

ACTA DE EVALUACIÓN DE LA TESIS DOCTORAL
(FOR EVALUATION OF THE ACT DOCTORAL THESIS)

Año académico (academic year): 2016/17

DOCTORANDO (candidate PHD): **ZAMPELLA, FRANCISCO JOSÉ N.**

D.N.I./PASAPORTE (Id.Passport): ******686**

PROGRAMA DE DOCTORADO (Academic Committee of the Programme): **D332 DOCTORADO EN
ELECTRÓNICA:SISTEMAS ELECTRÓNICOS AVANZADOS.SISTEMAS INTELIGEN**

DEPARTAMENTO DE (Department): **ELECTRÓNICA**

TITULACIÓN DE DOCTOR EN (Phd title): **DOCTOR/A POR LA UNIVERSIDAD DE ALCALÁ**

En el día de hoy 23/06/17, reunido el tribunal de evaluación, constituido por los miembros que suscriben el presente Acta, el aspirante defendió su Tesis Doctoral **con Mención Internacional** (In today assessment met the court, consisting of the members who signed this Act, the candidate defended his doctoral thesis with mention as International Doctorate), elaborada bajo la dirección de (prepared under the direction of) ANTONIO RAMÓN JIMÉNEZ RUIZ // .

Sobre el siguiente tema (Title of the doctoral thesis): **LOCALIZACIÓN DE PERSONAS MEDIANTE SENSORES INERCIALES Y SU FUSIÓN CON OTRAS TECNOLOGÍAS**

Finalizada la defensa y discusión de la tesis, el tribunal acordó otorgar la CALIFICACIÓN GLOBAL⁴ de (**no apto, aprobado, notable y sobresaliente**) (After the defense and defense of the thesis, the court agreed to grant the GLOBAL RATING (fail, pass, good and excellent): **SOBRESALIENTE**

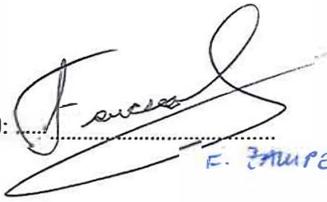
Alcalá de Henares, a 23 de junio de 2017

Fdo. (Signed): 

Fdo. (Signed): 

Fdo. (Signed): 

FIRMA DEL ALUMNO (candidate's signature),

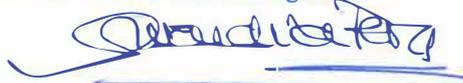
Fdo. (Signed): 

F. ZAMPPELLA

Con fecha 29 de junio de 2017 la Comisión Delegada de la Comisión de Estudios Oficiales de Posgrado, a la vista de los votos emitidos de manera anónima por el tribunal que ha juzgado la tesis, resuelve:

- Conceder la Mención de "Cum Laude"
 No conceder la Mención de "Cum Laude"

La Secretaria de la Comisión Delegada



⁴ La calificación podrá ser "no apto" "aprobado" "notable" y "sobresaliente". El tribunal podrá otorgar la mención de "cum laude" si la calificación global es de sobresaliente y se emite en tal sentido el voto secreto positivo por unanimidad. (The grade may be "fail" "pass" "good" or "excellent". The panel may confer the distinction of "cum laude" if the overall grade is "Excellent" and has been awarded unanimously as such after secret voting.)

INCIDENCIAS / OBSERVACIONES:
(Incidents / Comments)



Universidad
de Alcalá

COMISIÓN DE ESTUDIOS OFICIALES
DE POSGRADO Y DOCTORADO

En aplicación del art. 14.7 del RD. 99/2011 y el art. 14 del Reglamento de Elaboración, Autorización y Defensa de la Tesis Doctoral, la Comisión Delegada de la Comisión de Estudios Oficiales de Posgrado y Doctorado, en sesión pública de fecha 29 de junio, procedió al escrutinio de los votos emitidos por los miembros del tribunal de la tesis defendida por ZAMPELLA, FRANCISCO JOSÉ N., el día 23 de junio de 2017, titulada *LOCALIZACIÓN DE PERSONAS MEDIANTE SENSORES INERCIALES Y SU FUSIÓN CON OTRAS TECNOLOGÍAS*, para determinar, si a la misma, se le concede la mención "cum laude", arrojando como resultado el voto favorable de todos los miembros del tribunal.

Por lo tanto, la Comisión de Estudios Oficiales de Posgrado resuelve otorgar a dicha tesis la

MENCIÓN "CUM LAUDE"

Alcalá de Henares, 11 julio de 2017
EL PRESIDENTE DE LA COMISIÓN DE ESTUDIOS
OFICIALES DE POSGRADO Y DOCTORADO



Firmado digitalmente por VELASCO
PEREZ JUAN RAMON - DNI
03087239H
Fecha: 2017.07.12.22:56:36 +02'00'

Juan Ramón Velasco Pérez

Copia por e-mail a:

Doctorando: ZAMPELLA, FRANCISCO JOSÉ N.

Secretario del Tribunal: ALFONSO BAHILLO MARTÍNEZ.

Director de Tesis: ANTONIO RAMÓN JIMÉNEZ RUIZ



Universidad
de Alcalá

ESCUELA DE DOCTORADO
Servicio de Estudios Oficiales de
Posgrado

DILIGENCIA DE DEPÓSITO DE TESIS.

Comprobado que el expediente académico de D./D^a _____
reúne los requisitos exigidos para la presentación de la Tesis, de acuerdo a la normativa vigente, y habiendo
presentado la misma en formato: soporte electrónico impreso en papel, para el depósito de la
misma, en el Servicio de Estudios Oficiales de Posgrado, con el nº de páginas: _____ se procede, con
fecha de hoy a registrar el depósito de la tesis.

Alcalá de Henares a _____ de _____ de 20 _____



Fdo. El Funcionario

UNIVERSIDAD DE ALCALÁ

ESCUELA POLITÉCNICA SUPERIOR

Programa de Doctorado en Electrónica
Sistemas Electrónicos Avanzados. Sistemas Inteligentes



TESIS DOCTORAL

“Localización de personas mediante sensores
inerciales y su fusión con otras tecnologías”

Francisco José N. Zampella

2017



Dr. Antonio Ramón Jiménez Ruiz, Científico Titular del CSIC

INFORMA : Que la Tesis Doctoral titulada “Localización de personas mediante sensores inerciales y su fusión con otras tecnologías”, presentada por D. Francisco José N. Zampella, y realizada bajo mi dirección, dentro del campo de aplicación del **diseño de sistemas de localización en interiores de personas usando sensores inerciales**, reúne los méritos de calidad y originalidad para optar al Grado de Doctor.

Alcalá de Henares, 4 de Abril de 2017

Fdo.: Antonio Ramón Jiménez Ruiz



D^a. Sira E. Palazuelos Cagigas, Directora del Departamento de Electrónica de la Universidad de Alcalá

INFORMA que la Tesis Doctoral titulada: “**Localización de personas mediante sensores inerciales y su fusión con otras tecnologías**” presentada por **D. Francisco José Zampella Méndez**, bajo la dirección del Dr. D. Antonio Ramón Jiménez Ruiz, reúne los requisitos científicos de originalidad y rigor metodológicos para ser defendida ante un tribunal.

Para que así conste y surta los efectos oportunos, se firma el presente informe en Alcalá de Henares a 03 de abril de 2017,

Fdo.: D^a Sira E. Palazuelos Cagigas

UNIVERSIDAD DE ALCALÁ

ESCUELA POLITÉCNICA SUPERIOR

Programa de Doctorado en Electrónica
Sistemas Electrónicos Avanzados. Sistemas Inteligentes



“Localización de personas mediante sensores inerciales y su
fusión con otras tecnologías”

Autor

Francisco José N. Zampella

Director

Dr. Antonio Ramón Jiménez Ruiz

2017

TESIS DOCTORAL

Resumen

La popularización de los teléfonos inteligentes y los avances (y disminución de costos) de los sistemas satelitales de navegación global (GNSS) han permitido el desarrollo de múltiples sistemas de localización. Éstos permiten ubicar a una persona en un mapa con relativa facilidad, pero debido a los límites de la tecnología GNSS, en ambientes interiores donde no hay línea de visión con los satélites, el posicionamiento satelital presenta severos errores. En estas condiciones se pueden aplicar múltiples técnicas para estimar la posición de la persona de acuerdo a los dispositivos disponibles y las condiciones del lugar. Algunas de las técnicas utilizadas son: navegación inercial y PDR utilizando una IMU, sistemas basados en balizas (UWB, ultrasonido, WiFi, Bluetooth, etc.), señales de oportunidad (TV, celulares, luces, fingerprinting magnético, etc.), reconocimiento de imágenes (geotags, navegación visual, análisis de imágenes estéreo, etc.), observando variables ambientales (campo magnético, presión ambiental, temperatura, etc.), entre otras.

En el presente trabajo de Tesis se aborda el problema de la localización en entornos interiores utilizando sensores inerciales y su fusión con otras medidas para mejorar la estimación y limitar posibles derivas. Para ello, el algoritmo de localización propuesto se divide en tres partes: Una etapa de estimación del movimiento usando Pedestrian Dead Reckoning (PDR), un esquema de fusión de información que permite integrar múltiples tipos de medidas aunque tengan relaciones no lineales, y la utilización de medidas externas (como la potencia de la señal de puntos de acceso WiFi, rangos a balizas UWB, GNSS, etc.) para limitar la deriva, proponiendo mejoras a cada una de ellas.

El algoritmo PDR seleccionado, utiliza una IMU solidaria al pie, y consiste en realizar una estimación inercial con actualizaciones de velocidad cero (ZUPT) en cada apoyo del pie en el suelo. Para mejorar el algoritmo se propone la modificación del detector de apoyo utilizando un filtro de media sobre una ventana retardada. Se comprueba en varios experimentos y simulaciones que este método evita las falsas detecciones de pasos, y mejora la detección del inicio y fin de la fase de apoyo.

Para la estimación y corrección de errores la mayoría de los autores utilizan un filtro de Kalman extendido (EKF), pero para mejorar las relaciones no lineales de los estados (propagación y observaciones), se propone la utilización del filtro de Kalman Unscented (UKF) que simplifica los cálculos necesarios para la estimación y mejora la aproximación no lineal. Después de comparar las estimaciones con ambos filtros ante señales reales y sintéticas se comprueba que el UKF mejora la estimación a cambio de un ligero incremento en la cantidad de cómputo necesaria.

Debido a la falta de información de la guiñada, una estimación PDR pura divergirá con el tiempo. Esta deriva se corrige usualmente observando el campo magnético, pero debido a las perturbaciones encontradas usualmente en interiores, usarlo puede introducir más errores. Para aportar información de la orientación a la estimación se propone medir la rotación del campo magnético de acuerdo a las velocidades angulares observadas en el giróscopo. Al estudiar los resultados de estimación con señales sintéticas y reales se comprueba que se reduce el crecimiento del error de lineal con el tiempo (t) a proporcional a la raíz del tiempo ($t^{1/2}$, equivalente a un

random walk).

Para fusionar la información del PDR con medidas externas se propone la utilización de dos esquemas: el primero, un filtro de límites que establece una distancia máxima entre 2 estimaciones, y el segundo un esquema basado en un filtro de partículas a dos etapas. El filtro de límites modifica la pdf (función de densidad de probabilidad) de las estimaciones para eliminar las probabilidades donde las estimaciones de las posiciones de dos sensores en el cuerpo se encuentran muy distantes entre sí. Ésta se implementa como una corrección de la media y la covarianza, y se comprueba que al fusionar la estimación PDR con una estimación de una IMU con medidas de UWB, se evita la deriva del PDR y se mejora la estimación del sistema UWB.

Se estudia también un esquema basado en un filtro de partículas que utiliza la información de PDR para propagar las partículas y las medidas externas para actualizar los pesos de éstas. Al evaluarlo, se observa que el error real de la estimación crece más rápido que la dispersión obtenida, por lo que se agrega el bias de la velocidad angular a los estados de las partículas para modelar el efecto del *bias random walk* (sesgo de camino aleatorio) del giróscopo. Se comprueba mediante un análisis teórico y simulaciones que el estado adicional aproxima mejor el error esperado.

El filtro de partículas permite utilizar cualquier medida mientras se conozca su función de observación y su distribución de error, por lo que se estudian varios casos de estimaciones PDR fusionadas con medidas de sistemas WiFi, RFID, UWB y ZigBee. Los sistemas RF utilizados tienen un error de posicionamiento de 5 m (90% de los casos) y la estimación PDR tiene un error creciente, pero al fusionar las estimaciones se logra un error inferior a 2 m (90% de los casos).

Por último se utiliza el mapa del edificio para corregir las estimaciones y encauzarlas en las áreas caminables del edificio. Para ello se utiliza un método de eliminación de hipótesis (partículas) que atraviesan paredes. Este algoritmo se optimiza utilizando solo las paredes de la habitación en que se encuentra la partícula y se propone una vectorización de las operaciones para poder ser utilizada en MATLAB a tiempo real. Se demostró con señales reales que el algoritmo es capaz de autolocalizar a una persona si el recorrido es no simétrico, obteniendo un nivel de error que dependerá del edificio, en nuestro caso cercano a 1 m. Si se utilizan medidas RF y el mapa, la estimación converge significativamente más rápido, y el nivel de error y el número de partículas necesarias (por ende el tiempo de cómputo) disminuyen.

Abstract

The popularization of smartphones and the improvements (and cost reduction) of Global Navigation Satellite Systems (GNSS) have promoted the development of many positioning systems. These are able to easily locate a person in a map, but due to the limits of the GNSS technology, in indoor environments, without line of sight to satellites, there is a significant increase in the positioning error. This can be overcome using different techniques to estimate the position of the person according to the environment and the sensors and signals available. Some of the techniques are: inertial navigation and PDR using an IMU, beacon based systems (UWB, ultrasound, WiFi, Bluetooth, etc.), signals of opportunity (TV, mobile networks, light, magnetic fingerprints, etc.), image recognition (geo tags, visual navigation, stereo image analysis, etc.), environmental variables (magnetic field, atmospheric pressure, temperature, etc.) among others.

This thesis focus in the positioning problem in indoor environments using inertial sensors and sensor fusion with external measurements to improve the estimation and to limit the drift. The positioning algorithm is divided into three parts, the estimation of the relative position using Pedestrian Dead Reckoning (PDR), the sensor fusion scheme, that allows the use of the information from multiple sensors, and the external measures (like the Received Signal Strength from WiFi access points, ranges to UWB devices, GNSS measurements, etc.) used to limit the drift in the estimation. Each part is studied, proposing improvements to reduce the error level.

In this research PDR was implemented based on the measurements of an IMU in the foot of a person, generating an Inertial Navigation System with zero velocity updates during the stance phases of the walk pattern. The algorithm is improved modifying the stance detection to filter the output using the median of a delayed window sample. The new stance detection is tested with real IMU measurements and synthetic signals, showing that the method avoids false detections and improves the initial and final points of the stance phase.

The position and orientation of the person is usually estimated using an Extended Kalman filter (EKF), but as a way to improve the propagation and corrections of the non linear states this thesis proposes the use of an Unscented Kalman filter (UKF). Both filters' estimations were tested using real and synthetic data, where it is observed that the estimation improves with the UKF, at the cost of a small increase in the computing time.

The yaw state in a PDR estimation is usually non observable with only ZUPT measurements, therefore a common solution is the use of magnetic field measurements. In indoor environments the field is affected by the metallic structures of the building, and its direct use introduces errors in the estimation, therefore a measurement of the rotation of the magnetic field according to the gyroscope measurements is proposed. This Magnetic Angular Rate Update (MARU) reduces the rate of growth of the heading error from linear with time to linear to the squared root of the time.

To reduce the drift of PDR, it was fused with external measurements using two proposed schemes, a constraint filter that limits the distance between two estimations and a two level estimation using a particle filter. The constraint filter modifies the pdf of the estimations to eliminate the probabilities where the estimations of the position of two sensors in the body are too far away from each other. The constraint is implemented as a correction of the mean and

covariance of the states and when tested fusing foot-mounted PDR, with the estimation of an IMU in the head with UWB position updates, it limited the drift of PDR and reduced the error level of the IMU-UWB system.

The second scheme used was a two level estimation based on a particle filter (high level) that propagated the particles using the information from a PDR estimation (low level) and used the external measurements to update the weights. It was observed that the real error of the estimation grows faster than the particle dispersion, therefore a new state was added to the particles to estimate the bias of the turn rate as a way to model the effect of the bias random walk in the gyroscope. The theoretical and simulated results showed a particle dispersion closer to the real error growth.

The use of a particle filter allows the implementation of a wider variety of measurements using only the observation function and the error distribution, therefore several measurements from WiFi, RFID, UWB or ZigBee were fused with the PDR estimation. The positioning systems used presented errors of approximately 5 *m* (90 % of the time), while PDR had a growing with time/distance error, that after fused was able to provide a 2 *m* error (90 % of the time).

Finally, the map of the building was used to correct the estimation according to the walkable areas of the estructure (map matching). To achieve this, the hypothesis (particles) that crossed walls were eliminated. The algorithm was optimized to use only the walls of the room the particle is in, and it was implemented using Matrix operations to be able to run in real time in MATLAB. Using real signals it was proven that the algorithm was capable of locating himself using only the map of the building, the PDR information (initial position was not provided) and a non symmetrical path. The error level will depend on the map, but for our experiment it was observed to be around 1 *m*. The map matching algorithm when fused with the use of RF information showed a significantly faster convergence, a reduced error level and requires fewer particles to avoid deprivation (therefore it will be faster).

A mi esposa Mary, y mis hijos Allegra y Massimo

Agradecimientos

En primer lugar quisiera agradecer a mi director de tesis, Antonio R. Jiménez Ruiz, y mi tutor, Jesús Ureña Ureña, por el constante apoyo que he recibido a lo largo de mi periodo como doctorando, por sus comentarios y revisiones que han moldeado este trabajo, por las discusiones e intercambios de ideas que me han permitido profundizar mis conocimientos en el área, y hasta por ayudarme a realizar todas las pruebas a lo largo del doctorado. En especial quisiera agradecer a Antonio por confiar en mí y apoyarme para poder terminar este trabajo.

A Fernando Seco, por sus comentarios, recomendaciones e ideas que me han permitido mejorar como investigador, y sus excelentes revisiones de mis publicaciones que han mejorado enormemente mi trabajo. A J. Carlos Prieto y Jorge Guevara, por sus conversaciones y comentarios que me ayudaron a formar parte del grupo de investigación LOPSI.

Al personal del Centro de Automática y Robótica por su ayuda a lo largo de mi tiempo como doctorando. A los compañeros de LEMUR y luego LORIS, por ser un excelente punto de intercambio de ideas, en especial a Javier y Alfonso, por su valiosa contribución en lo que sería el esquema de fusión base de este trabajo. A la Universidad de Alcalá por ser mi segunda Alma Mater y por todo lo que me enseñaron.

A Patrick Robertson, Luigi Bruno, Mohammed Khider y Michael Angermann, por recibirme en el DLR y por las discusiones en las tardes que llevaron a desarrollar la primera parte de la tesis. A Peter Handel, John-Olof Nilsson e Isaac Skog por sus conversaciones durante la estancia en el KTH, donde logré profundizar sobre la estimación Bayesiana. A la beca JAE preDOC del CSIC por permitirme realizar mi doctorado y abrirme las puertas al mundo de la investigación.

Sobre todo quisiera darles las gracias a mi familia, a mi esposa Mary, por apoyarme constantemente y ayudarme en todo lo que puedes, sin tu empuje jamás habría podido realizar esto. A mis hijos Allegra y Massimo, son la alegría de mi vida y me dan la fuerza para seguir adelante.

