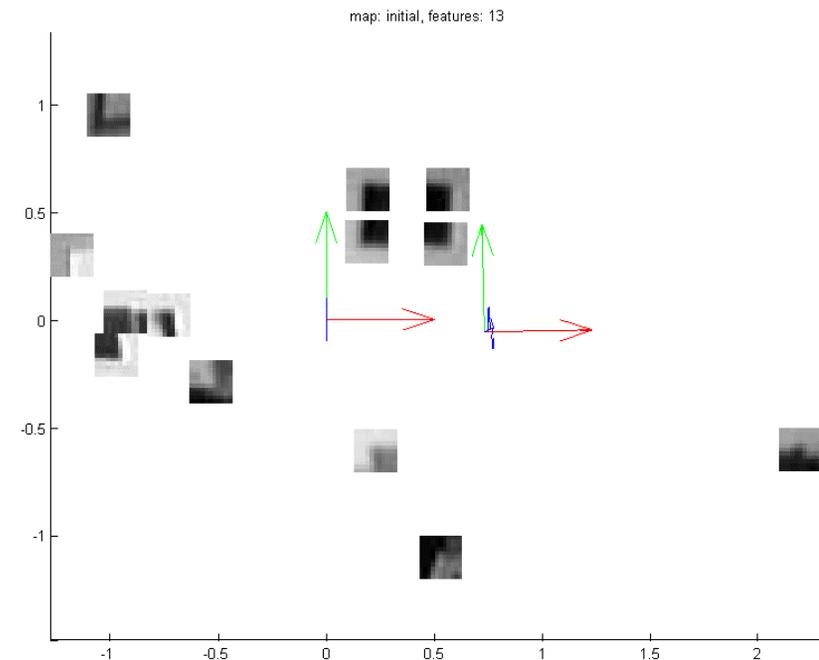
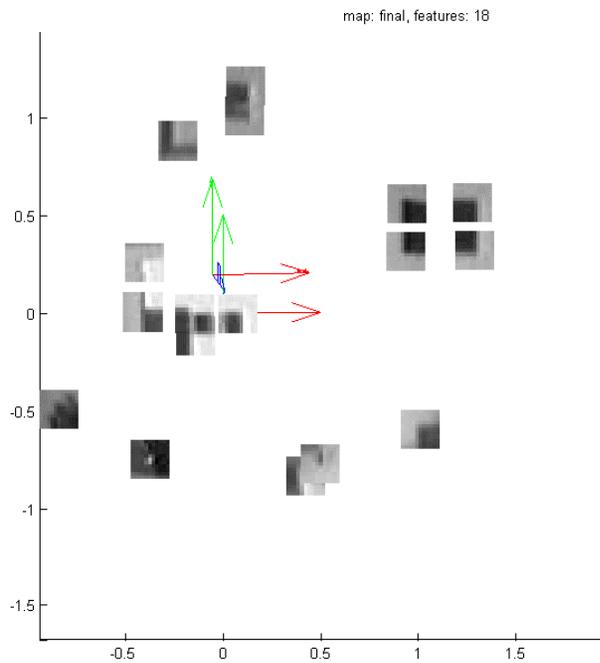


Individual
Tracks

Jointly compatible
Tracks (coste: 2ms)