Índice general

I Planteamiento	1
1. Introducción	3
1.1. Historia y Motivación	5
1.2. Problemática asociada	7
1.2.1. Errores derivados del entorno	7
1.2.2. Errores derivados del sensor utilizado	7
1.3. Planteamiento y objetivos iniciales	8
1.4. Estructura de la Tesis	9
2. Estado del arte y objetivos de la Tesis	11
2.1. Unidad de medida inercial (IMU)	14
2.1.1. Acelerómetro	14
2.1.2. Giróscopo	15
2.1.3. Fuentes de error en la medida	16
2.1.4. Sistema de navegación inercial	19
2.2. Detección de pasos y fases de apoyo	20
2.3. Fusión de información	22
2.3.1. Filtros paramétricos	22
2.3.1.1. Filtros de Kalman Extendido	23
2.3.1.2. Filtros de Kalman Unscented	23
2.3.2. Filtros no paramétricos	26
2.3.2.1. Filtro de rejilla de probabilidad	26
2.3.2.2. Filtros de partículas	27
2.3.3. Propagación de la estimación con sensores inerciales	30
2.3.3.1. Propagación de los estados basada en pasos	30
2.3.3.2. Propagación de los estados basada en INS	31
2.4. Métodos de corrección de la deriva	33
2.4.1. Restricciones de movimiento	34
2.4.1.1. Actualizaciones de velocidad cero (ZUPT)	34
2.4.1.2. Actualizaciones de velocidad angular cero (ZARU)	34
2.4.1.3. Direcciones predominantes de movimiento	35
2.4.1.4. Correcciones utilizando el mapa del edificio	36
2.4.1.5. Correcciones por reconocimiento de acciones	37
2.4.2. Utilización de sensores internos	38
2.4.2.1. Barómetros	38
2.4.2.2. Magnetómetros	39
2.4.2.3. Visión artificial	40
2.4.3. Utilización de medidas externas	41
2.4.3.1. Medidas de sistemas de posicionamiento por satélites	41

2.4.3.2.	Medidas de sistemas de posicionamiento locales	42
2.4.3.3.	Ángulos de incidencia	43
2.4.3.4.	Distancias a balizas	44
2.5.	Discusión y enmarque de la Tesis	45
2.6.	Objetivos específicos de la Tesis	46
II	Desarrollo	49
3.	Mejoras a la localización con PDR	51
3.1.	Detección del apoyo	54
3.1.1.	Certeza del apoyo	55
3.1.2.	Pruebas con señales reales	56
3.2.	Uso del filtro de Kalman Unscented	56
3.2.1.	Etapas del filtro UKF	58
3.2.2.	Diferencias entre el EKF y el UKF	59
3.2.2.1.	Estimación del bias en el giróscopo y el acelerómetro	60
3.2.2.2.	Estimación de la posición y orientación	60
3.2.3.	Tiempos de ejecución	61
3.3.	Uso del campo magnético en ambientes interiores	64
3.3.1.	Características del campo magnético en interiores	64
3.3.2.	Rotaciones del campo magnético	65
3.3.2.1.	Rotación magnética en un UKF	67
3.3.2.2.	Rotación magnética linealizada en un EKF	67
3.3.3.	Influencia de las perturbaciones magnéticas en la estimación	69
3.3.4.	Pruebas con señales reales	69
3.3.5.	Tiempos de ejecución	70
3.4.	Conclusiones	72
4.	Esquema de fusión de información	75
4.1.	Fusión de estimaciones con una distancia máxima entre ellas	78
4.1.1.	Constraint filter	78
4.1.1.1.	Proyección de la estimación	79
4.1.2.	Truncado de la función de densidad de probabilidad	79
4.1.2.1.	Cálculo de las integrales	80
4.1.2.2.	Transformación de estados	81
4.1.3.	Distancia máxima entre puntos de estimación	82
4.1.4.	Pruebas realizadas	83
4.1.4.1.	Prueba de Monte Carlo	83
4.1.4.2.	Pruebas con medidas reales	84
4.2.	Uso de PDR como modelo de desplazamientos en un filtro de partículas	87
4.2.1.	Esquema de estimación a dos niveles	88
4.2.1.1.	Nivel bajo, Pedestrian Dead Reckoning	88
4.2.1.2.	Nivel alto, filtro de partículas	89
4.2.2.	Modelo adaptativo de desplazamientos por pasos	91
4.2.3.	Cota inferior de Cramér-Rao	93
4.2.4.	Modelado del bias en la propagación	95
4.3.	Conclusiones	97

5. Utilización de métodos de corrección de la deriva	99
5.1. Utilización de medidas externas	102
5.1.1. Introducción de medidas RF	102
5.1.2. Fusión de PDR con potencia de la señal y tiempo de vuelo	107
5.1.3. Fusión de PDR con TDOA y AOA UWB, y RSS RFID	111
5.2. Map matching	117
5.2.1. Vectorización de la detección de cruces por paredes	117
5.2.2. Grupos de partículas y estructura del mapa	119
5.2.3. Pruebas realizadas	122
5.2.3.1. Autolocalización con PDR y mapas	122
5.2.3.2. Efecto del bias en la estimación en Map matching	123
5.2.3.3. Tiempo de cómputo y número de partículas	125
5.3. Medidas externas y Map matching	128
5.3.1. Inicialización de las partículas	128
5.3.2. Pruebas realizadas	129
5.3.3. Tiempo de cómputo y número de partículas necesarias	133
5.4. Conclusiones	134
III Conclusiones	137
6. Conclusiones y aportaciones	139
6.1. Conclusiones específicas por objetivos	141
6.1.1. Mejoras en la localización con PDR (Objetivo 1)	142
6.1.2. Esquema de fusión de información (Objetivo 2)	143
6.1.3. Métodos de corrección de la deriva (Objetivo 3)	144
6.2. Principales aportaciones	146
6.3. Publicaciones	147
6.3.1. Revistas Internacionales	147
6.3.2. Patentes	148
6.3.3. Conferencias Internacionales	148
6.3.4. Estancias de investigación Internacionales	148
6.3.5. Otras Publicaciones como coautor	148
6.4. Trabajos futuros	150
7. Conclusions and innovations	151
7.1. Objective specific conclusions	153
7.1.1. Improvements to the PDR positioning (Objective 1)	154
7.1.2. Sensor fusion scheme (Objective 2)	155
7.1.3. Drift correction methods (Objective 3)	156
7.2. Main innovations	158
7.3. Published work	159
7.3.1. International Journals	159
7.3.2. Patents	159
7.3.3. International conferences	160
7.3.4. International research visits	160
7.3.5. Other publications as coauthor	160
7.4. Future research subjects	161
8. Bibliografía	163

Índice de figuras

2.1. Esquema general de algoritmos de posicionamiento por sensores inerciales.	13
2.2. Métodos para la medición de la aceleración	15
2.3. Métodos para la medición de la velocidad angular	16
2.4. Análisis de la Varianza de Allan para la IMU MTi de XSense	18
2.5. Segmento de la aceleración y giros grabados durante el caminado.	21
2.6. Comparación de diferentes métodos de propagación de la media y la covarianza .	24
2.7. Propagación de la posición basado en concatenación de pasos	31
2.8. Posición de la IMU en el pie	33
2.9. Cambio del campo magnético medido originado por la rotación de la IMU.	40
2.10. Arreglo de antenas en 3 dimensiones para medir el AoA	44
2.11. Objetivos específicos planteados en cada uno de los bloques del esquema PDR. .	47
3.1. Esquema PDR generalizado destacando las aportaciones en el algoritmo.	53
3.2. Señales de la IMU y detección del apoyo	54
3.3. Señales de apoyo y certeza propuestas obtenidas de señales sintéticas	56
3.4. Señales de apoyo y certeza propuestas obtenidas de señales reales	57
3.5. Esquema del algoritmo de PDR utilizando un UKF.	59
3.6. Evolución de las estimaciones del bias de una IMU para un EKF y un UKF	60
3.7. Evolución de la guiñada utilizando PDR en un EKF con ZUPT	62
3.8. Evolución de la guiñada utilizando PDR en un UKF con ZUPT	62
3.9. Evolución de los errores de posición y guiñada para un EKF y un UKF	63
3.10. Estimaciones de la posición usando EKF con y sin Magnetómetro	65
3.11. Cambio en el vector de campo magnético del sensor debido a una rotación	66
3.12. Cambio en el vector de campo magnético del sensor y su linealización	68
3.13. Trayectorias reconstruidas en presencia de perturbaciones magnéticas	70
3.14. Análisis del error cuadrático medio para el MARU	71
3.15. Estimación de la posición utilizando el UKF, MARU y MARU suave en el CAR . . .	72
4.1. Esquema PDR generalizado destacando las aportaciones en fusión de información	77
4.2. Estudio de los límites de distancias entre el pie y la cabeza	83
4.3. Estimación de la posición de una señal sintética con y sin filtro de límites	84
4.4. Evolución del error para estimaciones con y sin filtro de límites	85
4.5. Equipo utilizado para la evaluación del sistema	86
4.6. Recorridos obtenidos con y sin el filtro de límites	86
4.7. Esquema propuesto usando una estimación a dos niveles	87
4.8. Propagación de las partículas usando los desplazamientos de PDR	90
4.9. Distribución del error de posición y orientación en pasos PDR	92
4.10. Evolución del rmse para PDR y la estimación a dos niveles	95
4.11. Evolución del RMSE para PDR y la estimación a dos niveles con y sin bias	97

5.1.	Esquema PDR destacando las aportaciones en correcciones de la deriva	101
5.2.	Posición de los diferentes dispositivos RF instalados en el CAR	102
5.3.	Proceso de estimación de la posición utilizando el filtro de partículas	104
5.4.	Trayectoria simulada y posición de las balizas a utilizar.	105
5.5.	Evolución de las CRLB de posicionamiento RSS, PDR y su fusión	106
5.6.	Evolución de los RMSE de posicionamiento RSS, PDR y su fusión	106
5.7.	Recorrido en el edificio ETSIT y dispositivos WiFi y ZigBee usados	109
5.8.	Posición de una persona en el edificio ETSIT utilizando WiFi y PDR	110
5.9.	Posición de una persona en el edificio ETSIT utilizando ZigBee y PDR	110
5.10.	CDF de las distribuciones de error por fusión y posicionamiento RF	111
5.11.	Relación de las medidas de elevación φ y acimut λ del sensor Ubisense	113
5.12.	Dispositivos utilizados en el experimento con PDR, UWB y RFID	114
5.13.	Trayectoria, sensores y tags utilizados en el experimento	115
5.14.	Estimación de la posición utilizando PDR con medidas de RFID y/o UWB	116
5.15.	CDF del error de posición utilizando PDR con medidas de RFID y/o UWB	116
5.16.	Ejemplo de detección de intersecciones entre segmentos de líneas	118
5.17.	Ejemplo de estructura del mapa utilizado	122
5.18.	Estimación de la posición utilizando PDR y Map matching, sin posición inicial	124
5.19.	Error cuadrático medio y clusters usando medidas RSS o map matching	125
5.20.	Evolución de las nubes de partículas para estimaciones con o sin bias	126
5.21.	Evolución de las nubes de partículas con map matching y medidas externas	131
5.22.	Evolución del número de hipótesis con map matching y medidas externas	132
5.23.	CDF de PDR con map matching y/o medidas RSS	132
6.1.	Esquema general de algoritmos de posicionamiento por sensores inerciales.	141
7.1.	Specific objectives defined in each of the blocks of the positioning system scheme.	153

Índice de tablas

3.1. Tiempos de ejecución para los filtros estudiados	64
3.2. Tiempos de ejecución de los métodos MARU	71
5.1. Tiempo de ejecución de los diferentes algoritmos de Map matching estudiados . .	128
5.2. Niveles de error para localizaciones con Map matching y/o medidas externas . .	130
5.3. Tiempo de ejecución para algoritmos PDR con map matching y/o medidas RSS .	133

Nomenclatura

$\sigma_{\text{Allan}}(\tau)$	Varianza de Allan para un periodo τ
$\boldsymbol{\omega}$	Velocidad angular
$\ddot{\mathbf{r}}$	Aceleración
$\ddot{\mathbf{r}}^b$	Aceleración del sensor
$\ddot{\mathbf{r}}^n$	Aceleración del sistema de navegación
$\dot{\mathbf{r}}^n$	Velocidad en el sistema de navegación
\mathbf{r}^n	Posición en el sistema de navegación
C_b^n	Matriz de rotación del sistema del sensor al de navegación
\hat{C}_b^n	Estimación de la Matriz de rotación del sistema del sensor al de navegación
$\Delta\Psi$	Error de orientación, tal que $C_b^n = e^{[\Delta\Psi \times]} \cdot \hat{C}_b^n$
$\Delta\boldsymbol{\omega}$	Bias del giróscopo
$\Delta\mathbf{r}$	Error de posición
$\Delta\dot{\mathbf{r}}$	Error de velocidad
$\Delta\mathbf{a}$	Bias del acelerómetro
Ω_{nb}^b	Matriz skew simétrica de rotación
$\mathbf{x}(k)$	Estados en el instante k
$\hat{\mathbf{x}}(k)$	Predicción de los estados en el instante k
\hat{P}_{xx}	Predicción de la covarianza de los estados
$\hat{P}(k)$	Estimación de la covarianza de los estados en el instante k
$\Phi(k)$	Matriz de transición de estados, Jacobiano de la función de propagación de estados

$H(k)$	Matriz de observación, Jacobiano de la función de observación
Q	Covarianza del ruido de la función de propagación de estados
R	Covarianza del ruido de la medida
$[\mathbf{a} \times]$	Matrix antisimétrica que transforma el producto cruz en una multiplicación por una matriz
Acc	Medición de la aceleración en el acelerómetro [m/s ²]
Gyr	Medición de las velocidades angulares en el giróscopo [rad/s]
$T_a(S)_{(k)}$	Detección de la fase de apoyo utilizando el método a sobre la señal S en el instante k
$\mathbf{B}(k)$	Campo magnético medido en el instante k
$\Delta\mathbf{B}^b(k)$	Cambio en el campo magnético observado en el sistema de referencia del sensor
$x^{(i)}(k)$	Estados de la partícula i en el instante k
$w^{(i)}(k)$	Peso de la partícula i en el instante k
$\mathbf{m}(k), \mathbf{z}(k)$	Medida u observación en el instante k
$h(\mathbf{x})$	función de observación basado en los estados \mathbf{x}
\mathbf{J}_k	Matrix de información de Fisher en el instante k
$\phi(z; h(\mathbf{x}), \sigma)$	Valor de la función de probabilidad Gaussiana evaluado en z cuando la media de la distribución es $h(\mathbf{x})$ y la desviación estándar es σ
λ_i	Acimut del tag con respecto al sistema de referencia del sensor
φ_i	Elevación del tag con respecto al sistema de referencia del sensor
\mathbf{r}^{u_i}	Posición del tag en el sistema de referencia del sensor UWB u_i
\mathbf{l}^s	s -ésimo segmento de pared definido entre l_1^s y l_2^s
\mathbf{p}^i	i -ésimo segmento de trayectoria PDR definido entre p_1^i y p_2^i

Lista de Acrónimos

AOA	Angle of Arrival (ángulo de incidencia)
AVA	Analysis o estudio de la Varianza de Allan
ARW	Angle Random Walk (caminado aleatorio de ángulo)
CDF	Cumulative distribution function (función de distribución de probabilidad acumulada)
CRLB	Cramér-Rao lower bound (cota inferior de Cramér-Rao)
EKF	Extended Kalman filter (filtro de Kalman Extendido)
GNSS	Global Navigation Satellite System (Sistema global de navegación por satélites)
GLRT	Generalized Likelihood Rate Test (Prueba de la tasa de semejanza generalizada)
IMU	Inertial Measurement Unit (Unidad de Medida Inercial)
INS	Inertial Navigation System (Sistema de Navegación Inercial)
kNN	k-nearest neighbors (k vecinos más cercanos)
LOS	Line Of Sight (Línea de visión)
LPS	Local Positioning System (sistema de posicionamiento local)
MARU	Magnetic Angular Rate Update (actualización de rotación magnética)
MEMS	Micro Electro Mechanical System
MLE	Maximum Likelihood Estimator (estimador de máxima verosimilitud)
NLOS	Non Line Of Sight (sin línea de visión)
pdf	probability density function (función de densidad de probabilidad)
PDR	Pedestrian Dead-Reckoning (Localización mediante sensores inerciales de un peatón)
PF	Particle filter (filtro de partículas)

RF	Radiofrecuencia
RMSE	Root mean squared error (error cuadrático medio)
RTT	Round Trip Time (tiempo de ida y vuelta)
SIFT	Scale Invariant Feature Transform [1]
SIR	Sequential Importance Resampling (remuestreo secuencial de la importancia)
SIS	Sequential Importance Sampling (muestreos de importancia secuencial)
SLAM	Simultaneous Location And Mapping (Autolocalización y Mapeo)
SURF	Speed-up Robust Features [2]
TDOA	Time Difference of Arrival (Diferencia en los tiempos de vuelo)
TOA	Time of Arrival (Tiempo de vuelo)
UKF	Unscented Kalman Filter (filtro de Kalman Unscented)
US	Ultra Sonido
UT	Unscented Transformation (transformación Unscented)
UWB	Ultra Wide Band (banda ultra ancha)
VRW	Velocity Random Walk (caminado aleatorio de velocidad)
ZARU	Zero Angular Rate Update (Actualización de velocidad angular cero) [3]
ZUPT	Zero velocity UPdaTe (actualización de velocidad cero)

Parte I

Planteamiento

Capítulo 1

Introducción

Introducción

Los avances en la tecnología han permitido el desarrollo de una gran cantidad de dispositivos para facilitar la vida de las personas y han creado un enorme mercado de aplicaciones y servicios para asistir a los usuarios. Éstos han evolucionado enormemente y actualmente se adaptan a la persona, el ambiente y las circunstancias, y por ende hacen uso de la posición de la persona o el dispositivo. Las personas comúnmente usan referencias visuales para ubicarse en entornos conocidos, pero es necesario encontrar métodos y algoritmos automáticos que permitan a los dispositivos obtener un posicionamiento y poder actuar de acuerdo a éste.

Saber la posición en el ambiente es una información fundamental para muchas especies, es por ello que la raza humana ha utilizado múltiples técnicas de posicionamiento y navegación desde tiempos inmemoriales. Los primeros marinos utilizaban el sol, la luna y las estrellas para orientarse debido a la falta de referencias geográficas en el mar. Este posicionamiento básico fue mejorado a lo largo de siglos con el desarrollo de innumerables herramientas como la brújula, el astrolabio, el sextante, el cronómetro, entre muchos otros. Sin duda entre las mayores aportaciones al posicionamiento actual se encuentra el desarrollo de las unidades de medida inercial (IMU) y los sistemas globales de navegación por satélite (GNSS). Éstos son capaces de proveer un posicionamiento global y automático en ambientes exteriores, pero presentan problemas dentro de edificios o en lugares sin línea de visión (NLOS) a los satélites, por lo que en la presente Tesis Doctoral se buscará desarrollar técnicas para el posicionamiento en interiores.

En el presente capítulo se expondrán los motivos para la realización de esta investigación, para luego pasar a plantear la problemática asociada. Posteriormente se establecerá el planteamiento y los objetivos iniciales y por último se presentará la estructura de la Tesis Doctoral.

1.1. Historia y Motivación

El posicionamiento (conocer la posición) y la navegación (cómo llegar a un lugar específico) han sido desde la antigüedad muy importantes debido principalmente al comercio, la pesca y la guerra. En tierra firme los viajeros utilizaban una técnica conocida como pilotaje [4, 5] en la que se valían de referencias para seguir un camino a un destino deseado.

En el mar las embarcaciones solo podían hacer pilotaje cuando navegaban por la costa. Si los marinos se desplazaban mar adentro debían confiar en otras referencias para poder llegar a su destino, es así como los marinos polinesios [6] y los fenicios [4] utilizaron las estrellas y las pocas referencias geográficas en el mar para navegar el Océano Pacífico y el Mar Mediterráneo respectivamente. Se cree que los fenicios utilizaban la estrella Polar (actualmente Polaris o α Ursae Minoris) para orientarse en el mar.

Esta navegación primitiva dependía de observaciones de las estrellas, pero cuando las condiciones climáticas no eran favorables otros métodos eran necesarios para evitar navegar a la deriva. Es así como uno de los primeros y más importantes instrumentos de navegación fue descubierto, la brújula. Se cree que los marinos vikingos y chinos [7] descubrieron las propiedades de la magnetita y la utilizaban para magnetizar una aguja que suspendida en agua les permitía conocer el norte aun cuando no veían el cielo. Con estos descubrimientos se utilizaba el *Deduced Reckoning* (posteriormente acuñado *Dead Reckoning*, por su peligrosidad) para deducir la trayectoria de las embarcaciones a partir de las velocidades y orientaciones, sumando los trayectos a partir de un punto de salida.

Navegadores antiguos ya tenían idea de la forma esférica de la tierra y utilizando instrumentos

como el astrolabio podían medir la latitud, observando la elevación de la estrella polar, u otras estrellas, con respecto al horizonte [7]. Entre ellos, Cristóbal Colón en su viaje a América en 1492 se valió de brújulas y astrolabios, entre otros, para trazar la ruta al nuevo continente.

Ya en el siglo XVI se tenía la idea de que para ubicarse en el planeta sería necesario una latitud y una longitud. La primera podía ser medida con relativa facilidad (para ese momento con errores de varios grados, aunque posteriormente mejorado con la invención del sextante), pero la segunda requería de una medición exacta del tiempo para poder calcular la diferencia de hora entre algún meridiano de referencia (hubo muchos) y el punto a localizar.

El principal problema de los relojes de la época se debía a las derivas de minutos al día (mucho más si el reloj se encontraba dentro de un barco), lo que se traducía en errores de varios kilómetros. Muchos países buscaron solucionar el problema de la longitud, proponiendo referencias temporales en el cielo como el paso de las lunas de Júpiter, o la ocultación de estrellas y planetas por parte de la Luna, pero no fue hasta la invención y fabricación de un cronómetro lo suficientemente preciso por John Harrison en el siglo XVIII que se pudo determinar la longitud con errores aceptables.

Durante la Segunda Guerra Mundial se generaron dos grandes avances en sistemas de posicionamiento, la navegación inercial y el desarrollo de sistemas de posicionamiento por RF. El primero está basado en reconstruir el movimiento de un vehículo midiendo sus aceleraciones y velocidades angulares, usando acelerómetros y giróscopos respectivamente. El conjunto de tres acelerómetros y tres giróscopos es la unidad de medida inercial (IMU), que suele estar acompañado de un magnetómetro para obtener medidas absolutas de orientación.

Los sistemas de posicionamiento por RF utilizan la distancia a radiobases en posiciones conocidas, obtenida midiendo el tiempo que tardan las señales en llegar del vehículo a la radiobase o los cambios en la frecuencia percibida debido al efecto Doppler. Con las distancias (o diferencias en las distancias, si el vehículo no está sincronizado con la radiobase) es posible estimar la posición haciendo una trilateración esférica (o hiperbólica). Las diferencias de frecuencia percibida se pueden asociar a diferencias de distancias radiales, que con suficientes referencias se pueden asociar a una posición.

Extrapolando la idea de la trilateración y buscando una máxima disponibilidad se desarrollaron los GNSS que utiliza satélites como puntos de referencia, y relojes atómicos ultra estables para mantener la sincronía. El sistema desarrollado por Estados Unidos, el GPS, con un costo de aproximadamente 10 mil millones de dólares es el sistema más utilizado, aunque hay otros sistemas como el GLONASS de Rusia, el BEIDOU en desarrollo por China y el GALILEO en desarrollo para la Union Europea.

Adicionalmente con los avances en los circuitos integrados y los sistemas Micro Electro Mecánicos (MEMs) se han podido desarrollar acelerómetros, giróscopos, magnetómetros, etc. en un solo chip, reduciendo los costos y el tamaño de cada instrumento. Esto ha permitido en la actualidad que un teléfono móvil inteligente pueda llevar una IMU para calcular su orientación y desplazamiento entre otros, a un precio razonable.

La mayor parte de estos desarrollos han sido asociados a sistemas de localización globales, donde se desea conocer la posición de una persona o vehículo en el mundo y se obtiene una posición fiable cuando éste se encuentra en ambientes exteriores. Si la persona se encuentra dentro de un edificio (donde pasamos la mayor parte del tiempo) o tiene poca visibilidad del cielo (y por ende de los satélites) es necesario un sistema que mantenga la posición y sea capaz de utilizar las señales percibidas dentro de éste para localizar a los usuarios. Este tipo de sistemas se conocen como sistemas de localización para interiores y debido a la variedad de sistemas RF pre-instalados y tecnologías disponibles hay una gran cantidad de técnicas individuales de

posicionamiento disponibles.

Las dos técnicas de posicionamiento más comunes son las basadas en balizas y las basadas en navegación inercial. La primera utiliza mediciones de ángulos o distancias a balizas RF, de ultrasonido (US), ópticas, etc. ubicadas en posiciones conocidas para estimar la posición del usuario. Los métodos de navegación inercial se basan en reconstruir el desplazamiento de las personas midiendo sus giros, velocidades y aceleraciones, ya sea utilizando IMUs o cámaras.

Cada una de las técnicas propuestas tiene sus ventajas y desventajas, por lo que una solución robusta y fiable debe tener en cuenta todos los sistemas disponibles y fusionar la información de una manera eficiente. La presente Tesis Doctoral se enfocará en estudiar las técnicas de posicionamiento para interiores basadas en navegación inercial y proponer métodos para fusionar información de otros sistemas que hagan más robusto y preciso el posicionamiento.

1.2. Problemática asociada

No existe una solución absoluta de posicionamiento para todas las situaciones utilizando una sola tecnología, sino métodos y sensores que se adaptan a situaciones específicas. En exteriores los GNSS ofrecen un posicionamiento absoluto con errores del orden de algunos metros cuando se dispone de línea de visión con los satélites, pero en ciudades con edificios altos, túneles o en presencia de cualquier objeto que limite la visibilidad de éstos, la precisión disminuye significativamente. Dentro de los edificios el posicionamiento mediante GNSS no es posible o está muy deteriorado, por lo que se debe emplear otra tecnología alternativa. Suelen utilizarse múltiples técnicas para obtener la posición, éstas podrían separarse en métodos basados en balizas y métodos basados en navegación inercial, cada técnica con sus ventajas y desventajas. A continuación presentamos sus principales fuentes de error.

1.2.1. Errores derivados del entorno

A diferencia de los espacios exteriores donde es posible tener línea de visión con las balizas utilizadas, en la mayoría de los ambientes interiores, las paredes generan reflexiones y refracciones de las señales RF, lo que altera sus ángulos de incidencia, tiempos de vuelo y potencia de las señales recibidas. Esto dificulta modelar la distancia y ángulos a los puntos de referencia y requiere la utilización de modelos calibrados específicamente para el ambiente, lo que hace menos robusto el sistema ante modificaciones del ambiente.

Los sensores inerciales pueden estar afectados por variaciones de la temperatura, sin embargo estos incluyen termómetros digitales y estudian la variabilidad de las medidas con respecto a la temperatura para ayudar a minimizar el efecto sobre la medida. En cambio, el campo magnético observado en el dispositivo, comúnmente utilizados para obtener las referencias de orientación en las IMU, se ve afectado por las estructuras metálicas de los edificios, lo que dificulta su utilización.

1.2.2. Errores derivados del sensor utilizado

Todos los sensores utilizados presentan errores debidos a ruidos, errores de cuantización y bias de la medida, así como posibles errores de linealidad y saturación de la medida, sin embargo cada sistema tiene sus propias fuentes adicionales de error. Los sistemas de posicionamiento por potencia de la señal tienen el problema de que la potencia emitida puede variar con el tiempo debido a la descarga de la batería o a cambios en la sensibilidad de las antenas utilizadas.

Para poder medir los tiempos de vuelo de señales RF es necesario relojes muy precisos, que la mayoría de los dispositivos comunes no tienen, por lo que los errores de cuantización pueden generar errores de distancias de varios metros.

Los sensores inerciales necesitan integrar sus medidas para poder obtener estimaciones de la posición. Errores en la medida como la no perfecta ortogonalidad de los ejes de medida, errores de escalado, el nivel de ruido y el bias en las medidas, generan que en la integración, el error de posición crezca con el cubo del tiempo. Para mantener la posición estable a pesar de las múltiples integraciones es necesario utilizar IMUs con un nivel de error muy bajo, pero estos dispositivos son de gran volumen, peso y alto costo, por lo que no pueden ser llevados por un peatón. Las únicas IMU de bajo costo, peso y volumen, son los dispositivos MEMs, pero debido a los niveles de ruido y bias de estos, las estimaciones solo serán válidas por pocos segundos y son necesarias correcciones de posición, velocidad u orientación. Una solución común para limitar la deriva de la navegación inercial es la utilización de correcciones de velocidad cero (posibles si la IMU está ubicada en el pie de la persona), aún así el error en estos sistemas crece linealmente con la distancia recorrida, por lo que el sistema diverge.

1.3. Planteamiento y objetivos iniciales

En la presente tesis se propone investigar y desarrollar un sistema de posicionamiento para interiores capaz de proveer la posición del usuario de forma ininterrumpida. No existe una tecnología capaz de adaptarse a cada ambiente, por lo que un sistema robusto necesitará la fusión de múltiples fuentes de información. En particular se propone un sistema basado en la utilización de sensores inerciales para obtener los desplazamientos y cambios de ángulo de la persona. Adicionalmente se utilizarán las mediciones de las señales emitidas por balizas distribuidas en el entorno, para ubicar de manera absoluta al usuario y limitar el crecimiento del error de posición.

Bajo este planteamiento se proponen los siguientes objetivos:

- Estudiar los métodos de posicionamiento por sensores inerciales y balizas, y proponer mejoras independientes a cada sistema de localización, buscando obtener la mejor estimación de cada sistema.
- Estudiar los sensores disponibles en los sistemas de localización utilizados (magnetómetros, barómetros, módulos WiFi, etc.) y proponer métodos para aprovechar las medidas y hacer más robusta cada estimación.
- Revisión del estado del arte de métodos de fusión de sensores. Es necesario adaptar o conseguir un método de estimación flexible que permita tratar la información con alta tasa de muestreo de los sensores inerciales, así como múltiples medidas posiblemente no lineales asociadas los métodos de corrección de la deriva.
- Estudiar métodos de fusión de la información para mediciones de diferentes tipos, tasas de muestreo, etc. Se buscará un esquema de fusión flexible que permita adaptar cualquier tipo de medida.
- Estudio e implementación de los métodos de estimación de la posición a varios niveles. Mediante la división del problema en subfases o niveles, se puede simplificar el tratamiento de cada señal y paralelizar el trabajo en el caso de disponer de múltiples plataformas.
- Comparación de los métodos de estimación en filtro único y en varios niveles de jerarquía. Se busca determinar las ventajas de cada tipo de filtro para la estimación a realizar.

- Estudiar la posibilidad de implementar la estimación en plataformas móviles (tablets, móviles, etc) ordenadores portátiles, de escritorio, servidores. Se estudiarán los requerimientos de cómputo para determinar cómo distribuir el procesamiento y obtener un estimado de la posición.

Los objetivos presentados se engloban en las tareas 8 a 11, 16 y 20 del Proyecto de Investigación Fundamental no orientada “Sistemas Cooperativos de Localización para Personas y Objetos en Entornos Diversos (LORIS)” en el que participan el grupo GEINTRA de la Universidad de Alcalá de Henares y el grupo LOPSI del Centro de Automática y Robótica. Adicionalmente forma parte del proyecto de Beca Pre Doctoral “Localización de personas en el interior de edificios mediante sensores inerciales y su fusión con otras tecnologías” de la Junta de Ampliación de Estudios del Consejo Superior de Investigaciones Científicas.

1.4. Estructura de la Tesis

Para lograr los objetivos previamente propuestos se utilizará la siguiente estructura de la Tesis:

- El segundo capítulo plantea un estado del arte de las técnicas comúnmente utilizadas para posicionamiento en interiores y métodos de fusión de información. Posteriormente propondrá una discusión sobre los aspectos mejorables y la declaración detallada de los objetivos de la tesis.
- El tercer capítulo estudiará y detallará las implementaciones del método de posicionamiento por sensores inerciales y propondrá posibles mejoras a los algoritmos existentes. En particular se propondrá un algoritmo de detección de pasos, un filtro de fusión de información basado en el filtro de Kalman Unscented y la medición de las rotaciones de la IMU observando el cambio en el campo magnético.
- El cuarto capítulo propondrá algoritmos de fusión de información basados en las estimaciones obtenidas con los sensores inerciales. En particular propondrán algoritmos de fusión de información basados en filtros de límites, y se propondrá una mejora a la propagación por longitud y cambio de orientación del paso en un filtro de partículas.
- El quinto capítulo estudiará la inclusión de posibles medidas externas o adicionales a la de la IMU, en el algoritmo de fusión de información. Entre las medidas estudiadas se tratará la potencia de la señal recibida, tiempos de vuelo, ángulos de incidencia y se propondrá un esquema de utilización de medidas de acuerdo al área en que se encuentra la estimación.
- El sexto capítulo presentará las conclusiones agrupadas de acuerdo a cada capítulo/fase de la tesis, luego sintetizará las aportaciones de acuerdo a los trabajos publicados y por último presentará las publicaciones presentadas y los posible trabajos futuros
- El séptimo capítulo presentará las conclusiones en inglés a modo de resumen para los lectores sin dominio del español y citará las publicaciones y los posibles trabajos futuros

Capítulo 2

Estado del arte y objetivos de la Tesis

Estado del arte y objetivos de la tesis

La localización en ambientes interiores busca poder conocer la posición y orientación de una persona con una precisión del orden de algunos centímetros y pocos grados. Las personas al visitar ambientes conocidos, usualmente se ubican utilizando la percepción de movimiento (al dar pasos y observar el cambio en el paisaje observado) y referencias visuales conocidas o interpretadas (anuncios indicando direcciones). De manera análoga, la mayoría de los sistemas de posicionamiento en ambientes interiores utilizan los desplazamientos medidos utilizando unidades de medida inercial (IMU) y fijan referencias de posiciones y orientaciones absolutas mediante otras medidas para obtener una idea de la posición de la persona.

En exteriores es posible utilizar los GNSS y el campo magnético de la tierra para obtener la posición y orientación absoluta, pero en interiores, debido a la falta de línea de visión con los satélites y las perturbaciones magnéticas debidas a los materiales metálicos de la estructura de los edificios, no es posible utilizarlos directamente. Debido a esto, no hay una solución única para localizar a una persona, sin embargo es posible obtener estimaciones de la posición de una persona utilizando una IMU y diferentes medidas disponibles dentro de los edificios. La mayoría de estos algoritmos de localización en ambientes interiores basados en sensores inerciales se pueden generalizar bajo el esquema de la figura 2.1.

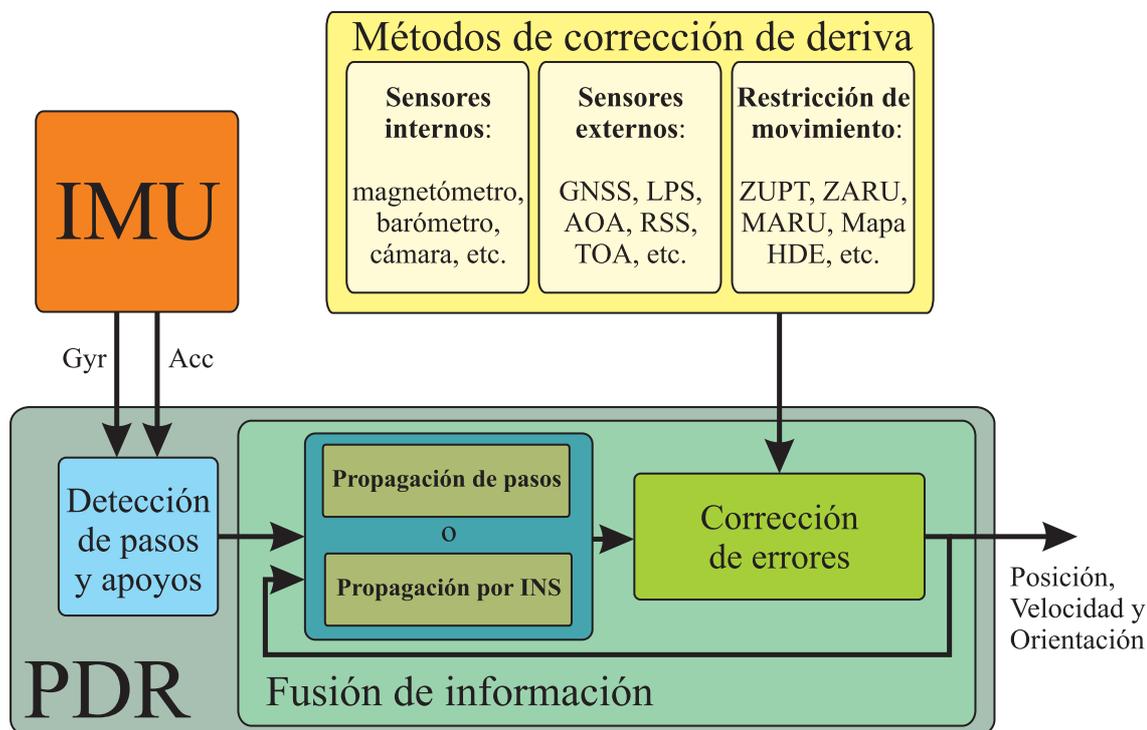


Figura 2.1: Esquema general de algoritmos de posicionamiento por sensores inerciales.

Según este esquema, la localización basada en sensores inerciales parte de la información obtenida de una IMU (la aceleración y las velocidades angulares medidas en el sistema de

referencia del sensor). Al observar las señales, es posible la identificación de los pasos de la persona a ubicar. Esta información le permite a un filtro de fusión de información (usualmente un EKF) propagar la estimación de la posición, ya sea utilizando la suma de los desplazamientos discretos de los pasos o la integración continua de las medidas inerciales. Debido a la divergencia de una estimación inercial, es necesaria la corrección de dicha estimación, por lo que se utilizan diferentes métodos de corrección de la deriva, ya sean basados en sensores internos, externos o restricciones de movimiento.

A continuación se estudiarán los distintos bloques que conforman un sistema de posicionamiento en interiores. En la Sección 2.1 se estudiarán los diferentes sensores que conforman una IMU, luego en la Sección 2.2 se mostrarán los métodos para detectar los pasos y fases de apoyo con dichos sensores. La Sección 2.3 tratará los métodos de fusión de información, mientras que la Sección 2.4 propondrá sensores y medidas para corregir la deriva de la estimación. Por último la Sección 2.5 planteará la discusión y enmarque de la tesis, y la Sección 2.6 establecerá los objetivos a buscar en la presente tesis.

Estado del arte

2.1. Unidad de medida inercial (IMU)

La unidad de medida inercial (IMU), primer bloque del esquema de la figura 2.1 (en naranja), consiste en un sensor capaz de medir los vectores de aceleración y rotación de un dispositivo, mediante la utilización de una triada de acelerómetros y de giróscopos respectivamente. La triada de sensores es colocada de modo que éstos sean ortogonales entre sí y midan los vectores respectivos en las 3 dimensiones. A continuación se estudiarán cada uno de los dispositivos utilizados.