Detección de bucles: Emparejamiento Mapa-a-Mapa

- Emparejar dos nubes de puntos con textura



Emparejamiento de Mapas

- Restricciones Unarias: Correlación SSD normalizada

Mapa 1

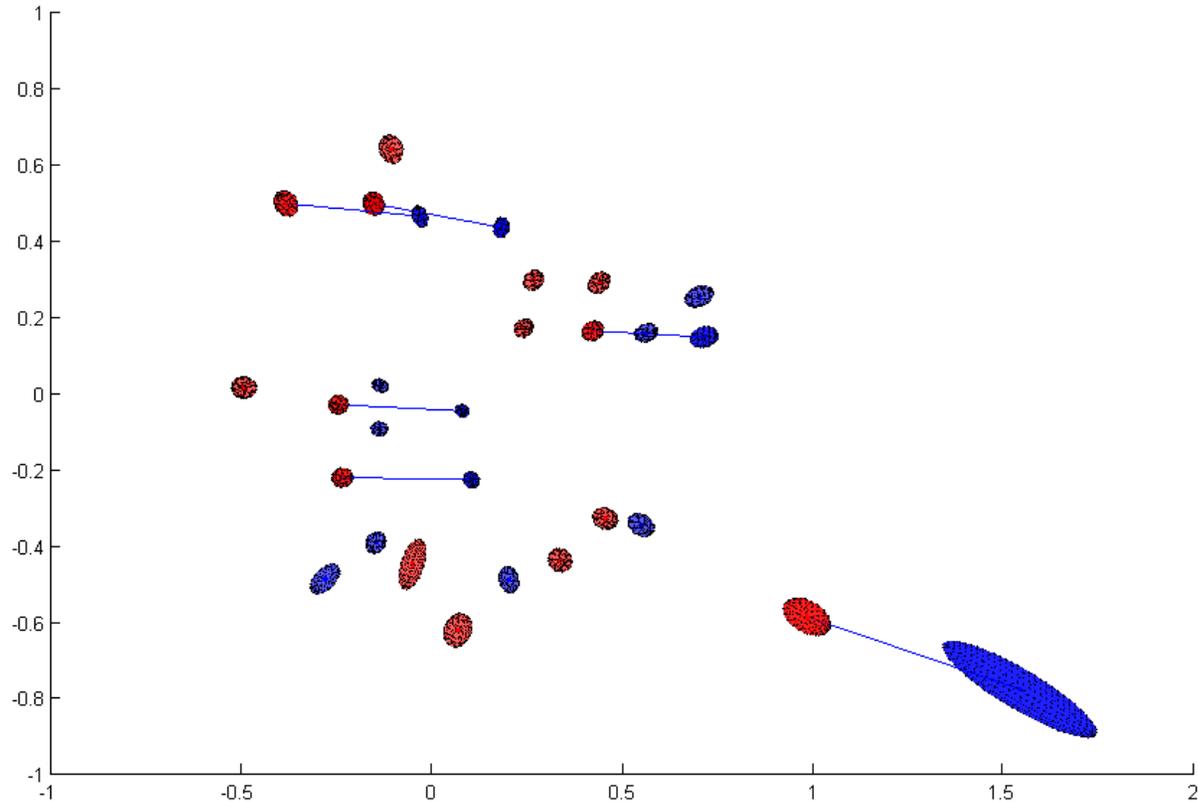


Mapa 2



Emparejamiento de Mapas

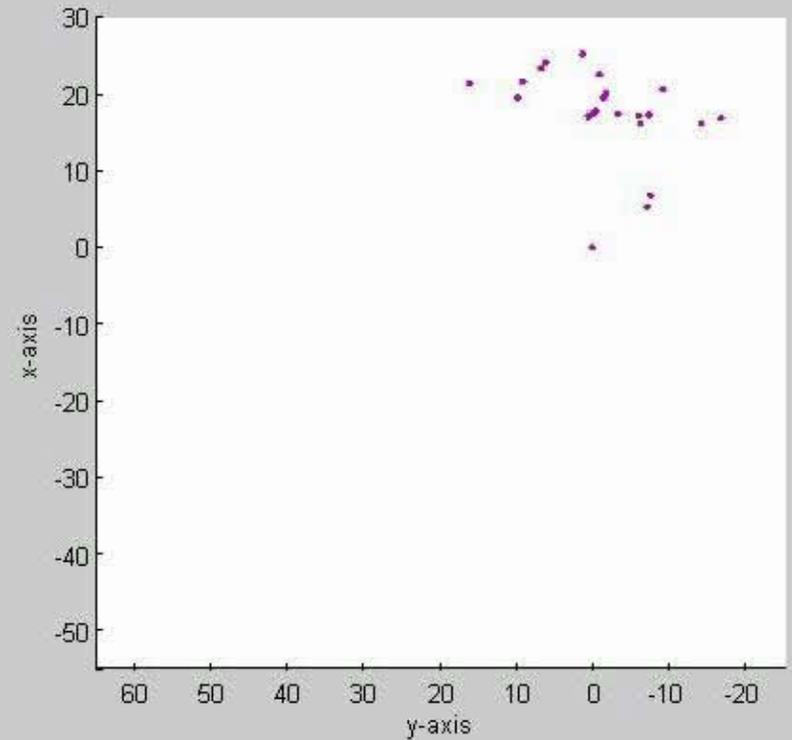
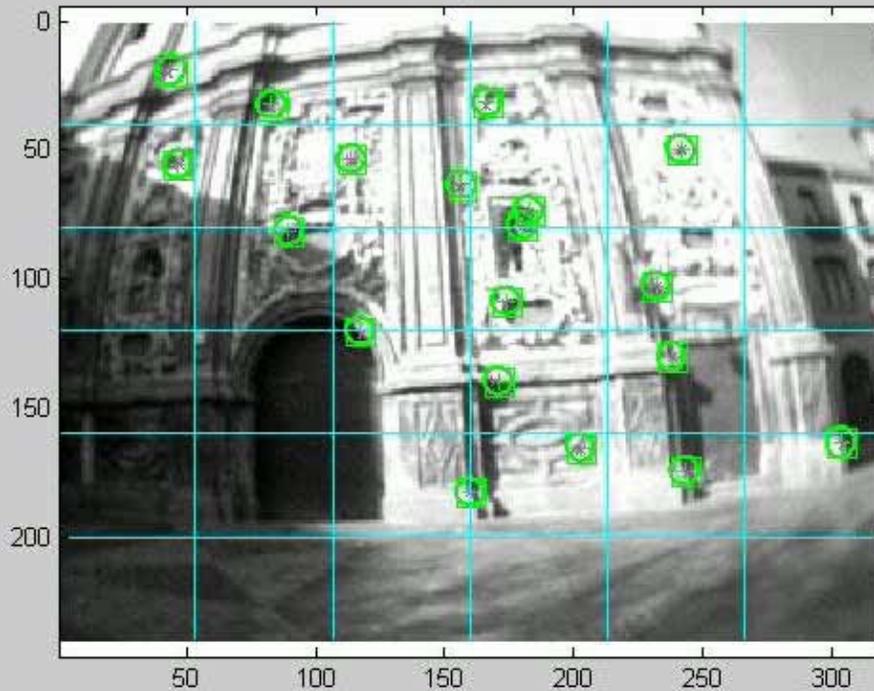
- Restricciones binarias: Distancias entre pares de puntos



- Invariante a escala (visión monocular):
 - Los dos primeros pares fijan el cambio de escala entre mapas
 - Después, las distancias relativas deben ser compatibles

Resultados Experimentales: Plaza del Justicia (bucle de 140m)