2.1.1. Acelerómetro

El acelerómetro es el sensor que mide la aceleración de un cuerpo al observar la fuerza específica \mathbf{f} , debida a la segunda ley de Newton y medida en una masa de prueba. En general la aceleración $\ddot{\mathbf{r}} = [\ddot{r}_x \quad \ddot{r}_y \quad \ddot{r}_z]^T$ puede obtenerse como $\ddot{\mathbf{r}}^n = C_b^n \cdot \mathbf{f}^b - \mathbf{g}$, donde \mathbf{g} es el vector de gravedad y C_b^n es la matriz de rotación que transforma las medidas del sistema de referencia del sensor (superíndice b , body) al sistema de referencia de navegación inercial (superíndice n).

Para medir la fuerza específica ejercida sobre la masa de prueba suelen utilizarse múltiples principios detallados en [6], de los que resaltan los dos mostrados en la figura 2.2. Éstos están basados en las siguientes características:

- **Desplazamientos:** Se miden los desplazamientos de la masa de prueba sobre un elemento elástico como un muelle. En dispositivos de tipo MEM se puede utilizar muelles de silicio u otros materiales específicamente colocados en el dispositivo y medir los desplazamientos mediante las variaciones en la capacitancia inducida entre la masa y la estructura. Otros dispositivos utilizan fibra óptica como muelle y miden las variaciones de la posición mediante técnicas de interferometría.
- **Cambio de frecuencia:** Se miden los cambios en la frecuencia de oscilación debidos a la fuerza ejercida por la masa de prueba. En dispositivos de tipo MEM se utilizan cristales de cuarzo o silicio.

Las variaciones por desplazamientos o cambios de frecuencia pueden medirse de dos maneras:

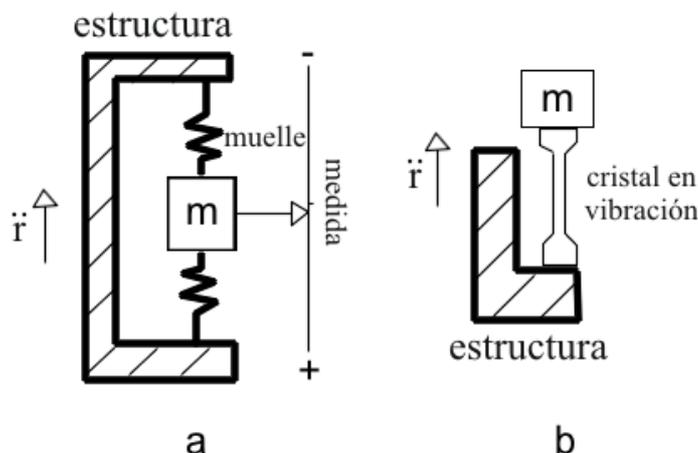


Figura 2.2: Configuraciones para la medición de la aceleración $\ddot{\mathbf{r}}$, mediante las fuerzas específicas generadas en la masa de prueba m . a. Medición de la compresión/elongación de un elemento elástico (muelle). b. Cambio en la frecuencia de oscilación de un elemento en vibración (cristal). [6].

- **A lazo abierto:** La característica estudiada es medida directamente utilizando la capacitancia, interferometría, voltajes o rejillas de sensores. La medida puede tener una relación no lineal con la fuerza por lo que se pueden aplicar curvas de corrección. Las variaciones tienen un pequeño rango dinámico pero son capaces de distinguir pequeñas aceleraciones.
- **A lazo cerrado:** La posición de la masa de prueba es controlada mediante un electroimán, aplicando fuerzas para contrarrestar el efecto de la aceleración sobre la masa. De esta manera la corriente aplicada por el electroimán será proporcional a la fuerza específica generada por la aceleración de la masa. El sistema a lazo cerrado tiene un mayor consumo, pero es capaz de contrarrestar las posibles características no lineales del sistema.

2.1.2. Gir6scopo

El Gir6scopo es el sensor que mide la velocidad angular de un dispositivo $\boldsymbol{\omega} = [\omega_x \ \omega_y \ \omega_z]^T$ utilizando diferentes t6cnicas basadas en la conservaci6n del momento angular, un an6logo de la inercia para cuerpos en rotaci6n. Con las velocidades angulares, es posible propagar la matriz de orientaci6n C_b^n seg6n la t6cnica propuesta en la secci6n 2.1.4.

Para medir las velocidades angulares los gir6scopos se utilizan m6ltiples t6cnicas detalladas en [6, 8]. Entre ellas, las m6s destacadas pueden ser observados en la figura 2.3 y est6n basadas en:

- **Gir6scopos mec6nicos:** Debido al efecto de la precesi6n, al girar con velocidad angular $\boldsymbol{\omega}$, un rotor con un momento angular \mathbf{H} , se generar6 un torque $\mathbf{T} = \boldsymbol{\omega} \times \mathbf{H}$ en direcci6n perpendicular a las anteriores. Utilizando este principio es posible medir la velocidad angular perpendicular a un rotor midiendo el torque generado en el eje perpendicular a este. Debido a la necesidad de piezas en rotaci6n, suelen ser dispositivos de gran tama1o y no implementados en MEMs.
- **Gir6scopos vibratorios:** Cualquier vibraci6n genera velocidades lineales oscilatorias, que si son rotadas en un eje perpendicular a las velocidades, generar6 aceleraciones de Coriolis

en el eje perpendicular a la velocidad y la rotación. Si se pueden medir estas aceleraciones, se podría conocer la magnitud de la velocidad angular. Esta técnica es la más común en la fabricación de giróscopos de tipo MEM [9, 10], pues el principio de funcionamiento es independiente del tamaño del dispositivo.

- **Giróscopos ópticos:** Debido al efecto Sagnac, si se tienen 2 haces de luz, cada uno dando una vuelta en una trayectoria cerrada en un plano, se generará un patrón de interferencia en el punto de inicio/fin. Si el sistema es rotado en la dirección del plano, el haz viajando en el sentido de la rotación deberá recorrer una mayor distancia y el haz viajando en sentido contrario una menor distancia, lo que alterará el patrón de interferencia dependiendo de la velocidad de giro, por lo que se puede medir la velocidad angular. Este tipo de giróscopos son los más precisos y su precisión depende del área de la trayectoria utilizada, por lo que no suele utilizarse este principio para fabricar giróscopos de tipo MEM.

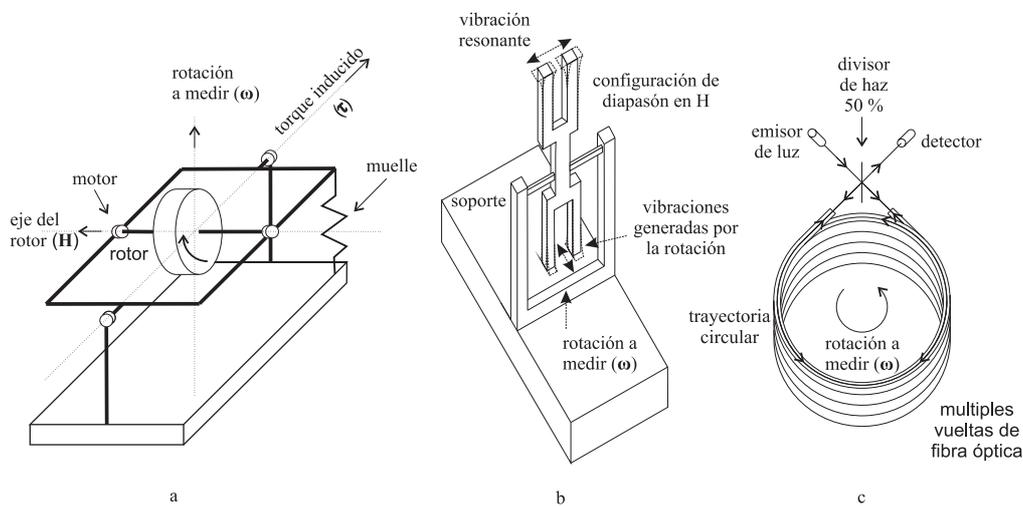


Figura 2.3: Configuraciones para la medición de la velocidad angular ω . a. Medición del torque ejercido al girar un rotor en el plano perpendicular a su dirección de rotación. b. Medición de las vibraciones generadas al rotar un elemento en vibración. c. Medición del cambio en el patrón de interferometría generado por haces de luz en sentido contrario en fibra óptica. [6].

Al igual que los acelerómetros, los giróscopos pueden medirse a lazo abierto o lazo cerrado, dependiendo de las necesidades del sistema.

2.1.3. Fuentes de error en la medida

Las IMU presentan diferentes fuentes de error que deben ser tomadas en cuenta para poder estimar correctamente la posición de una persona o dispositivo. Las principales fuentes de error en ambos dispositivos de las IMU pueden clasificarse de acuerdo a:

- **Errores determinísticos:** Errores debido al montaje o fabricación de los sensores. Entre ellos se encuentran: el bias, el factor de escala, la no ortogonalidad de la triada de sensores, la no linealidad de las medidas y la sensibilidad entre los ejes de las medidas. Estos errores pueden ser obtenidos mediante una calibración del dispositivo y suelen ser corregidos de fábrica para minimizar su efecto [11].

- **Errores aleatorios:** Son errores debidos a fenómenos aleatorios en la obtención de la medida como el ruido térmico y fluctuaciones en el bias de la medida. Debido a su naturaleza, su efecto suele ajustarse a diferentes modelos aleatorios para conocer su efecto sobre las estimaciones [12]. Entre los modelos más utilizados están:
 1. Bias constante: El bias de la medida, aunque ligeramente cambiante se puede modelar como una constante conocida o por estimar.
 2. Error Gaussiano: El ruido térmico suele modelarse como ruido blanco, Gaussiano de media cero.
 3. Bias caminante aleatorio: Las variaciones en el bias usualmente asociado a ruido $1/f$ (flicker noise, [13]) suelen modelarse como ruido marrón o Browniano, basado en la integración de ruido blanco.

Utilizando uno o varios de los modelos anteriores es posible estimar la distribución de probabilidad de las estimaciones de la posición usando una IMU.

- **Errores dependientes de la temperatura:** La temperatura juega un papel muy importante en los dispositivos, alterando características físicas y electrónicas de los componentes, lo que puede variar las medidas realizadas [14]. Al igual que los errores determinísticos, los sensores son calibrados de fábrica para compensar el efecto de la temperatura en las medidas.

Los errores determinísticos y dependientes de la temperatura suelen estar corregidos de fábrica o ser calibrados al inicio de una estimación, mientras que los errores aleatorios deben ser medidos para conocer su efecto en las estimaciones. Una de las técnicas más comunes para la obtención de los parámetros de dichos ruidos, es el estudio de la Varianza de Allan (AVA, Allan Variance Analysis [15]), originalmente desarrollado para estudiar la estabilidad de los osciladores pero generalizado para la estimación de los errores de los sensores. Éste permite, mediante el análisis del error característico de un sensor en estático conocer los diferentes tipos de errores presentes.

El estudio está basado en el análisis de ventanas de datos de diferentes tamaños o tiempos de promediado τ . Así, para una secuencia $\mathbf{x} = \{\mathbf{x}(k) | k = 1, \dots, N\}$, la varianza de Allan $\sigma_{\text{Allan}}(\tau)$ en función de τ , puede calcularse como:

$$\sigma_{\text{Allan}}^2(\tau) = \frac{1}{2\tau^2(N-2m)} \sum_{k=1}^{N-2m} (\mathbf{S}(k+2m) - 2\mathbf{S}(k+m) + \mathbf{S}(k))^2 \quad (2.1)$$

donde m es el número de muestras en tiempo de promediado ($m = \tau/\Delta t$) y \mathbf{S} es la aproximación de la integral de x , calculada como $S(k) = \Delta t \sum_{i=1}^k \mathbf{x}(i)$.

Dependiendo del tipo de error, la representación de la varianza en función del tiempo de promediado adoptará diferentes formas como las observadas en la figura 2.4. Identificando las regiones de pendiente constante es posible identificar las diferentes fuentes de error. Las regiones de pendiente constante más comunes en el ruido de una IMU son:

- Pendiente $-1/2$: Asociado al ruido Gaussiano en la medida, comúnmente conocido como angle/velocity random walk (caminado aleatorio en el ángulo/velocidad) abreviado como ARW o VRW, cuyo coeficiente (la densidad de ruido en la densidad espectral de potencia de la señal) puede ser obtenido observando el punto de corte de la varianza con un tiempo de promediado de 1 s.

- Pendiente 0: Asociado a la inestabilidad del bias con un modelo de flicker noise, cuyo coeficiente B , puede ser obtenido dividiendo entre 0.664 el valor en la zona de pendiente nula. También es conocido como el caminado aleatorio del bias (Bias Random Walk, BRW)

Utilizando esta técnica es posible obtener la curva de varianza de Allan para el acelerómetro de la IMU MTi de XSens observada en la figura 2.4.a. Se puede apreciar que la densidad de ruido blanco (o caminado aleatorio de la velocidad, VRW) es $1,1 \cdot 10^{-3} \text{ m/s}^2/\sqrt{\text{Hz}}$ y el coeficiente de inestabilidad del bias es $2,6 \cdot 10^{-4} \text{ m/s}^2/0,664 = 3,9 \cdot 10^{-4} \text{ m/s}^2$. Repitiendo el análisis con el giróscopo se obtuvo la curva de la figura 2.4.b, donde se observa una densidad de ruido blanco (o caminado aleatorio del ángulo, ARW) de $4,4 \cdot 10^{-2} \text{ }^\circ/\text{s}/\sqrt{\text{Hz}}$ y un coeficiente de inestabilidad del bias de $1,0 \cdot 10^{-2} \text{ }^\circ/\text{s}/0,664 = 1,5 \cdot 10^{-2} \text{ }^\circ/\text{s}$

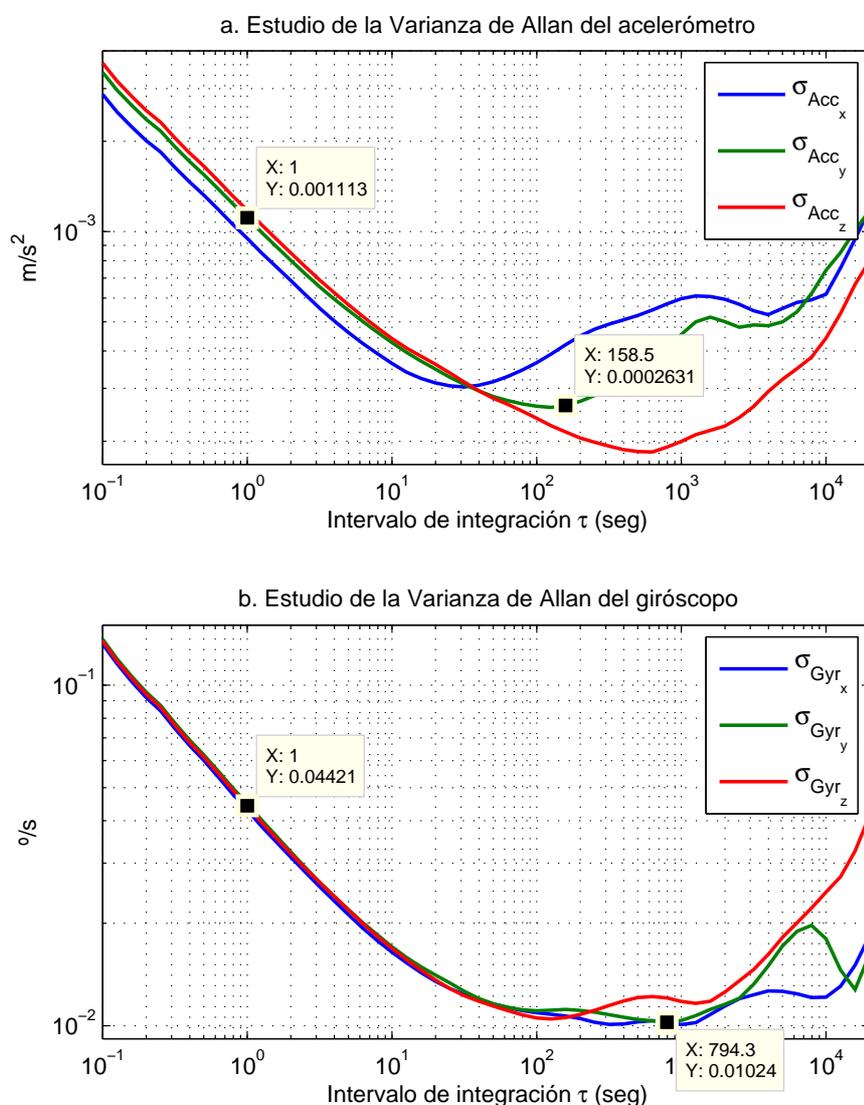


Figura 2.4: Análisis de la Varianza de Allan del acelerómetro (a) y el giróscopo (b) de la IMU MTi de XSense. [15]

2.1.4. Sistema de navegación inercial

Con las medidas del gir6scopo y el aceler6metro, es posible la reconstrucci6n del desplazamiento de un cuerpo. Para ello se utiliza la t6cnica del sistema navegaci6n inercial (INS) para una IMU adherida al cuerpo (Strapdown). Esta t6cnica ha sido extensamente estudiada [6, 16, 17] y mediante los INS muchas aeronaves son capaces de mantener su posici6n, velocidad y orientaci6n con un m6nimo error.

El INS esta basado en la doble integraci6n de la aceleraci6n $\ddot{\mathbf{r}}^n$ en el sistema de referencia de navegaci6n inercial (super6ndice n), esta 6ltima es obtenida a partir de la fuerza espec6fica \mathbf{f}^b medida en el sensor (super6ndice b , body) y la matriz de rotaci6n que transforma del sistema de referencia del sensor al sistema de referencia de navegaci6n inercial C_b^n , como: $\ddot{\mathbf{r}}^n = C_b^n \cdot \mathbf{f}^b - \mathbf{g}$, donde \mathbf{g} es el vector de gravedad. La mayor6a de los sistemas son discretos, por lo que considerando las medidas constante durante el intervalo de muestreo Δt , la velocidad $\dot{\mathbf{r}}^n(k)$ y la posici6n $\mathbf{r}^n(k)$ pueden ser calculadas de acuerdo a:

$$\dot{\mathbf{r}}^n(k) = \dot{\mathbf{r}}^n(k-1) + (C_b^n(k) \cdot \mathbf{f}^b(k) - \mathbf{g}) \cdot \Delta t, \quad (2.2)$$

$$\mathbf{r}^n(k) = \mathbf{r}^n(k-1) + \frac{(\dot{\mathbf{r}}^n(k) + \dot{\mathbf{r}}^n(k-1))}{2} \cdot \Delta t. \quad (2.3)$$

Para propagar C_b^n se utilizan las rotaciones $\boldsymbol{\omega}$ en rad/seg, medidas en el gir6scopo, como:

$$C_b^n(k) = C_b^n(k-1) \cdot e^{\Omega_{nb}^b(k) \cdot \Delta t}, \quad (2.4)$$

donde $\Omega_{nb}^b(k)$ es la matriz antisim6trica (skew-symmetric) que transforma el producto vectorial $\boldsymbol{\omega}^b \times \mathbf{r}$ en una multiplicaci6n por una matriz $\Omega_{nb}^b \cdot \mathbf{r}$, de acuerdo a:

$$\Omega_{nb}^b(k) = [\boldsymbol{\omega}^b(k) \times] = \begin{bmatrix} 0 & -\omega_z^b(k) & \omega_y^b(k) \\ \omega_z^b(k) & 0 & -\omega_x^b(k) \\ -\omega_y^b(k) & \omega_x^b(k) & 0 \end{bmatrix}. \quad (2.5)$$

Para el c6lculo de $e^{\Omega_{nb}^b \cdot \Delta t}$ es com6n utilizar una aproximaci6n de Pad6 de orden (1,1) [18] como:

$$e^{\Omega_{nb}^b \cdot \Delta t} \approx \left(I + \frac{1}{2} \Omega_{nb}^b \cdot \Delta t \right) \left(I - \frac{1}{2} \Omega_{nb}^b \cdot \Delta t \right)^{-1} \quad (2.6)$$

o de orden mayor, utilizar la funci6n *expm* de MATLAB (una aproximaci6n de Pad6 de orden (6,6) con ‘‘scaling’’ y ‘‘squaring’’) o utilizar la descomposici6n propuesta en [6] para agrupar los t6rminos de la serie de Taylor de la exponencial como:

$$e^{\Omega_{nb}^b \cdot \Delta t} = I + \frac{\sin(\|\boldsymbol{\omega} \Delta t\|)}{\|\boldsymbol{\omega}\|} \Omega_{nb}^b + \frac{(1 - \cos(\|\boldsymbol{\omega} \Delta t\|))}{\|\boldsymbol{\omega}\|^2} \Omega_{nb}^b{}^2. \quad (2.7)$$

Debido a las integraciones requeridas en el proceso, la presencia de ruido o bias en cualquiera de los sensores genera errores de posicionamiento que aumentan con el tiempo. En [19] se analizan los efectos de estos errores y se determina que la mayor fuente de error es el gir6scopo, por lo que suele ser el componente de mayor importancia de una IMU. Debido al r6pido incremento del error, el INS suele usarse solo por poco tiempo (dependiendo de la calidad de la IMU puede usarse por segundos u horas) y debe ser corregido con alguna medida global de posici6n, velocidad u orientaci6n para limitar el crecimiento del error. En adelante si la posici6n \mathbf{r} y velocidad $\dot{\mathbf{r}}$ no tienen super6ndice para indicar el sistema de referencia, por defecto se asumir6 que es el sistema de referencia de navegaci6n inercial.

2.2. Detección de pasos y fases de apoyo

Como se comentó previamente, el INS es capaz de ofrecer los desplazamientos de una persona, pero debido al nivel de ruido y bias presentes en dispositivos de tipo MEM, la estimación es poco fiable después de algunos segundos. Una solución es la utilización del patrón de caminado para estimar los pasos de la persona. Utilizando la información del acelerómetro y el giróscopo es posible identificar los pasos y estimar ciertas características del caminado como la longitud y la dirección, lo que permitiría reconstruir la posición concatenando las zancadas dadas como se propone en la figura 2.1. Esta técnica conocida como Pedestrian Dead Reckoning (PDR), permitiría reducir el error introducido por el INS que tiene un crecimiento cúbico con el tiempo a un crecimiento lineal con la distancia recorrida [20, 21].

La IMU utilizada para la detección de pasos puede ser colocada en múltiples partes del cuerpo, pero se ha observado que las técnicas de posicionamiento más comunes siguen 2 tendencias: 1) utilizar la IMU de dispositivos electrónicos como teléfonos inteligentes que será llevada en la mano, bolsillo, cartera, etc. [21]; y 2) colocar una IMU en el pie de la persona a localizar [20].

La utilización de la IMU de dispositivos electrónicos comunes como los teléfonos inteligentes, permite minimizar la cantidad de sensores adicionales a utilizar, pero tiene la desventaja de que dependen de las características del paso como la longitud y cambio de orientación de cada persona, lo que introduce errores adicionales. Esta técnica permite conocer la posición con errores cercanos al 5 % de la distancia total recorrida.

Utilizar una IMU en el pie ofrece un punto de velocidad conocida (durante la fase de apoyo puede asumirse que la velocidad es nula) y esta información puede ser utilizada para corregir la estimación de la navegación inercial. Esta técnica aunque requiere la utilización de un sensor en el pie, permite estimar la posición de la persona con errores cercanos al 1 % de la distancia total recorrida. En adelante, al referirnos a PDR asumiremos que la IMU está colocada en el pie de la persona siguiendo el trabajo de [20].

Al observar las señales de la figura 2.5, provenientes de las aceleraciones y velocidades angulares de una IMU adherida al pie de una persona, es posible identificar momentos en que los valores se mantienen aproximadamente constantes y el vector de aceleración es aproximadamente igual a la gravedad. Esta fase es la que comúnmente se conoce como apoyo, un momento en el que la velocidad es aproximadamente nula, por lo tanto la aceleración debe ser nula y solo se observaría la gravedad.

En la actualidad hay una gran cantidad de métodos de detección de la fase de apoyo para una IMU en el pie, en [22] se propone un método generalizado, se estudian los métodos más comunes y se compara su probabilidad de detección frente a sensores de contacto colocados en el pie. Para la detección de la fase de apoyo, en la literatura se proponen los siguientes métodos:

1. **Detección de la varianza local de la aceleración:** Propuesto en [23] mide la varianza de la aceleración en el intervalo entre la muestra k y muestra $k + N$, utilizando la media local de la aceleración $\bar{Acc}_{k \dots k+N}$ y la compara con un umbral γ_v . No utiliza la información del giróscopo. La ecuación de la condición de detección es:

$$T_v(Acc)_{(k)} = \frac{1}{N} \sum_{n \in k \dots k+N} \|Acc(n) - \bar{Acc}_{k \dots k+N}\|^2 < \gamma_v \quad (2.8)$$

2. **Detección de la magnitud de la aceleración:** Propuesto en [23], es el algoritmo más básico de detección de apoyos, en el que se verifica que la magnitud de la señal de aceleración esté dentro de ciertos umbrales (inferior γ_{lm} y superior γ_{um}) sin importar la orientación.

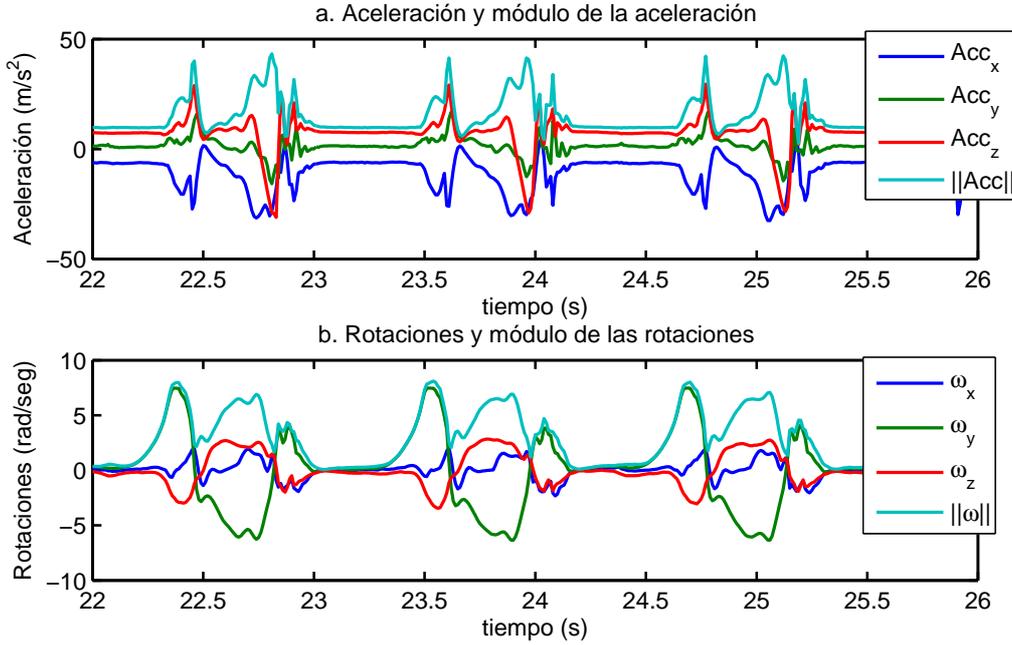


Figura 2.5: Segmento de la aceleración y giros grabados durante el caminado.

En muchas implementaciones se usa como medida suplementaria a otros algoritmos. La ecuación de la condición de detección es:

$$T_m(Acc)_{(k)} = (\|Acc(k)\| < \gamma_{um}) \& (\|Acc(k)\| > \gamma_{lm}) \quad (2.9)$$

3. **Detección de la energía de las rotaciones:** Propuesto en [24], utiliza el módulo al cuadrado de las velocidades angulares para realizar la comparación. Idealmente, en la fase de apoyo, el módulo de las velocidades angulares debería ser 0 pero debido a pequeños movimientos y la presencia del bias es necesario utilizar un umbral γ_ω . La ecuación de la condición de detección es:

$$T_\omega(Gyr)_{(k)} = \|Gyr(k)\|^2 < \gamma_\omega \quad (2.10)$$

4. **Prueba de la tasa de semejanza generalizada (GLRT):** Propuesto en [22], es una forma generalizada de algoritmo de detección que utiliza las n muestras adyacentes y evalúa su cercanía a las condiciones de apoyo ideales. Para determinar si se está en la fase de apoyo se compara con un umbral γ_t la suma de los errores cuadráticos medios de la aceleración con respecto a la gravedad orientada en la dirección de $\bar{Acc}_{k \dots k+N}$ y las rotaciones con respecto a una condición estática. La ecuación de la condición de detección es:

$$T_{GLRT}(Acc, Gyr)_{(k)} = \frac{1}{N} \sum_{n \in k \dots k+N} \left(\frac{1}{\sigma_{Acc}^2} \left\| Acc(n) - g \frac{\bar{Acc}_{k \dots k+N}}{\|\bar{Acc}_{k \dots k+N}\|} \right\|^2 + \frac{1}{\sigma_{Gyr}^2} \|Gyr_n\|^2 \right) < \gamma_t \quad (2.11)$$

5. **Algoritmos de múltiples condiciones:** Propuesto en [18], mide por separado las condiciones de magnitud de la aceleración, energía de la rotación y varianza local, pidiendo las 3 condiciones para que se detecte el apoyo. Por último utiliza un filtro de mediana para evitar falsas detecciones. En [19] se propone realizar la mediana de la condición conjunta

de la magnitud de la aceleración y la energía de la rotación, posteriormente multiplicar con la condición de la varianza de la magnitud de la aceleración y por último retardar la información del detector de apoyo para que la señal del EKF coincida con el valor medio de la ventana utilizada para el filtro de media. La ecuación de la condición de detección es:

$$T_{mc}(Acc, Gyr)_{(k+N/2)} = \text{mediana}_{n=k, \dots, k+N}(T_m(Acc)_{(n)} \& T_\omega(Gyr)_{(n)} \& T_v(Acc)_{(k)}) \quad (2.12)$$

2.3. Fusión de información

Los sensores inerciales mediante el INS son capaces de obtener los desplazamientos de una persona independientemente del ambiente en que se encuentre, pero no son capaces de conocer su posición absoluta. Adicionalmente debido al ruido y bias que presentan las medidas una estimación con bajo nivel de error durante varios minutos requeriría de acelerómetros mecánicos y giróscopos ópticos, ambos demasiado grandes y costosos para ser llevados por una persona, por lo que se suelen utilizar dispositivos de tipo MEM. Para asociar las medidas a posiciones absolutas y evitar la divergencia de la estimación, se utiliza un filtro de fusión de información como se observa en la figura 2.1 para asociar la información de otros sensores a la estimación y por ende limitar el crecimiento del error. Los filtros Bayesianos son los estimadores más utilizados y están basados en dos etapas de cómputo: la propagación de los estados y su corrección.

De manera general los filtros bayesianos propagan la función de densidad de probabilidad (pdf) de la estimación en el instante previo $p(\mathbf{x}(k-1))$ para obtener la estimación de la pdf en el instante actual $p(\hat{\mathbf{x}}(k))$ de acuerdo a [25]:

$$p(\hat{\mathbf{x}}(k)) = \int p(\mathbf{x}(k)|\mathbf{x}(k-1))p(\mathbf{x}(k-1))d\mathbf{x}(k-1). \quad (2.13)$$

Si se reciben medidas $\mathbf{m}(k)$, la estimación puede ser corregida de acuerdo a:

$$p(\mathbf{x}(k)) = \frac{p(\mathbf{m}(k)|\hat{\mathbf{x}}(k))p(\hat{\mathbf{x}}(k))}{p(\mathbf{m}(k))}, \quad (2.14)$$

donde la probabilidad de la medida $p(\mathbf{m}(k))$ puede calcularse como:

$$p(\mathbf{m}(k)) = \int p(\mathbf{m}(k)|\hat{\mathbf{x}}(k))p(\hat{\mathbf{x}}(k))d\hat{\mathbf{x}}(k). \quad (2.15)$$

En la mayoría de los casos, obtener las pdf de las estimaciones requeriría la resolución de integrales de múltiples dimensiones que no podrían ser resultas a tiempo real. Para poder calcular las pdf a tiempo real se utilizan dos técnicas, los filtros paramétricos y los filtros no paramétricos. Los primeros están basados en asumir distribuciones específicas de las pdf y propagar diferentes parámetros que representan dichas distribuciones, mientras que los segundos toman muestras de las distribuciones y las propagan y corrigen. A continuación se detallan ambos métodos.

2.3.1. Filtros paramétricos

Los filtros paramétricos utilizan aproximaciones de las pdfs para propagar las estimaciones, la más utilizada por su versatilidad es la distribución Gaussiana que puede ser caracterizada por su media $\mathbf{x}(k)$ y su covarianza $P(k)$. El filtro de Kalman es el estimador óptimo cuando el sistema y las medidas tienen relaciones lineales, y la distribución del error es Gaussiana. El filtro

utiliza dos etapas para estimar los estados, en la primera se propagan los estados de acuerdo a la media y covarianza en el instante anterior utilizando las ecuaciones de estado:

$$\hat{\mathbf{x}}(k) = F \cdot \mathbf{x}(k-1), \quad (2.16)$$

$$\hat{P}(k) = F \cdot P(k-1) \cdot F^T + Q, \quad (2.17)$$

$$(2.18)$$

donde el símbolo $\hat{}$ indica las estimaciones (o predicciones) de la media y la covarianza, F es la matriz de transición de los estados y Q es la covarianza del ruido del proceso.

La segunda etapa consiste en corregir los estados de acuerdo a las mediciones \mathbf{m} observadas con covarianza de la medida R , de acuerdo a:

$$\mathbf{x}(k) = \hat{\mathbf{x}}(k) + K \cdot (\mathbf{m} - H \cdot \hat{\mathbf{x}}(k)), \quad (2.19)$$

$$P(k) = (I - K \cdot H) \cdot \hat{P}(k), \quad (2.20)$$

$$(2.21)$$

donde H es la matriz de observación y K es la constante de Kalman:

$$K = H^T \cdot \hat{P}(k) \cdot (H^T \cdot \hat{P}(k) \cdot H + R)^{-1}. \quad (2.22)$$

En la mayoría de los sistemas en posicionamiento, algunos estados (principalmente la orientación) y la mayoría de las medidas utilizadas, no son lineales ni tienen error gaussiano, por lo que se suelen utilizar modificaciones de este filtro como lo son el filtro Kalman Extendido o el filtro de Kalman Unscented, ambos explicados a continuación.

2.3.1.1. Filtros de Kalman Extendido

El filtro de Kalman Extendido (EKF) es la simplificación más básica y utilizada del filtro de Kalman, se basa en linealizaciones para estimar el comportamiento del sistema y predice la evolución de los estados aproximando su media $\mathbf{x}(k)$ y covarianza $P(k)$ a un modelo Gaussiano lineal, utilizando las ecuaciones (2.16) a (2.22), pero sustituyendo las matrices de transición de estados y de observación por sus jacobianos, tal que $F \approx \Phi(k)$ y $H \approx H(k)$.

A pesar de que el EKF solo implementa una linealización, la aproximación lograda es suficiente para mejorar la estimación de la posición utilizando sistemas de posicionamiento global y una IMU [6]. Esto es debido a que las medidas de los GNSS son tan lejanas que el jacobiano y el error característico no cambian significativamente. La IMU permite estimar la evolución de los estados, mientras que las medidas de los satélites limitan el crecimiento del error característico de la navegación inercial.

Es frecuente introducir al filtro EKF medidas de tipo heurístico como en el caso de navegación inercial de peatones con una IMU en el pie [20] donde detectando los apoyos se puede implementar medidas que indiquen que la velocidad es cero (una medida lineal, pero no Gaussiana). Otras medidas también pueden ser incorporadas a la estimación de la posición, como es el caso de la orientación magnética [18, 26–28] o medidas de distancias a balizas de posición conocida [29] (ambas no lineales y no Gaussianas).

2.3.1.2. Filtros de Kalman Unscented

Debido a los problemas de implementación y ajuste que conlleva el uso del EKF han surgido múltiples filtros alternativos, entre los que se encuentra el filtro de Kalman Unscented (UKF) o

“sigma-point Kalman filter” propuesto inicialmente por Julier y Uhlmann [30] y posteriormente desarrollado por Wan y van der Merwe [31].

A diferencia de la versión extendida, el UKF mide la evolución de la media y la covarianza de los estados mediante la propagación de una serie de puntos “sigma” con una dispersión proporcional a la desviación estándar de los estados. Este proceso de estimación de la media y la covarianza es llamado Transformación Unscented (UT) y es una forma de medir experimentalmente estos valores. En la figura 2.6 se pueden apreciar las diferencias entre una medida real o muestreada, la linealización (EKF) y la transformación Unscented.

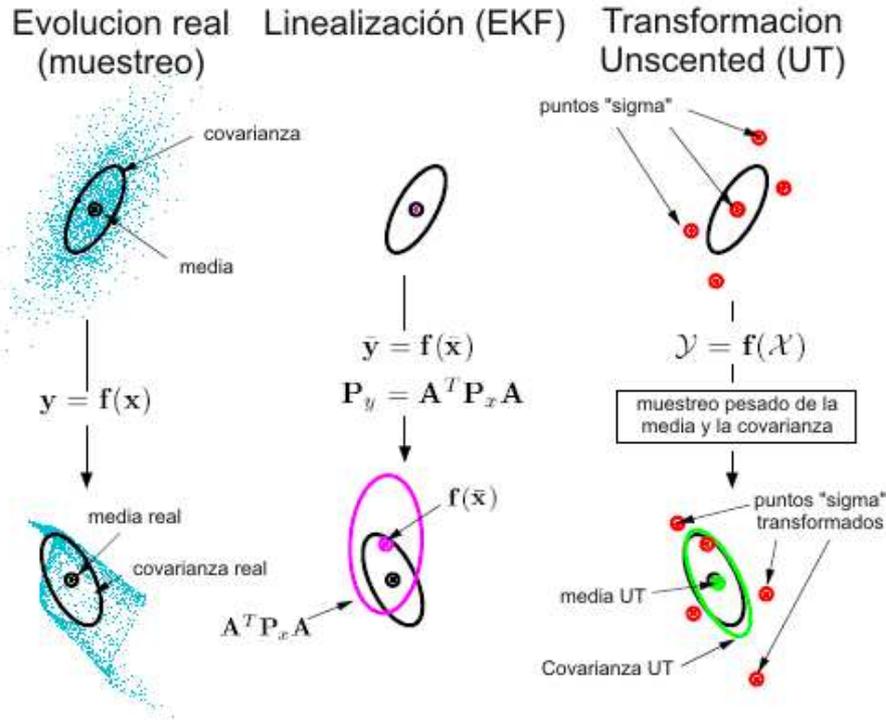


Figura 2.6: Comparación de diferentes métodos de estimación de la propagación de la media y la covarianza en filtros Bayesianos. [31]

El algoritmo de estimación del UKF utilizado en [32] inicia estableciendo los puntos “sigma” $\mathbf{X}_{k-1,i}$ simétricos alrededor de la media $\mathbf{x}(k-1)$ como:

$$\mathbf{X}_{k-1,i} = \begin{cases} \mathbf{x}(k-1) & i = 0 \\ \mathbf{x}(k-1) + (\sqrt{(n+\lambda)P(k-1)})_i & i = 1, \dots, n \\ \mathbf{x}(k-1) - (\sqrt{(n+\lambda)P(k-1)})_{i-n} & i = n+1, \dots, 2 \cdot n \end{cases} \quad (2.23)$$

$(\sqrt{(n+\lambda)P(k-1)})_i$ representa la i -ésima columna de la matriz raíz cuadrada de la covarianza $P(k-1)$ escalada. La matriz raíz cuadrada puede obtenerse utilizando la factorización de Cholesky (en MATLAB `chol(P(k-1), 'lower')`) y luego escalando por $\sqrt{n+\lambda}$. n es el número de estados y $\lambda = \alpha^2(n+\kappa) - n$ es un factor de escala, donde α y κ ajustan la dispersión de los puntos “sigma”.