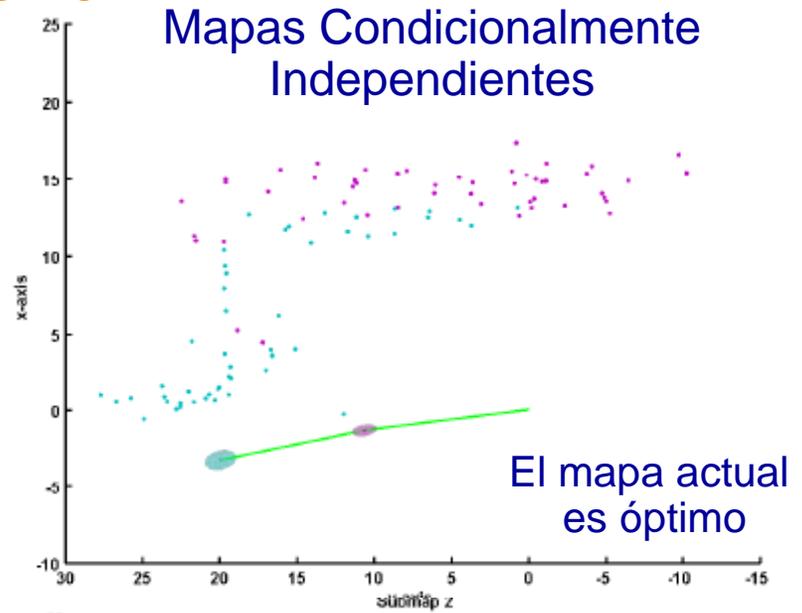
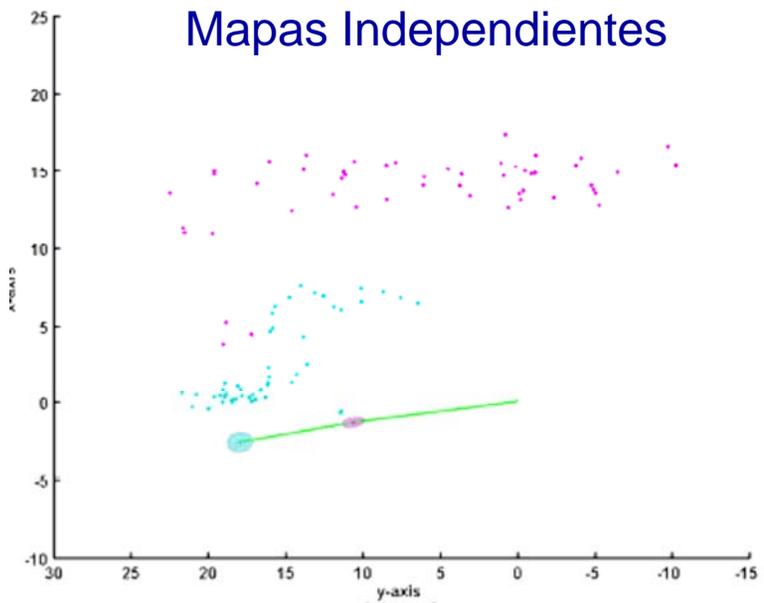
Image: 12



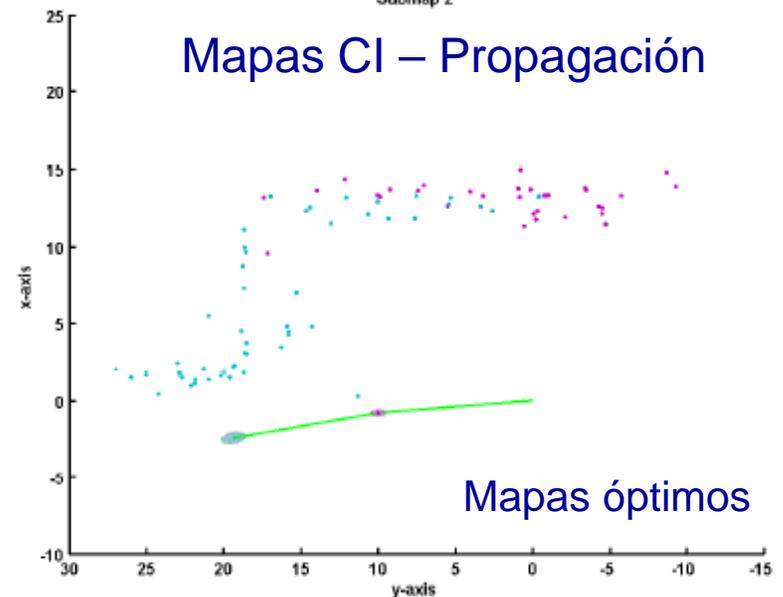
Plaza del Justicia (bucle de 140m)



Independencia .vs. Independencia Condicional



- Mapas sub-óptimos
- No pueden compartir estados del vehículo o del sensor como velocidades, sesgos (IMU),...
- Imprecisión en la zona común
- Escala diferente



Bucles más largos: Optimización no lineal

- Minimizar las correcciones, sujeto a la restricción del bucle:

$$\min_{\mathbf{x}} \frac{1}{2} (\mathbf{x} - \hat{\mathbf{x}})^T \mathbf{P}^{-1} (\mathbf{x} - \hat{\mathbf{x}})$$
$$\mathbf{h}(\mathbf{x}) = \mathbf{0}$$

- Sequential Quadratic Programming (SQP) :