Luego los puntos $\mathbf{X}_{k-1,i}$ son propagados con la función de transición de estados f y la entrada

$\mathbf{u}(k)$ que modelan la evolución de los estados tal que:

$$\mathbf{X}_{k,i}^* = f(X_{k-1,i}, u(k)) \quad (2.24)$$

posteriormente se predice la media $\hat{\mathbf{x}}(k)$ y la covarianza \hat{P}_{xx} de los puntos propagados:

$$\hat{\mathbf{x}}(k) = \sum_{i=0}^{2n} w_i \cdot \mathbf{X}_{k,i}^* \quad (2.25)$$

$$\hat{P}_{xx} = \sum_{i=0}^{2n} w_i \cdot (\mathbf{X}_{k,i}^* - \hat{\mathbf{x}}(k)) \cdot (\mathbf{X}_{k,i}^* - \hat{\mathbf{x}}(k))^T + Q \quad (2.26)$$

donde los pesos w_i son [31]:

$$w_i = \begin{cases} \frac{\lambda}{n+\lambda} & i = 0, \text{ para la media} \\ \frac{\lambda}{n+\lambda} + (1 - \alpha^2 + \beta) & i = 0, \text{ para la covarianza} \\ \frac{\lambda}{2 \cdot (n+\lambda)} & i > 0 \end{cases}, \quad (2.27)$$

β en un factor para incorporar conocimiento a priori de la distribución de \mathbf{x} , para distribuciones Gaussianas $\beta = 2$ es óptimo.

Posteriormente se establecen nuevos puntos “sigma” para evaluar la observación basados en la media y covarianza propagada, como:

$$\mathbf{X}_{k,i} = \begin{cases} \hat{\mathbf{x}}(k) & i = 0 \\ \hat{\mathbf{x}}(k) + (\sqrt{(n+\lambda)\hat{P}_{xx}})_i & i = 1, \dots, n \\ \hat{\mathbf{x}}(k) - (\sqrt{(n+\lambda)\hat{P}_{xx}})_{i-n} & i = n+1, \dots, 2 \cdot n \end{cases}. \quad (2.28)$$

Si se sabe que el sistema es suficientemente lineal pueden utilizarse los puntos calculados anteriormente $\mathbf{X}_{k,i}^*$. Para conocer el efecto de cada observación se evalúan los puntos en el modelo de observación definido por la función h como

$$\mathbf{Y}_i = h(\mathbf{X}_{k,i}), \quad (2.29)$$

se predice el valor medio $\hat{\mathbf{y}}$, la covarianza de la observación P_{yy} y la covarianza cruzada entre los estados y las salidas P_{xy} :

$$\hat{\mathbf{y}} = \sum_{i=0}^{2n} w_i \cdot \mathbf{Y}_i \quad (2.30)$$

$$P_{yy} = \sum_{i=0}^{2n} w_i \cdot (\mathbf{Y}_i - \hat{\mathbf{y}}) \cdot (\mathbf{Y}_i - \hat{\mathbf{y}})^T + R \quad (2.31)$$

$$P_{xy} = \sum_{i=0}^{2n} w_i \cdot (\mathbf{X}_{k,i} - \hat{\mathbf{x}}(k)) \cdot (\mathbf{Y}_i - \hat{\mathbf{y}})^T. \quad (2.32)$$

Con estos valores es posible realizar la actualización de los estados con la medida realizada \mathbf{y} , según:

$$K = P_{xy} \cdot P_{yy}^{-1} \quad (2.33)$$

$$\mathbf{x}(k) = \hat{\mathbf{x}}(k) + K \cdot (\mathbf{y} - \hat{\mathbf{y}}) \quad (2.34)$$

$$P(k) = \hat{P}_{xx} - K \cdot P_{yy} \cdot K^T. \quad (2.35)$$

El procesamiento necesario para realizar este filtrado es mayor, principalmente porque se debe propagar $2n + 1$ veces el sistema y se requiere de una factorización de Cholesky por cada iteración del sistema, pero no es necesario realizar la linealización y la precisión es mayor. El UKF aproxima correctamente la evolución de los estados hasta el tercer orden de la serie de Taylor para la media y de segundo orden para la covarianza [33], mientras que el EKF solo aproxima hasta primer orden. Al aproximar correctamente una mayor cantidad de términos de la serie de Taylor, permite además obtener información que se encuentra en los efectos de segundo o mayor orden del sistema y por ende converger más rápido.

El UKF ha sido utilizado en aplicaciones de PDR como [32, 34], navegación inercial asistida por cámaras como [35, 36] y posicionamiento local por balizas como [37], debido a que es capaz de manejar las no linealidades típicas en dichos sistemas con un costo computacional relativamente bajo en comparación con los filtros de partículas.

2.3.2. Filtros no paramétricos

Los filtros de Kalman son óptimos cuando el sistema es lineal y Gaussiano, si las condiciones son cercanas a las anteriores los filtros son subóptimos pero permiten una buena estimación con bajo cómputo. Si el sistema es significativamente no lineal o no Gaussiano es necesaria otra técnica de estimación que permiten aproximar los sistemas mediante un número finito de puntos [38].

La forma más básica de filtro no paramétricos son las rejillas de probabilidad que discretizan el espacio de probabilidades y siguen para cada punto su probabilidad. Otra alternativa son los filtros de partículas que ajustan los puntos estudiados de acuerdo a la evolución de la distribución de probabilidad de modo que halla un mayor número de puntos en las zonas donde hay una mayor probabilidad.

2.3.2.1. Filtro de rejilla de probabilidad

Si se dispone de un espacio de probabilidades continuo, pero que se puede descomponer en un número finito de celdas es posible aplicar un filtro por aproximación a una rejilla de probabilidad [39]. Éste consiste en aproximar la densidad de probabilidad a un conjunto de Deltas de Dirac con pesos $w^i(k)$, dados N puntos $x^i(k)$.

La densidad de probabilidad en el instante $k - 1$ puede ser aproximada de acuerdo a una rejilla, según:

$$p(x(k-1)|m(k-1)) \approx \sum_{i=1}^N w^i(k-1) \Delta(x(k-1) - x^i(k-1)), \quad (2.36)$$

donde $\Delta(x)$ es una función delta de Dirac. El valor estimado (predicción) y el valor actualizado (corrección) después de una medida serían:

$$p(x(k)|m(k-1)) \approx \sum_{i=1}^N \hat{w}^i(k) \Delta(x(k) - x^i(k)), \quad (2.37)$$

$$p(x(k)|m(k)) \approx \sum_{i=1}^N w^i(k) \Delta(x(k) - x^i(k)). \quad (2.38)$$

El problema se transforma en propagar los pesos (o probabilidades) y luego actualizarlos de acuerdo al modelo del sistema $p(x(k)|x(k-1))$ y la medida $m(k)$.

El valor estimado de los pesos $\hat{w}^i(k)$ sería por definición:

$$\hat{w}^i(k) = \sum_{j=1}^N w^j(k-1) \int_{x \in x^i(k)} p(x|x^j(k-1)) dx, \quad (2.39)$$

mientras que si se recibe una medida los pesos se actualizarían a:

$$w^i(k) = \frac{\hat{w}^i(k) \int_{x \in x^i(k)} p(m(k)|x) dx}{\sum_{j=1}^N \hat{w}^j(k) \int_{x \in x^j(k)} p(m(k)|x) dx}. \quad (2.40)$$

Si se utilizan las aproximaciones de que las densidades de probabilidad están distribuidas en puntos finitos, las integrales se vuelven sumatorias, tales que :

$$\hat{w}^i(k) = \sum_{j=1}^N w^j(k-1) p(x^i(k)|x^j(k-1)), \quad (2.41)$$

$$w^i(k) \approx \frac{\hat{w}^i(k) p(m(k)|x^i(k))}{\sum_{j=1}^N \hat{w}^j(k) p(m(k)|x^j(k))}. \quad (2.42)$$

Este filtro requiere de una rejilla lo suficientemente densa para obtener una buena aproximación, pero esto implica que el número de puntos aumenta exponencialmente con respecto a las dimensiones. El incremento de los cálculos al aumentar las dimensiones es comúnmente llamado “the curse of dimensionality” [40] y es debido a que es necesario desperdiciar procesamiento en puntos de muy baja probabilidad.

2.3.2.2. Filtros de partículas

Bajo la misma idea de las rejillas de probabilidades es posible aproximar la densidad de probabilidad $p(x(k)|m(k))$ en el instante k , mediante N pares $\{x^i(k), w^i(k)\}$ [39], donde $\{x^i(k), i = 1, \dots, N\}$ es un conjunto de puntos de soporte y $\{w^i(k), i = 1, \dots, N\}$ es un conjunto de pesos (los pesos están normalizados de modo que $\sum_{i=1}^N w^i(k) = 1$). La densidad de probabilidad $p(x(k)|m(k))$ se aproximaría como:

$$p(x(k)|m(k)) \approx \sum_{i=1}^N w^i(k) \Delta(x(k) - x^i(k)). \quad (2.43)$$

Esta aproximación discreta a la pdf es idéntica a la ecuación 2.38, pero a diferencia de los métodos por rejilla de probabilidad, los puntos pueden estar distribuidos de manera no uniforme y cambiante de acuerdo al instante estudiado. La idea principal de los filtros de partículas es concentrar los puntos de estudio en los espacios de mayor probabilidad y no propagar los puntos en los espacios de muy baja probabilidad con el objetivo de optimizar el uso del procesador.

Un algoritmo básico para tratar los filtros de partículas es el algoritmo de muestreo de importancia secuencial (SIS), en el que los puntos de soporte están distribuidos de manera no uniforme de acuerdo a una “densidad de importancia” $q(\cdot)$, los pesos son elegidos utilizando la probabilidad esperada del punto correspondiente $p(x^i(k)|m(k))$, según:

$$w^i(k) \propto \frac{p(x^i(k)|m(k))}{q(x^i(k)|m(k))}. \quad (2.44)$$

Como la densidad de importancia se puede propagar de acuerdo a:

$$q(x(k)|m(k)) = q(x(k)|x(k-1), m(k))q(x(k-1), m(k-1)) \quad (2.45)$$

y la pdf de acuerdo a:

$$p(x(k)|m(k)) = \frac{p(m(k)|x(k))p(x(k)|x(k-1))}{p(m(k))}p(x(k-1)|m(k-1)) \quad (2.46)$$

$$\propto p(m(k)|x(k))p(x(k)|x(k-1))p(x(k-1)|m(k-1)), \quad (2.47)$$

por lo que los pesos se podrían actualizar de acuerdo a:

$$w^i(k) = w^i(k-1) \frac{p(m(k)|x^i(k))p(x^i(k)|x^i(k-1))}{q(x^i(k)|x^i(k-1), m(k))} \quad (2.48)$$

Un problema común con los filtros de partículas es la “degeneración” de sus partículas [41], cuando todas menos una partícula tienen pesos despreciables, por lo que se desperdicia poder de cómputo en propagar la información que tiene muy poco impacto en la aproximación de $p(x(k)|m(k))$. Una manera de medir la degeneración es utilizar el valor efectivo del número de muestras N_{eff} , según:

$$N_{eff} = \frac{N}{1 + \text{Var}(w^{*i}(k))}, \quad (2.49)$$

y $w^{*i}(k) = p(x^i(k)|m(k))/q(x^i(k)|x(k-1), m(k))$ son los verdaderos pesos. Debido a que no se puede evaluar exactamente se propone utilizar la aproximación:

$$\widehat{N_{eff}} = \frac{1}{\sum_{i=1}^N (w^i(k))^2}, \quad (2.50)$$

donde $1 < \widehat{N_{eff}} < N$. Un valor muy pequeño de N_{eff} indicaría una degeneración que debe ser corregida.

Existen diferentes técnicas para tratar con la degeneración, entre las que se encuentran, utilizar una buena densidad de importancia $q(x(k)|x(k-1), m(k))$ [41] o la utilización de remuestreos [42]. La elección de la densidad de importancia dependerá del sistema, pero la función que optimiza el valor efectivo del número de muestras es:

$$q(x(k)|x(k-1), m(k)) = p(x(k)|x^i(k-1), m(k)) \quad (2.51)$$

$$= \frac{p(m(k)|x(k), x^i(k-1))p(x(k)|x^i(k-1))}{p(m(k)|x^i(k-1))} \quad (2.52)$$

En la mayoría de los casos no se puede muestrear $p(x(k)|x^i(k-1), m(k))$, por lo que se tienen que asumir o aproximar densidades de importancia, lo que hace que la condición anterior no se cumpla pero se obtienen resultados aceptables de acuerdo al problema. Algunas excepciones son cuando $X(k)$ tiene un número finito de posibles valores y cuando el sistema es Gaussiano (lineal o no lineal) y las medidas son lineales [39]. Una alternativa simple de implementar, es utilizar:

$$q(x(k)|x(k-1), m(k)) = p(x(k)|x^i(k-1)) \quad (2.53)$$

lo que simplifica el cálculo de la ecuación 2.48.

Para concentrar el cálculo en las partículas de mayor probabilidad y descartar las de una probabilidad despreciable se utiliza un remuestreo [39]. Éste implica generar un set $\{X^*(k)\} =$

$\{x^{i*}(k), i = 1, \dots, N\}$ que represente la misma probabilidad pero con pesos distribuidos de manera más uniforme, cuando el valor de \widehat{N}_{eff} cae por debajo de cierto umbral.

Con el remuestreo se busca reiniciar los pesos a $w^i(k) = 1/N$ utilizando un muestreo uniforme de la inversa de la función de distribución de probabilidad, de modo que cada punto represente segmentos de la misma probabilidad. Un algoritmo básico para el remuestreo sería [39]:

```

c(1)=0
for i=1:N-1
    c(i+1)=c(i)+w_k^i
end
i=1
u1=uniform(0,1/N)
for j=1:N
    uj=u1+(j-1)/N
    while uj>c(i)
        i=i+1
    end
    x_k^{j*}=x_k^i
    w_k^j=1/N
end

```

Primero se obtiene la aproximación de la función de distribución “c” o probabilidad acumulada y se inicializa un límite “u1” en un punto aleatorio uniformemente distribuido entre 0 y 1/N. Luego se busca sucesivamente el índice “i” de la función de distribución que sobrepasa el límite, se agrega el punto $x^i(k)$ a la muestra, se incrementa el límite en 1/N y se repite la búsqueda N veces. Los puntos se distribuirán uniformemente de modo que el peso de cada uno será 1/N.

El remuestreo permite mejorar el uso eficiente del procesador pero puede llevar al “empobrecimiento de las muestras” pues si una partícula tiene una probabilidad muy grande, el algoritmo repetirá dicha partícula y dejará de representar partículas de baja probabilidad, por lo que el número de puntos a evaluar disminuiría, generando una pérdida de la diversidad. Una solución consistiría en agregar una aleatorización local a las partículas repetidas.

El algoritmo SIS representa los filtros de partículas en su forma más general y la mayoría de los algoritmos encontrados en la literatura pueden tratarse como casos específicos de la representación anterior. Entre los métodos comúnmente utilizados está la utilización del remuestreo de importancias secuencial (SIR) [43] que utiliza la propagación de cada partícula por el modelo del sistema.

En general los filtros de partículas permiten estimar problemas no lineales y no Gaussianos, mejorando las prestaciones de los EKF y UKF, pero al costo de ser susceptibles a la degeneración o empobrecimiento de sus partículas e incrementando el costo computacional. Los filtros de partículas son la herramienta más completa en estimación mientras se tenga el poder de cómputo para utilizarla.

Las aplicaciones que utilizan filtros de partículas en localización suelen utilizar una simplificación de la información de modo que el número de estados a estimar se reducen, así es posible encontrar métodos que utilizan PDR simplificando la información suministrada a un paso y un cambio de ángulo como [44, 45] o inclusive métodos que fusionan la información con balizas de posiciones desconocidas [46] para mejorar la convergencia de la estimación.

2.3.3. Propagación de la estimación con sensores inerciales

Siguiendo el esquema de la figura 2.1, es necesario asociar los pasos detectados y la información inercial a la propagación de los estados. Los sensores inerciales son una excelente fuente de información para calcular la propagación en (2.13), debido a que miden características asociadas al cambio entre estados. La mayoría de los sistemas actuales siguen dos estructuras para introducir las medidas inerciales en la propagación de la estimación, la propagación basada en pasos y la basada en INS. La primera utiliza las estimaciones de la longitud y cambio de ángulo de los pasos dados por una persona, mientras que la segunda utiliza cada medida de la IMU, utilizando un INS para actualizar los estados modelados.

La selección del método a utilizar dependerá de la posición de la IMU, las medidas externas y el número posible de actualizaciones por segundo del filtro. A continuación ambos métodos son explicados.

2.3.3.1. Propagación de los estados basada en pasos

La propagación basada en pasos utiliza la estimación de la zancada para actualizar la posición de la persona. Existen múltiples modelos de estados y medidas que utilizan las zancadas para actualizar los estados, pero en su forma más básica [47] propaga las posiciones en el plano horizontal (r_x y r_y) y la orientación (guiñada θ) según:

$$\hat{r}_x(k) = r_x(k-1) + SL(k) \cdot \cos(\hat{\theta}(k)), \quad (2.54)$$

$$\hat{r}_y(k) = r_y(k-1) + SL(k) \cdot \sin(\hat{\theta}(k)), \quad (2.55)$$

$$\hat{\theta}(k) = \theta(k-1) + \Delta\theta(k), \quad (2.56)$$

donde SL (Stride Length) es la longitud del paso y $\Delta\theta$ es el cambio de la dirección del paso con respecto al anterior, como se puede apreciar en la figura 2.7.

Para obtener la longitud de los pasos y su cambio de orientación se pueden utilizar múltiples métodos entre los que se encuentran:

- **Estudio de la magnitud de las aceleraciones [48]:** Se asume que la longitud del paso es proporcional al movimiento de la cadera en los seres humanos por lo que se estudia la diferencia entre el máximo y el mínimo pico de aceleración. Con esta información se estima que la longitud del paso es:

$$SL_w = K \cdot \sqrt[4]{\max_{k \in Step(j)} (Acc_z(k)) - \min_{k \in Step(j)} (Acc_z(k))}, \quad (2.57)$$

mientras que el cambio de ángulo se calcula utilizando el magnetómetro o el giróscopo. Este método es muy utilizado en pedómetros debido a que solo necesita la información del acelerómetro y es fácil de implementar.

- **Modelo de péndulo invertido [49]:** Se modela el movimiento del pie durante el caminado asumiendo que se comporta como un péndulo invertido. De este modelo se puede obtener la relación entre la longitud del paso, altura alcanzada en el balanceo h (medida con una IMU en la base de la espalda) y la longitud de la pierna l de acuerdo a:

$$SL_p = 2 \cdot K \cdot \sqrt{2 \cdot l \cdot h - h^2}, \quad (2.58)$$

donde K es una constante de ajuste para cada persona.