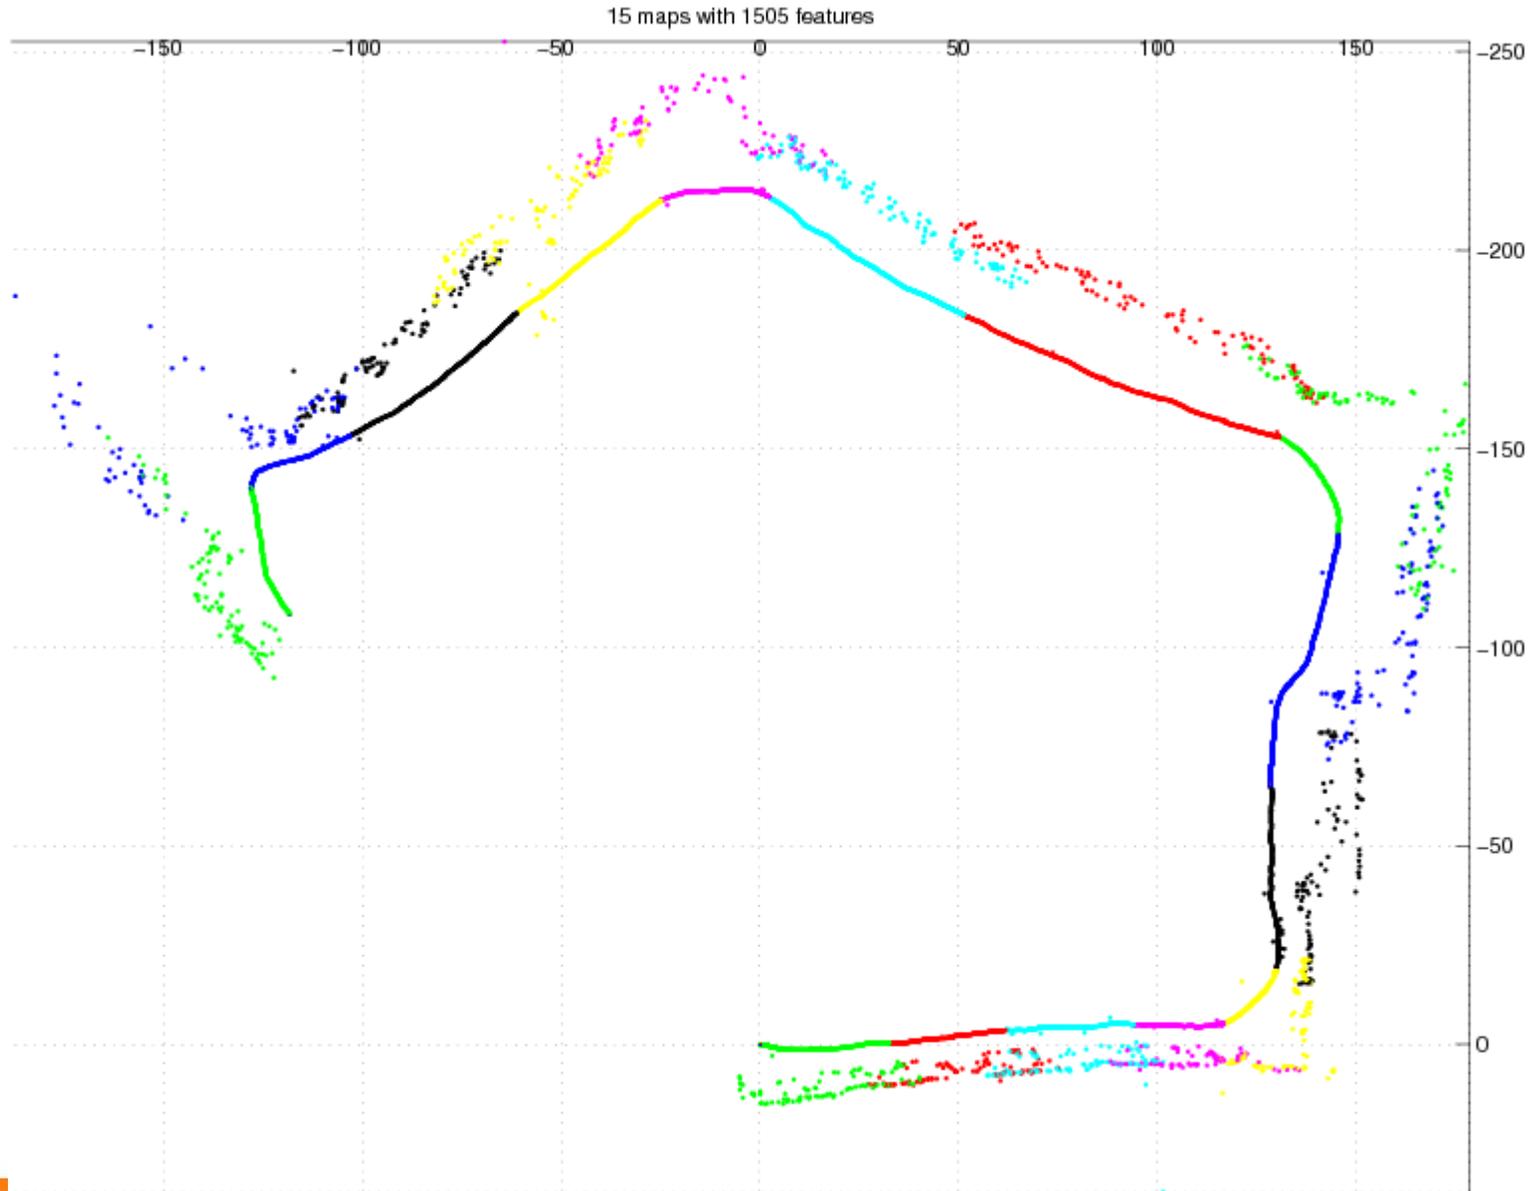
$$\mathbf{H}_i = \left[\begin{array}{cccc} \frac{\partial \mathbf{h}}{\partial \mathbf{x}_1} \Big|_{\hat{\mathbf{x}}_i} & \frac{\partial \mathbf{h}}{\partial \mathbf{x}_2} \Big|_{\hat{\mathbf{x}}_i} & \cdots & \frac{\partial \mathbf{h}}{\partial \mathbf{x}_n} \Big|_{\hat{\mathbf{x}}_i} \end{array} \right]$$