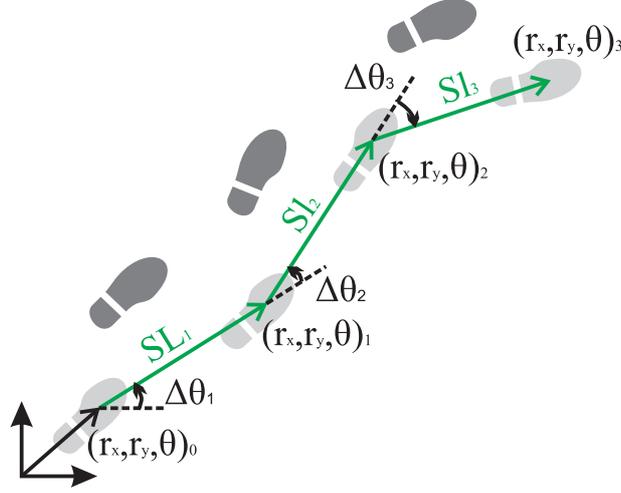


Figura 2.7: Propagación de la posición basada en concatenación de pasos, utilizando la longitud del paso SL y el cambio de orientación del paso $\Delta\theta$

- **Estudio de la frecuencia del movimiento [21, 50]:** Luego de estudiar la relación entre la longitud del paso y la frecuencia [50], se propone modelar la longitud del paso como una función dependiente de la altura de la persona h y la frecuencia del paso f obtenida de análisis en frecuencia de las señales de la IMU, de acuerdo a:

$$SL_f = h \cdot (a \cdot f + b) + c, \quad (2.59)$$

donde a , b y c son parámetros de ajuste para cada persona. A diferencia de los métodos anteriores en esta implementación la calibración es independiente de la posición de la IMU en el cuerpo, mientras se pueda determinar la frecuencia de los pasos.

- **Estimación por métodos de control inteligente [51–53]:** El modo de caminado, su frecuencia y longitud del paso son estimados utilizando diferentes métodos de control inteligente como las redes neuronales y la lógica difusa, observando diferentes características de la señal como la amplitud de las aceleraciones, sus máximos y mínimos, etc.
- **Pasos obtenidos de PDR [54–56]:** Se utilizan las estimaciones de la posición obtenidas de un INS implementado en un EKF con actualizaciones de velocidad cero (ZUPT, Sección 2.4.1.1) para obtener las longitudes y cambios de ángulos de los pasos con un modelo de estados simplificado. En los trabajos de [54–56] se utiliza la simplificación para poder implementar un filtro de partículas con corrección por mapas.

2.3.3.2. Propagación de los estados basada en INS

Si se dispone de una IMU (3 acelerómetros ortogonales y 3 giróscopos ortogonales), se puede estimar de la posición de ésta durante cada muestra. El principal problema asociado es el crecimiento del error, que utilizando INS generaría un error que crece como el cubo del tiempo [19].

Las IMU tácticas y de navegación serían capaces de mantener la posición y orientación durante suficiente tiempo, pero debido a su costo, peso y volumen no pueden ser utilizadas fácilmente por una persona. Debido a los requerimientos de tamaño y costo, las únicas IMU disponibles son de tipo MEM, pero debido a su nivel de ruido y variabilidad del bias, solo son capaces de estimar la posición por algunos segundos.

Una solución propuesta en [57] es colocar la IMU en el pie y asumir que la velocidad es nula durante las fases de apoyo. Si se inicia el INS con un apoyo a velocidad nula se puede utilizar (2.2) para calcular la evolución de la velocidad en el balanceo. Al finalizar el balanceo, durante el próximo apoyo se obtiene una velocidad $\dot{\mathbf{r}}_e$ que se asume será el error acumulado debido al bias. Para eliminarlo de la estimación de la velocidad se asume un error creciente linealmente en la velocidad y se usa:

$$\dot{\mathbf{r}}_c(k) = \dot{\mathbf{r}}(k) - \frac{(k - k_0)}{k_1 - k_0} \cdot \dot{\mathbf{r}}_e, \quad (2.60)$$

donde k_0 y k_1 son los índices del apoyo previo y el actual respectivamente. Por último se obtiene el desplazamiento usando (2.3) con las velocidades corregidas $\dot{\mathbf{r}}_c$. Este método es la forma más sencilla de propagar la posición utilizando INS, pero no corrige el error acumulado en la orientación y aproxima el error durante el balanceo a un incremento lineal.

Otra forma propuesta en [20] y más común, es propagar los estados asociados a la navegación inercial (velocidades angulares $\boldsymbol{\omega}$, orientación C_b^n , aceleraciones $\ddot{\mathbf{r}}$, velocidades $\dot{\mathbf{r}}$ y posición \mathbf{r}) utilizando un filtro complementario que propague los errores de los estados anteriormente mencionados.

La técnica introducida por Foxlin [20] asume que la IMU está colocada en el pie del peatón (como se observa en la figura 2.8) y propaga los errores de la navegación inercial con un filtro de Kalman Extendido (EKF). En las implementaciones de [18, 20] se propagan los errores de orientación ($\Delta\Psi$), los bias del giróscopo ($\Delta\boldsymbol{\omega}$), los errores de posición ($\Delta\mathbf{r}$), los errores de velocidad ($\Delta\dot{\mathbf{r}}$) y los bias del acelerómetro ($\Delta\mathbf{a}$). El error de orientación $\Delta\Psi$ se utiliza para corregir la estimación de la orientación \hat{C}_b^n y obtener la orientación real C_b^n , utilizando:

$$C_b^n = e^{[\Delta\Psi \times]} \cdot \hat{C}_b^n \quad (2.61)$$

En la implementación se propagan la media de los errores estimados $\Delta\hat{\mathbf{x}}(k)$ y la covarianza estimada $\hat{P}(k)$ como:

$$\Delta\hat{\mathbf{x}}(k) = \Phi(k-1) \cdot \Delta\mathbf{x}(k-1) + w \quad (2.62)$$

$$\hat{P}(k) = \Phi(k-1) \cdot P(k-1) \cdot \Phi^T(k-1) + Q \quad (2.63)$$

donde w es el modelo de ruido aditivo del proceso con covarianza Q y $\Phi(k)$ es el Jacobiano de la función de transición de estados. Si el vector de estados es $\Delta\mathbf{X} = [\Delta\Psi; \Delta\boldsymbol{\omega}; \Delta\mathbf{r}; \Delta\dot{\mathbf{r}}; \Delta\mathbf{a}]$, la matriz de transición de estados $\Phi(k)$ es definida como:

$$\Phi(k) = \begin{bmatrix} I_{3 \times 3} & C_b^n(k) \cdot \Delta t & 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} \\ 0_{3 \times 3} & I_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} \\ 0_{3 \times 3} & 0_{3 \times 3} & I_{3 \times 3} & I_{3 \times 3} \cdot \Delta t & 0_{3 \times 3} \\ [C_b^n(k) \cdot Acc(k) \times] \cdot \Delta t & 0_{3 \times 3} & 0_{3 \times 3} & I_{3 \times 3} & C_b^n(k) \cdot \Delta t \\ 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} & I_{3 \times 3} \end{bmatrix} \quad (2.64)$$

Cuando se obtiene algún tipo de medida relativa a la posición, el modelo de observación es:

$$\mathbf{m}(k) = H(k) \cdot \Delta\mathbf{x}(k) + \eta \quad (2.65)$$



Figura 2.8: Posición de la IMU en el pie. [18]

donde η es el modelo de ruido aditivo de la medida con covarianza R , y $H(k)$ es el Jacobiano de la función de observación con respecto a los estados.

Las ecuaciones de actualización de los estados y la covarianza según el filtro de Kalman son:

$$\Delta \mathbf{x}(k) = \Delta \hat{\mathbf{x}}(k) + K(k) \cdot (\mathbf{m}(k) - H(k) \cdot \Delta \hat{\mathbf{x}}(k)) \quad (2.66)$$

$$P(k) = (I - K(k) \cdot H(k)) \cdot \hat{P}(k) \quad (2.67)$$

donde $K(k)$ es la ganancia de Kalman, valor que minimiza la covarianza $P(k)$, según:

$$K(k) = \hat{P}(k) \cdot H^T(k) \cdot (H(k) \cdot \hat{P}(k) \cdot H^T(k) + R)^{-1}. \quad (2.68)$$

Si los estados del filtro producen valores no nulos, se corrige la estimación del INS con estos valores de acuerdo a (2.61) y:

$$\mathbf{r}(k) = \hat{\mathbf{r}}(k) - \Delta \mathbf{r}(k), \quad (2.69)$$

$$\dot{\mathbf{r}}(k) = \hat{\dot{\mathbf{r}}}(k) - \Delta \dot{\mathbf{r}}(k) \quad (2.70)$$

$$(2.71)$$

y se restablecen los valores de la estimación de los errores a $\Delta \mathbf{x} = [0_{15 \times 1}]$, ya que se eliminó el error medio de la estimación.

Debido a la utilización de IMUs de tipo MEM (las únicas que pueden ser llevadas en el pie por su peso), esta estimación diverge por lo que es necesario la utilización de métodos de corrección de la deriva, en particular Foxlin propone la utilización del ZUPT que estudiaremos en la siguiente sección y con el que logra errores cercanos al 1% de la distancia total recorrida.

2.4. Métodos de corrección de la deriva

Debido al carácter integrativo de las estimaciones basadas en sensores inerciales la estimación diverge, por lo que es necesaria la utilización de medidas para corregir o minimizar la deriva

integrándolos en la estimación como se observa en el bloque amarillo de la figura 2.1. Las técnicas más comunes de corrección de la deriva de los sensores inerciales pueden clasificarse como restricciones de movimiento, utilización de sensores internos y utilización de sensores externos.

Las medidas a utilizar dependerán de los sensores disponibles, el ambiente y la posición del sensor en el cuerpo, pero en general mientras mayor sea el número de medidas, mejor será la estimación. A continuación se presentan los diferentes tipos de correcciones y sus medidas más comunes.

2.4.1. Restricciones de movimiento

Las personas en ambientes interiores tienen ciertas características en su movimiento que pueden ser utilizadas para limitar el crecimiento del error y mejorar la estimación. Entre las restricciones más comunes se encuentran el hecho de que el pie presenta velocidades casi nulas, los apoyos prolongados pueden asociarse a condiciones de velocidad angular nula, la predisposición a caminar en ciertas direcciones en un edificio, la coincidencia de trayectorias con los mapas del edificio, etc. Estas restricciones de movimiento ayudan a limitar el crecimiento del error en la estimación y en algunos casos a obtener la posición global de la persona sin la necesidad de agregar nuevos sensores, pero requieren que estos estén en posiciones específicas o la persona siga ciertos patrones.

2.4.1.1. Actualizaciones de velocidad cero (ZUPT)

Cualquier estimación de la posición basada exclusivamente en la información de una IMU tiene un error que crece como el cubo del tiempo y es capaz de estimar la posición únicamente por algunos segundos. Sin embargo si se sabe que la IMU está ubicada en el pie de una persona caminando, se puede asumir que ésta mantendrá una velocidad casi nula durante el tiempo que el pie esté en apoyo.

La actualización de velocidad cero o ZUPT introducida por [20] en PDR, utiliza esa información para corregir el filtro, usando los algoritmos de detección de pasos de la Sección 2.2 para identificar los puntos de apoyo e implementando una medida que indique $\dot{\mathbf{r}} = [0 \ 0 \ 0]^T$. En el caso del estimador propuesto en la Sección 2.3.3.2, debido a que se estiman los errores de los estados, la medida del error de velocidad ($\Delta\dot{\mathbf{r}}$) sería el valor estimado en el INS para la velocidad:

$$m^{\text{ZUPT}} = \dot{\mathbf{r}}(k) \quad (2.72)$$

y la matriz de observación sería $H^{\text{ZUPT}} = [0_{3 \times 9} \ I_{3 \times 3} \ 0_{3 \times 3}]$.

El ZUPT es la medida más importante en estimaciones con la IMU en el pie, ya que disminuye el error a aproximadamente 1% de la distancia total recorrida, corrigiendo tanto el error de velocidad acumulado entre pasos, como el error de cabeceo y alabeo del INS (algo que no lograba el método de [57]). Sin embargo el principal problema del ZUPT es que no ofrece información sobre el error acumulado en la guiñada ni su bias asociado, por lo que es necesaria la utilización de otras medidas.

2.4.1.2. Actualizaciones de velocidad angular cero (ZARU)

El bias del giróscopo es la principal fuente de error en la estimación debido a que al estimar incorrectamente la orientación, se elimina incorrectamente el vector de gravedad, lo que introduce un bias creciente en las aceleraciones. Sin embargo, al utilizar ZUPT, ese error se corrige y se

estiman las componentes del bias del giróscopo en el plano horizontal, pero no la componente en el eje vertical, asociado a la guiñada. Una forma de estimar esos bias, es colocar la IMU en una plataforma de calibración, pero debido a que la IMU está sujeta al pie de la persona, esto no es posible.

Una solución es utilizar los momentos de apoyo para aplicar la corrección [3], pero [18] discute que los movimientos durante el caminado alteran esta medida, por lo que utilizan solo los apoyos prolongado del pie sobre el suelo para estimar momentos de velocidad angular nulos y por ende poder medir el bias. Este método es llamado actualizaciones de velocidad angular nula (ZARU, Zero Angular Rate Update [3]). Las medidas del filtro de Kalman propuesto serían:

$$m^{\text{ZARU}} = \text{Gyr}(k) \quad (2.73)$$

y la matriz de observación sería $H^{\text{ZARU}} = [0_{3 \times 3} \quad I_{3 \times 3} \quad 0_{3 \times 9}]$.

Los momentos con velocidades angulares cero pueden detectarse con algoritmos similares a los propuestos en la Sección 2.2 [18], pero estableciendo límites más estrictos a los detectores para evitar detectar las fases de apoyo durante el caminado que presentan rotaciones que alterarían el efecto de la medida. Una solución común es la utilización del detector de pasos pero activar las medidas ZARU solo si la duración del apoyo supera un umbral. Los principales problemas de estas medidas son las falsas detecciones de momentos sin giros, las pocas veces que se utiliza esta medida y el hecho de que no provee medidas absolutas de orientación.

2.4.1.3. Direcciones predominantes de movimiento

Para corregir la pérdida de la orientación se puede utilizar el hecho de que en ambientes interiores y exteriores las personas tienden a caminar en líneas rectas. Bajo este precepto se han desarrollado varias mejoras a los algoritmos de posicionamiento comenzando por el Heuristic Drift Reduction (HDR) desarrollado por Borestein en [58]. El método propone medir las velocidades angulares asociadas al eje z entre apoyos ω_z y corregirlas con un sistema de control integrativo de la señal a lazo cerrado (separado del filtro de PDR) cuando se detecta que la persona no giró su orientación significativamente. Al detectar que el sistema está en presencia de una curva se disminuyen los pasos del lazo integrador, hasta el punto en que se detectan rotaciones mayores a $0,6^\circ/\text{seg}$ se asume que la persona está dando una curva y no se modifica el factor de corrección.

Las correcciones del HDR permiten reducir el efecto de la deriva del bias en el giróscopo, pero debido al carácter integrativo del INS, este error se acumulará con el tiempo. Una posible solución llamada heuristic Drift Elimination (HDE) es propuesta por el mismo autor en [59]. En esta mejora al algoritmo, se utiliza el hecho de que la mayoría de los edificios debido a sus estructuras rectangulares tienen “direcciones predominantes” que pueden ser identificadas al observar la reconstrucción de la posición con sensores inerciales.

Utilizando un esquema similar al propuesto para el HDR se busca agregar factores de corrección a la velocidad angular en el eje vertical que generen que los pasos estén orientados en los 8 ángulos que se cree puede caminar la persona (ángulos múltiplos de 45°). Cuando se detecta un ángulo de orientación muy distinto a los principales o cuando la persona da pasos muy cortos (se asume que si la persona da pasos muy cortos, no se está desplazando por los pasillos) el efecto del bucle integrador es minimizado para no introducir errores adicionales al sistema.

Las medidas de HDE permiten medidas absolutas de orientación, pero debido a su implementación como un lazo de control de las medidas del giróscopo fuera del filtro de PDR, no corrige los efectos preexistentes en la posición de la persona e introduce errores cuando la persona no

camina por las direcciones principales. En [60] el autor propone mejoras al algoritmo desarrollando el improved Heuristic Drift Elimination (iHDE). Entre las mejoras está la utilización de la dirección del paso en vez de la orientación de la IMU durante el apoyo, adicionalmente implementa un detector de caminado recto observando la variabilidad de los ángulos de los pasos e implementa el método como una corrección del ángulo de guiñada en el filtro de PDR, lo que permite la corrección de los errores asociados a la orientación (como la posición).

El método evita los errores debidos a trayectorias curvas que pasan cerca de las direcciones principales, pero al igual que el HDE si pasa mucho tiempo sin medidas podría perder la orientación y al volver a caminar recto, orientarse con la dirección principal incorrecta. Como mejora a esta situación se propone la utilización del Magnetically-aided improved Heuristic Drift Elimination (MiHDE) en [61] que utiliza las direcciones de los campos magnéticos durante los últimos pasos declarados como rectos para seleccionar la orientación principal a utilizar.

2.4.1.4. Correcciones utilizando el mapa del edificio

El mapa de un edificio es usualmente utilizado para mostrar las trayectorias obtenidas usando algún sistema de posicionamiento en ambientes interiores, pero al sobreponer las trayectorias sobre el mapa se puede obtener una mejor idea de la posición real. Esto es debido a que si se dispone de la información del mapa, las estimaciones están limitadas a pasar solamente por regiones específicas, lo que delimita el crecimiento del error.

La localización de vehículos utilizando sistemas GNSS motivó los primeros intentos de usar la información de los mapas para mejorar el posicionamiento. El autor en [62] ofrece un estado del arte para el 2007 y establece un método de clasificación de algoritmos de corrección por mapas para vehículos. Aplicando el mismo criterio a los algoritmos de posicionamiento asistido por mapas, estos se pueden clasificar como:

Análisis geométrico: La posición estimada se aproxima a trayectorias conocidas, aproximando las estimaciones a puntos, curvas o polígonos en el mapa. En [63], el autor propone un algoritmo utilizando un EKF basado en propagación de longitudes de pasos, estimaciones de orientación y medidas de posición de GPS y WiFi. Una vez obtenida una posición con el filtro, éste obtiene al punto más cercano a una red de las posibles trayectorias (segmentos de recta) y establece un vector de corrección en el filtro EKF. Esta técnica permite la utilización de un filtro como el EKF, pero requiere un posicionamiento absoluto y altera las trayectorias de la persona al encauzarlas en las trayectorias predefinidas.

Análisis topológico: Las estimaciones se aproximan a los puntos más cercanos, pero el paso entre ellos está limitado de acuerdo a una conectividad asociada a la posibilidad de pasar entre esos puntos. Utilizando este tipo de método, el autor en [64] mejora el método geométrico propuesto en [63] al implementar un detector de giros para identificar posibles cambios entre segmentos de trayectoria. El método mejora la estimación, pero requiere posicionamientos absolutos y altera las trayectorias.

Algoritmos probabilísticos de correcciones por mapas: Se obtiene la posición observando las probabilidades de posicionamiento en diferentes regiones del mapa, tomando en cuenta la conectividad entre las áreas y los estimados de posición y patrones de caminado. En [65] el autor propone la estimación de las probabilidades de posicionamiento en cada sección de las posibles trayectorias en un mapa, utilizando los desplazamientos obtenidos de medidas inerciales y la detección de giros en el patrón de caminado. Este método permite la estimación de la posición de la persona sin posición inicial o medidas absolutas, pero altera el patrón de caminado al proyectarlo solo sobre trayectorias específicas.