$$\mathbf{P}_i = \mathbf{P}_0 - \mathbf{P}_0 \mathbf{H}_i^T \left(\mathbf{H}_i \mathbf{P}_0 \mathbf{H}_i^T \right)^{-1} \mathbf{H}_i \mathbf{P}_0$$

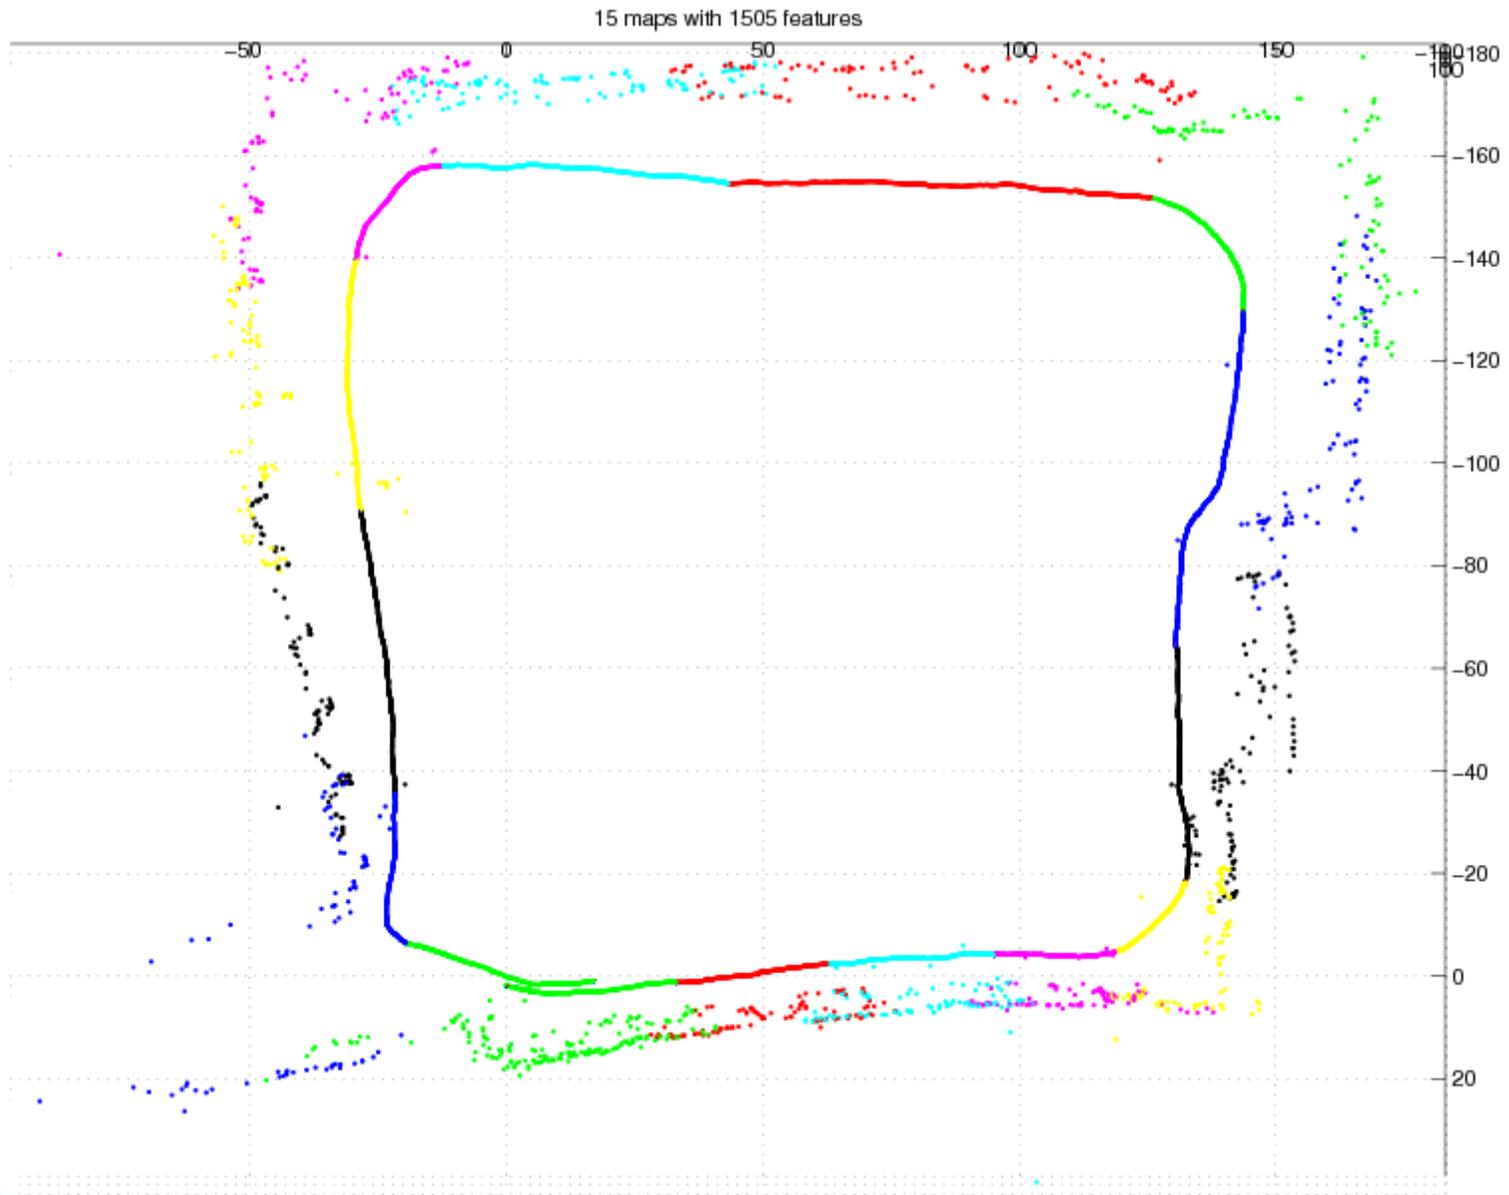
$$\hat{\mathbf{x}}_{i+1} = \hat{\mathbf{x}}_i - \mathbf{P}_i \mathbf{P}_0^{-1} (\hat{\mathbf{x}}_i - \hat{\mathbf{x}}_0) - \mathbf{P}_0 \mathbf{H}_i^T \left(\mathbf{H}_i \mathbf{P}_0 \mathbf{H}_i^T \right)^{-1} \hat{\mathbf{h}}_i$$

C. Estrada, J. Neira, J.D. Tardós: **Hierarchical SLAM: real-time accurate mapping of large environments**. IEEE Transactions on Robotics 21 (4), 588-596, Aug 2005

Mapas Locales

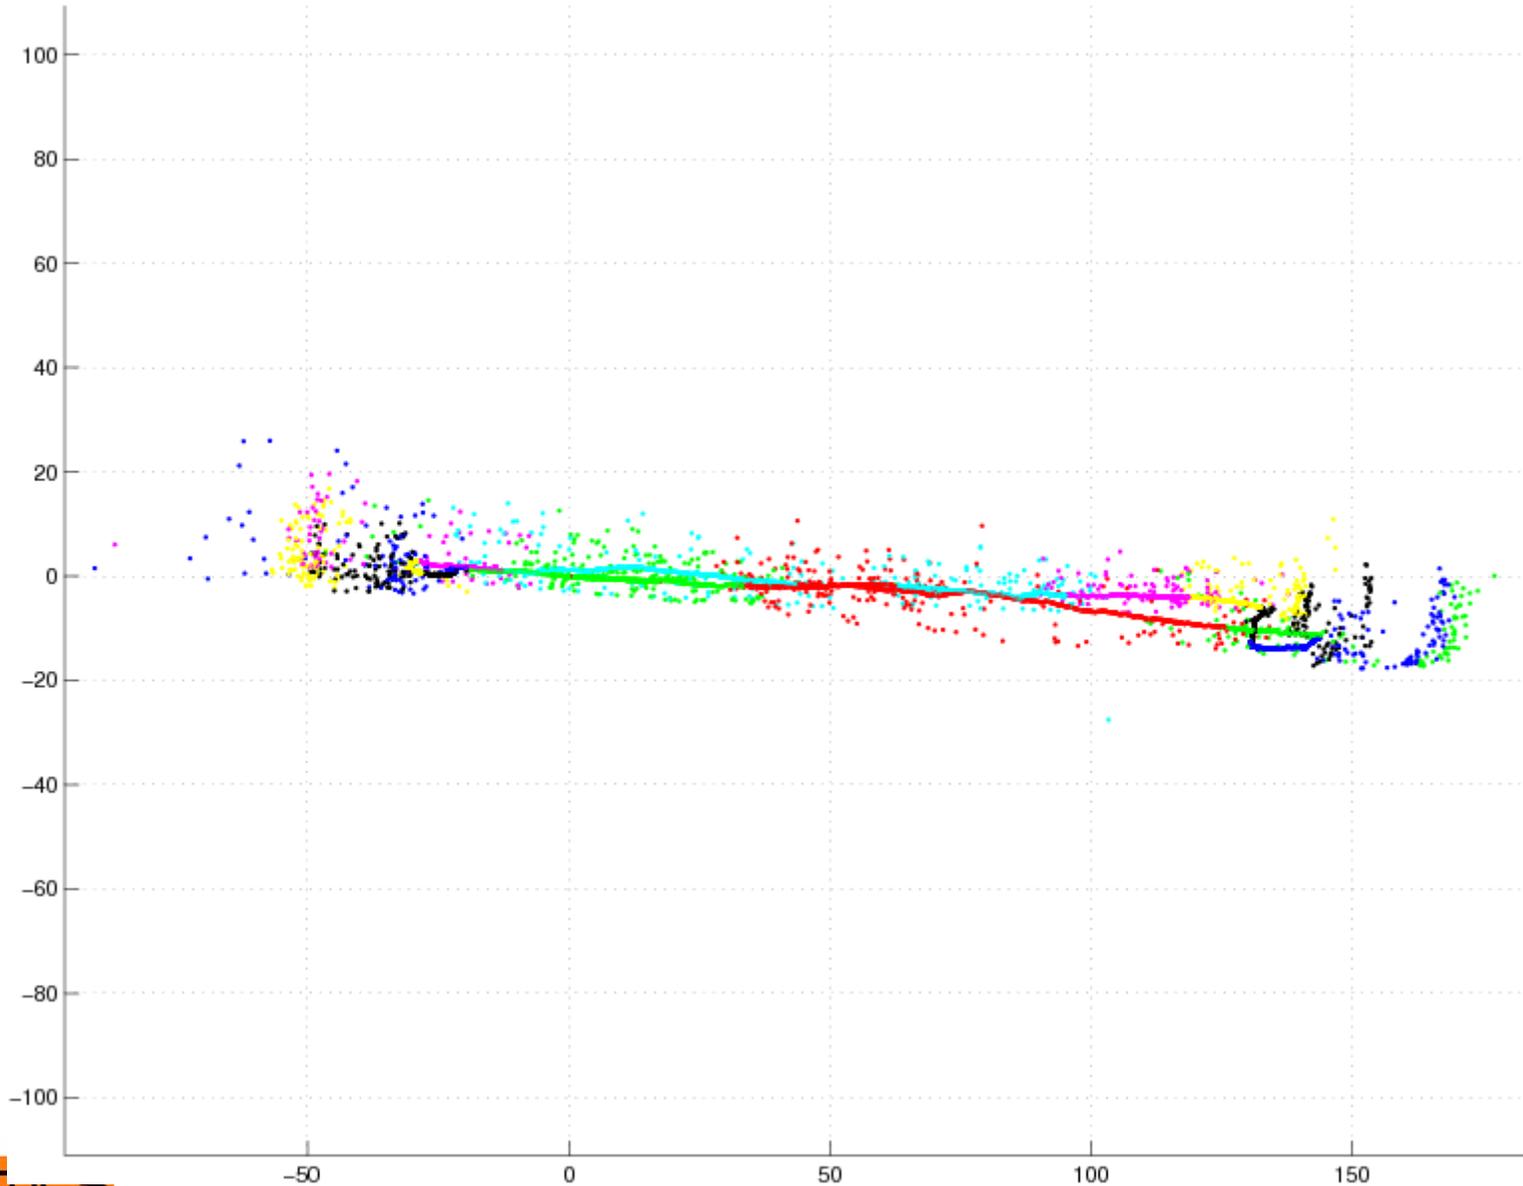


Cerrado de Bucle

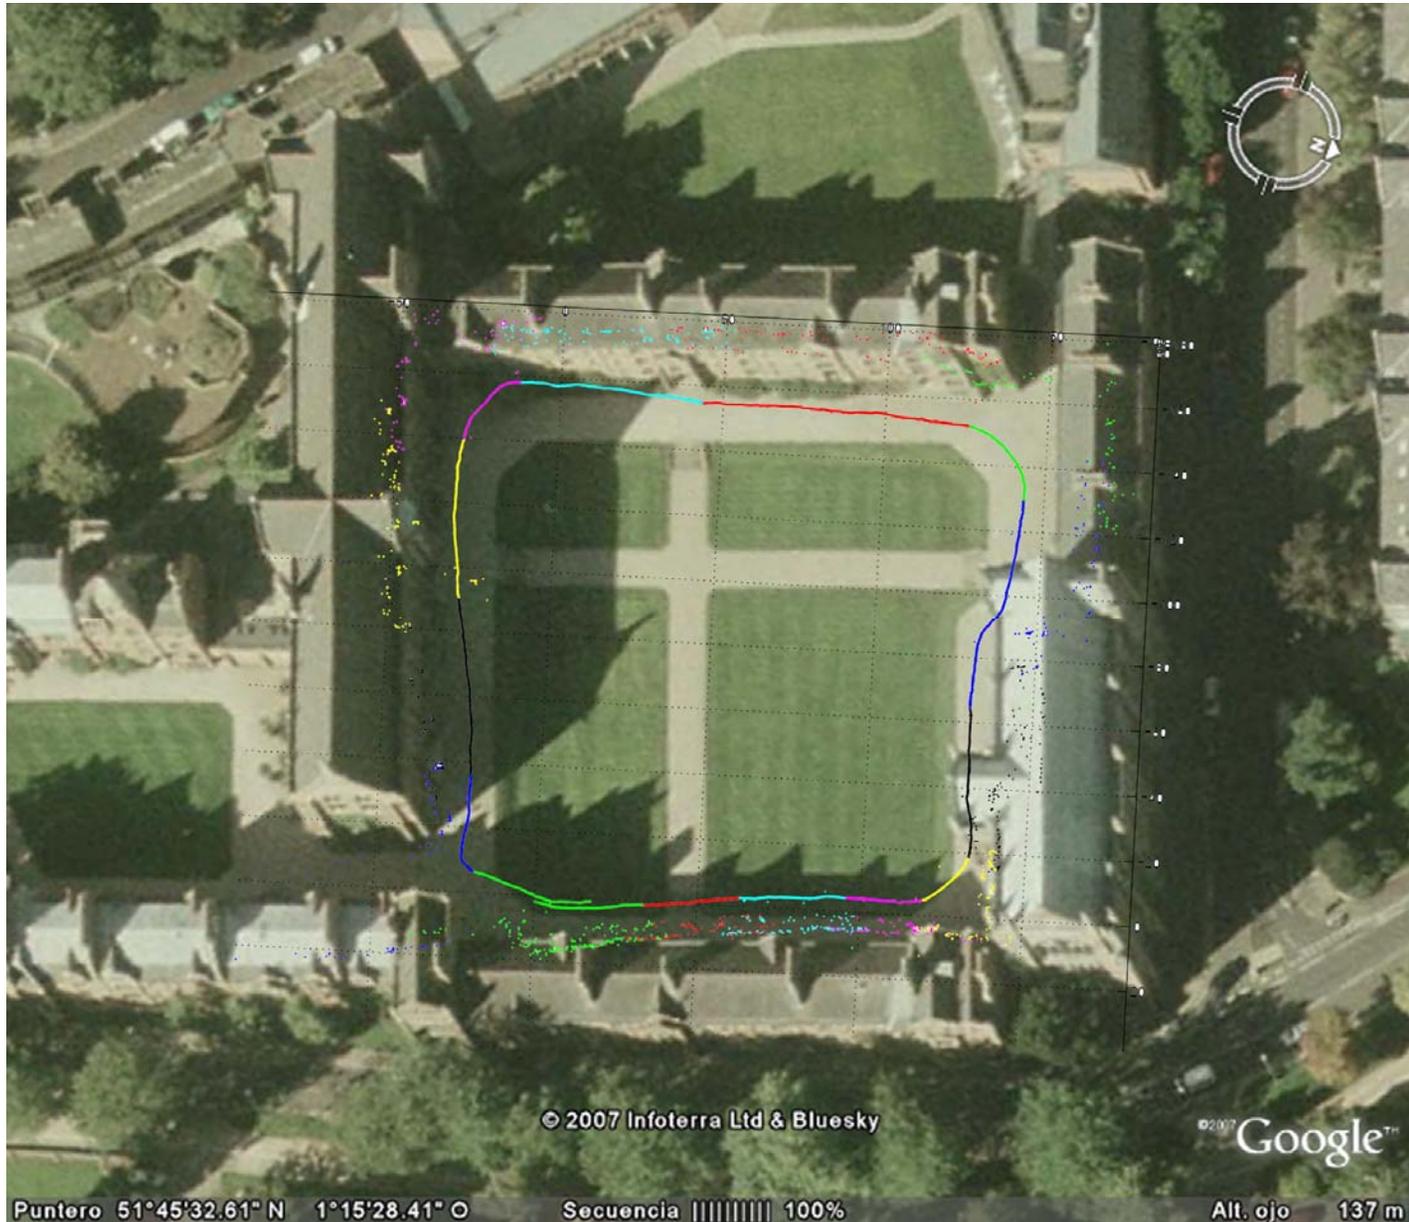


Cerrado de Bucle (vista lateral)

15 maps with 1505 features



Keble College, Oxford (250m)



ROBOT 2007: I Workshop de Robótica, Zaragoza, Sept 2007

Índice

1. Introducción
2. SLAM en entornos grandes
 - Mapas locales
 - CI-SLAM: Mapas Condicionalmente Independientes
 - Caso Gaussiano con covarianzas
 - Exploración y cerrado de bucles
3. Aplicación al SLAM monocular
 - Representación
 - Asociación de datos
 - Cerrado de bucles
 - Resultados experimentales
4. Conclusiones y trabajo futuro

Conclusiones

- Mapas locales condicionalmente independientes
 - Permiten compartir información entre mapas
 - Mapas locales óptimos en $O(1)$
 - Mapa global óptimo en $O(n)$
 - Covarianzas disponibles para asociación de datos
 - Reducen los errores de linealización
- SLAM Monocular en tiempo real en entornos urbanos
 - Inverse depth: inicialización inmediata
 - Joint Compatibility: robustez
 - Emparejamiento de mapas: detección de bucles
 - Mapas CI: eficiencia, escala coherente y buena precisión

Trabajo Futuro

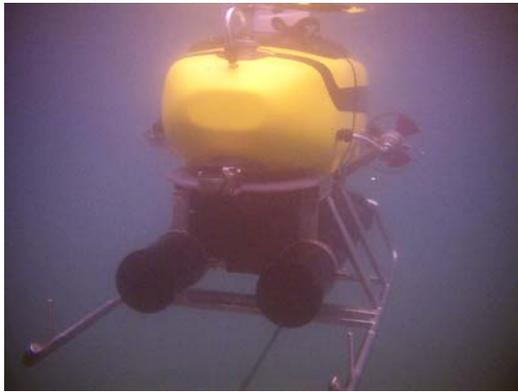
- Mapas CI para entornos más grandes
 - Optimización no lineal de los bucles
 - Mapas Jerárquicos
 - Detección de bucles Imagen-a-Mapa
- Benchmarks para SLAM: RAWSEEDS, **FP6-IST-045144**
 - SLAM con visión en 3D
 - CI-SLAM: eficiencia y precisión
- Nuevas aplicaciones de SLAM

Sistemas portátiles para SLAM

- Proyecto “SLAM6DOF: Sistemas portátiles para localización y construcción de mapas en entornos grandes y complejos”, MCYT, DPI2006-13578, responsable: José Neira, (2007-2009)



Aplicación a SLAM Submarino



**Garbi, Univ.
Girona, Spain**



David Ribas, Pere Ridao, Juan D. Tardos, José Neira: **Underwater SLAM in a Marina Environment**, IEEE/RSJ International Conference on Intelligent Robots and Systems, IROS 2007 (aceptado)

ROBOT 2007: I Workshop de Robótica, Zaragoza, Sept 2007