Algoritmos avanzados de correcciones por mapas: Cualquier método que trata la corrección por mapas usando técnicas de fusión sensorial para incluir múltiples medidas de diferentes sensores. La mayoría de los métodos propuestos [54, 55, 66] utilizan filtros no paramétricos usando la información obtenida de PDR para propagar las estimaciones y actualizar las probabilidades de acuerdo a la detección de cruces por paredes o cualquier medida adicional. Es el método más robusto y soluciona los problemas de posición inicial, no altera la trayectoria y no necesita posiciones absolutas, pero es el más pesado computacionalmente.

En [54, 55, 66], cada autor independientemente propuso el uso de filtros de partículas para estimar la posición y orientación de una persona. Los autores utilizaron la longitud del paso y el cambio de orientación (obtenida por PDR) para propagar las partículas, y reducen a cero los pesos de las partículas que cruzan cualquier pared. El autor en [67] también utiliza dicha implementación para guiar a personas en escenarios con múltiples plantas pero usando un mapa simplificado.

La información del mapa le permite al filtro enfocarse solo en las partículas que pasan por el camino correcto. El número de operaciones requerido para detectar los cruces por paredes crece con el producto del número de partículas y el número de paredes. Los métodos propuestos en [54, 66, 67] verifican el cruce de todas las partículas con todas las paredes del edificio, lo que solo es viable si el número de partículas y paredes es pequeño.

Para solucionar ese problema el autor en [55] propone incluir la habitación o área como estado y evaluar los cruces solamente entre la partícula y las paredes de dicha habitación o área. Esta mejora permite que cada partícula solo necesite verificar entre 4 y 20 paredes, acelerando el cómputo significativamente y haciéndolo escalable. El algoritmo define dos tipos de segmentos que definen el borde de las áreas a estudiar, cruzables (como puertas y conexiones entre habitaciones) y no cruzables (como paredes y ventanas), y verifica la intercepción entre el movimiento de la partícula \vec{AB} (de $r^{(i)}(j-1)$ a $r^{(i)}(j)$), y las paredes y puertas de la habitación de la partícula. Los tres posibles resultados de la verificación son:

1. El movimiento no intercepta ningún segmento. La partícula mantiene su peso y habitación.
2. El movimiento intercepta una pared. A la partícula se le asigna un peso nulo.
3. La primera intercepción de la partícula es con una puerta. Se cambia la habitación de la partícula a la habitación respectiva y se cambia el vector \vec{AB} a un nuevo vector \vec{IB} , donde I es el punto de intercepción entre \vec{AB} y la puerta. Se verifica de nuevo los cruces con el nuevo vector y la nueva habitación.

El proceso se repite hasta que se obtenga uno de los 2 primeros resultados.

2.4.1.5. Correcciones por reconocimiento de acciones

Al caminar en un edificio, una persona suele realizar diferentes acciones de acuerdo al lugar en que se encuentra, es por ello que si se analiza la conducta de la persona, observando las señales de la IMU, se puede estimar su posición sin necesidad de sensores adicionales.

Diferentes trabajos han tratado el reconocimiento de acciones basados en sensores inerciales. En [68], [69], [70] y [71] se utiliza una IMU en el cuerpo para clasificar los movimientos en diferentes posibles acciones, utilizando diferentes métodos probabilísticos. Para analizar cual método clasifica mejor las acciones, el autor en [72] utilizan 5 IMU colocadas en las muñecas,

rodillas y pecho para estudiar los métodos de clasificación de patrones al realizar 19 tipos distintos de acciones. El autor concluye que el mejor clasificador es el basado en decisiones Bayesianas.

Los métodos de clasificación de acciones suelen utilizarse para estimar las características de los pasos (Sección 2.3.3.1), pero detectando ciertas acciones asociadas a posiciones específicas como subir escaleras, usar elevadores, sentarse, etc. [73, 74]. Utilizando un esquema similar el autor en [75] utiliza un algoritmo PDR basado en navegación inercial para detectar y clasificar las pendientes del caminado, pudiendo detectar rampas y corrigiendo la posición en un estimador basado en un EKF.

Si no se conoce a priori el mapa del edificio, es posible utilizar el hecho de que las personas tienden a repetir acciones en lugares específicos. Siguiendo este precepto, se puede utilizar una localización y mapeo simultáneo de estas acciones [76] lo que permitiría disminuir la deriva de la estimación.

2.4.2. Utilización de sensores internos

Debido al problema de la deriva de la medida en las IMU, es común que éstas incorporen sensores adicionales para reforzar las estimaciones. Los sensores usualmente incorporados en las IMU son los barómetros, magnetómetros, cámaras, etc. Estos sensores pueden asociarse a posiciones o orientaciones globales que disminuirían el crecimiento del error.

2.4.2.1. Barómetros

La presión atmosférica varía con la altura, por lo que es una característica usualmente utilizada para conocer la altura de una persona con respecto al mar. Se sabe que la presión puede variar lentamente debido a las condiciones climáticas, aún así, las medidas pueden ser utilizadas durante periodos de tiempo de algunas horas asumiendo dichas condiciones constantes.

La relación entre la altura y la presión puede ser aproximada (asumiendo un gradiente de temperatura constante) si se conoce la temperatura T_0 y la presión P_0 en un punto de referencia [77]:

$$r_z = \frac{T_0}{L} \left(\left(\frac{P}{P_0} \right)^{-L \cdot R/g} - 1 \right), \quad (2.74)$$

donde L es la tasa de incremento de la temperatura con la altura, r_z es medida con referencia a la altura donde se miden P_0 y T_0 , R es la constante de los gases y g es la magnitud de la gravedad. Debido a las variaciones en las condiciones climáticas si se utiliza la presión y temperatura a nivel del mar para obtener la altura absoluta, habría que calibrar los valores de P_0 y T_0 en cada estimación, pero para evitarlo los autores utilizan diversas técnicas.

En diferentes trabajos como [78–81], se utiliza el barómetro para obtener la información de la altura en algoritmos de posicionamiento por PDR basado en pasos. Esto es debido a que dicho algoritmo solamente provee información del posicionamiento en el plano horizontal. Debido a las variaciones de la presión producidas por los cambios en el clima, estos métodos suelen estimar la presión a nivel del mar (conociendo la altura actual del GPS u otras fuentes, [79]) o solo tomar en cuenta los cambios de presión para estimar la usan como referencia las condiciones de presión y temperatura iniciales del recorrido, y por ende miden las diferencias de altura con respecto a la posición inicial [81]. En [82] el autor registra las diferencias de altura con respecto al punto inicial e incluye esta información como medidas en el filtro EKF de PDR basado en INS con ZUPT, corrigiendo directamente las derivas en altura de la navegación inercial.

Debido a que la altura medida con un barómetro puede estar afectada por cualquier cambio en las condiciones climáticas, mejores resultados pueden ser obtenidos mediante la utilización de mediciones de presión de referencia en puntos cercanos de altura conocida [83, 84]. Este método permite mantener la referencia de altura con errores inferiores a 50 cm, aun cuando la referencia está a más de 1 Km de distancia [85].

2.4.2.2. Magnetómetros

El campo magnético de la Tierra es una referencia de orientación descubierta en China hace más de 2000 años y desde hace siglos ha sido utilizada para navegación. Se cree que el campo magnético es provocado por los movimientos del núcleo de hierro fundido del planeta y tiene una magnitud de entre 0,25 y 0,65 Gauss en dirección al norte magnético de la tierra (a unos 10° del norte geográfico de la Tierra, aunque se desplaza cada año) con ángulos de inclinación (ángulo entre el vector y el plano horizontal) y declinación (ángulo horizontal entre el vector y el norte geográfico).

En general la magnitud, inclinación y declinación del campo magnético cambian con la posición en el mundo [27] y están modeladas según el Campo Internacional de Referencia Geomagnética (IGRF por sus siglas en inglés). Estos cambios son pequeños para desplazamientos del orden de las distancias a tratar en este trabajo, por lo que conociendo la ubicación general se puede corregir la declinación para obtener la orientación del norte geográfico de la Tierra.

En los sistemas de navegación inerciales es común utilizar la información del campo magnético de la Tierra para corregir la orientación obtenida de los giróscopos. Este método es fiable en exteriores y ha sido extendida a ambientes interiores en numerosas ocasiones. La forma más básica de integración de la información en PDR es mediante la detección de la longitud del paso y la obtención del cambio de orientación a partir de la integración del giróscopo corregido con el cambio de orientación del compás magnético [86].

Una manera más completa de utilizar el campo magnético para corregir la orientación fue propuesta en [18], donde se utiliza la medida de la orientación en el plano horizontal durante la etapa de apoyo para corregir los bias del giróscopo en un EKF. Este planteamiento permite la utilización del campo magnético, pero al igual que en [86] se ven afectados por la presencia de perturbaciones magnéticas generadas por estructuras metálicas, motores, etc. En [18] se utiliza la proyección del campo magnético en el plano horizontal para estimar los errores de orientación con respecto al sistema inercial y si estos no son detectados como perturbaciones, son corregidos utilizando el EKF de un PDR basado en INS.

Para utilizar el campo magnético en ambientes interiores es necesaria la cuantificación de la calidad de la medida y la detección de perturbaciones. En [27] se propone identificar la calidad de los campos magnéticos estudiando sus ángulos de inclinación, magnitud total, horizontal y vertical. Este método permite discriminar la información errada del Magnetómetro, pero en ambientes con fuertes perturbaciones magnéticas descartaría la mayor parte de la información.

Se puede intuir que el campo magnético medido en el sensor \mathbf{B}^b cambia de acuerdo a las rotaciones de éste, por lo tanto se podría obtener información del giróscopo observando los cambios en el Magnetómetro. Asumiendo que el campo magnético en el plano de navegación inercial \mathbf{B}^n (aunque tenga perturbaciones) permanece constante, en [27] se ha propuesto que el error de medida entre muestras del campo magnético en el plano de navegación inercial $\delta\mathbf{B}^n$ es:

$$\delta\mathbf{B}^n(k) = \mathbf{B}^n(k) - C_b^n(k+1) \cdot \mathbf{B}^b(k+1). \quad (2.75)$$

Descomponiendo la matriz de orientación $C_b^n(k+1)$ como una rotación sobre la matriz de

orientación anterior y utilizando el vector de las rotaciones angulares del gir6scopo $\boldsymbol{\omega}$, tenemos $C_b^n(k+1) = (I - [\boldsymbol{\omega}\Delta t \ \times]) \cdot C_b^n(k)$ usando una aproximaci6n de primer orden de la rotaci6n. Aproximando el campo magn6tico en el instante $k+1$ como el campo magn6tico anterior m6s un error $\mathbf{B}^b(k+1) = \mathbf{B}^b(k) + \varepsilon_B$ tenemos

$$\delta\mathbf{B}^n(k) = \mathbf{B}^n(k) - (I - [\boldsymbol{\omega}\Delta t \ \times]) \cdot C_b^n(k) \cdot (\mathbf{B}^b(k) + \varepsilon_B) \quad (2.76)$$

$$\delta\mathbf{B}^n(k) = \mathbf{B}^n(k) - C_b^n(k) \cdot \mathbf{B}^b(k) - C_b^n(k) \cdot \varepsilon_B + [\boldsymbol{\omega}\Delta t \ \times] \cdot \mathbf{B}^n(k) + [\boldsymbol{\omega}\Delta t \ \times] \cdot \varepsilon_B \quad (2.77)$$

Descartando el 6ltimo t6rmino pues es un error de segundo orden y eliminando los t6rminos iguales ($\mathbf{B}^n(k) = C_b^n(k) \cdot \mathbf{B}^b(k)$), tenemos

$$\delta\mathbf{B}^n(k) = [\boldsymbol{\omega}\Delta t \ \times] \cdot \mathbf{B}^n(k) - C_b^n(k) \cdot \varepsilon_B \quad (2.78)$$

$$\delta\mathbf{B}^n(k) = [-\mathbf{B}^n(k) \ \times] \cdot \boldsymbol{\omega}\Delta t - C_b^n(k) \cdot \varepsilon_B. \quad (2.79)$$

Esta ecuaci6n relaciona la variaci6n en el campo magn6tico del sensor con las rotaciones en el gir6scopo y puede ser utilizada para estimar los errores del gir6scopo. En la figura 2.9 se observa la variaci6n del campo magn6tico, medido en el sistema de referencia del sensor (por facilidad se ubic6 en el plano XY) y su relaci6n con la rotaci6n en el eje Z.

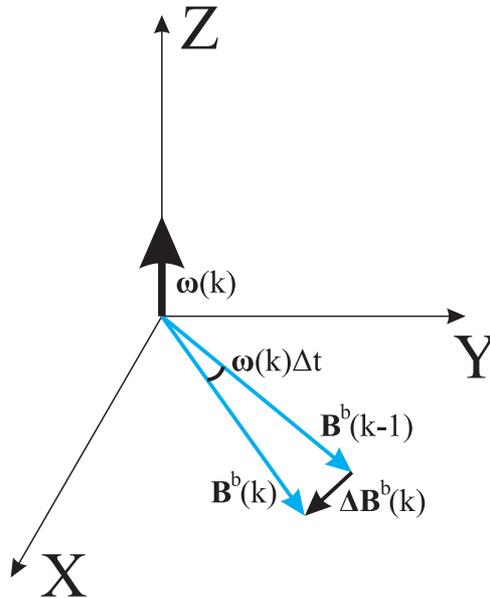


Figura 2.9: Cambio del campo magn6tico medido originado por la rotaci6n de la IMU.

Por otro lado, las perturbaciones magn6ticas en ambientes interiores suelen estar asociadas a las posiciones, por lo que si se logra caracterizar el campo magn6tico en un edificio, esta informaci6n puede ser utilizada para asistir en el posicionamiento [87]. Adicionalmente, si dichas variaciones en el campo magn6tico son identificadas y mapeadas durante la localizaci6n, pueden ser utilizadas al volver a dicha posici6n para delimitar el error de posici6n, generando un algoritmo de autolocalizaci6n y mapeo (SLAM) [88].

2.4.2.3. Visi6n artificial

Intuitivamente las personas utilizan el sentido de la visi6n y la percepci6n del movimiento en el o6do interno para ubicarse en cualquier ambiente. Las c6maras son los dispositivos encargados

de captar la luz emitida o reflejada por los objetos que nos rodean y emular el sentido de la visión.

Una técnica común en navegación inercial es la utilización de puntos de referencia para reconstruir la posición del sistema de navegación inercial con respecto al sistema global. En [35,89] se utilizan marcadores visuales como referencias de posición y orientación conocidos, que evitan la deriva de estimaciones puramente inerciales.

Si se dispone de cámaras estéreo [90] o información de la distancia a puntos de interés [91] es posible realizar un seguimiento de los puntos detectados mediante un EKF y proveer información a un sistema de navegación inercial. Con los puntos detectados es posible también generar un mapa de la zona recorrida y usarlos como referencia para futuros recorridos (SLAM).

Muchos teléfonos inteligentes incorporan sensores de luz que permiten ajustar la iluminación de la pantalla. Utilizando estos sensores es posible identificar de una manera sencilla y con escaso cómputo la presencia de luz exterior o luminarias cercanas. Si se conoce la posición y dimensiones de las luminarias en un edificio, es posible corregir las estimaciones de posición aproximándolas a las luces del edificio. En [92] se propone la utilización de estas señales y PDR para localizar con un filtro de partículas a una persona.

2.4.3. Utilización de medidas externas

Para poder estimar de forma absoluta la posición de una persona es necesaria la referencia de medias absolutas. Estas suelen ser los sistemas GNSS, sistemas de posicionamiento locales, ángulos de incidencia o distancias a posiciones conocidas, etc.

2.4.3.1. Medidas de sistemas de posicionamiento por satélites

Los sistemas GNSS son la referencia de posicionamiento en exteriores, es por ello que son los más utilizados para mejorar las estimaciones de sistemas de posicionamiento basados en sensores inerciales. Las fusiones de la información de los GNSS con sistemas inerciales suelen clasificarse de las siguientes maneras [6]:

- **Sistemas desacoplados (Uncoupled systems):** Las medidas de posición y velocidad de los sistemas GNSS son utilizadas para inicializar un sistema de posicionamiento inercial, manteniendo ambos sistemas independientes. Este sistema es poco común cuando se utilizan IMUs comerciales pues éstas divergen rápidamente.
- **Integración suave (Loosely coupled integration):** Las posición y velocidad obtenida de los sistemas GNSS son utilizadas como medidas en un filtro (usualmente un EKF) que corrige la deriva de un sistema INS, por último la posición estimada por éste es utilizada para inicializar los correladores del GNSS. Si no se reciben suficientes medidas para estimar la posición en base a los satélites, no se puede proveer información al INS. Esta técnica es utilizada en [93,94] para mejorar las estimaciones del GNSS con medidas inerciales.
- **Integración fuerte (Tightly coupled integration):** Los pseudo rangos y diferencias de distancia son utilizados como medidas en el filtro de corrección de la deriva del INS y la posición estimada por éste inicializa los correladores del GNSS. Al utilizar cualquier distancia recibida, se puede corregir la estimación cuando hay pocas medias de los satélites, pero la presencia de multitrayectos puede perturbar la estimación. En [95,96] se utilizan los pseudor rangos provenientes del GNSS como medidas en un sistema de navegación inercial en exteriores.

- **Integración profunda (Deep o ultra-tightly coupled integration):** Cada uno de los correladores del GNSS es corregido usando la información de la IMU y la estimación de las derivas de los relojes, lo que permite una mejor detección de multicaminos. Las estimaciones son integradas en un filtro central para unificar todas las medidas. La integración profunda es implementada en [97] utilizando un filtro de Kalman Unscented para estimar las variaciones por efecto doppler en el correlador y así poder identificar correctamente los multicaminos.

Debido a la baja calidad de las medidas en ambientes interiores, las medidas de los GNSS no suelen utilizarse directamente en ambientes interiores. Sin embargo, las medidas de los satélites pueden proveer información antes y después de entrar en los edificios, estableciendo un punto de inicio (y posiblemente la orientación) en la estimación, por lo que podrían considerarse medidas desacopladas.

Las medidas pueden ser utilizadas en una estimación de PDR con un esquema de integración suave si las medidas de posición son introducidas como observaciones de posición con una covarianza constante (y alta) [20]. Adicionalmente, si el sistema es capaz de proveer la matriz de covarianza de la estimación de la posición, estas medidas pueden ser introducidas en una estimación ya sea utilizando estimaciones de la longitud del paso [98] o INS con ZUPT [92].

Si el receptor GNSS es capaz de proveer los rangos a los satélites, se puede implementar una integración fuerte con PDR como proponen [99] (utilizando INS con ZUPT), [100] (utilizando estimaciones de la longitud del paso) o [101] (comparando ambos métodos PDR).

En [80], el autor propone una integración profunda de las medidas utilizando, utilizando PDR basado en la estimación de la longitud del paso. Sin embargo, este tipo de fusiones son poco comunes debido a que requieren tener acceso a los correladores del sistema GNSS, lo que aumenta el costo del sistema.

2.4.3.2. Medidas de sistemas de posicionamiento locales

En algunos ambientes interiores (y exteriores) es posible encontrar diferentes dispositivos que son capaces de suministrar medidas asociadas a la posición de la persona. En general cualquier sensor suministrará una medida m_i , asociada la posición de acuerdo a $m_i = h_i(\mathbf{r}) + e_i$, donde h_i es la función que relaciona las medidas y la posición y e_i es el patrón de error de la medida.

Para asociar una posición a dicha medida, se puede utilizar una serie de técnicas que permiten obtener la posición \mathbf{r} que satisfaga todas las medidas recibidas [25]. Las técnicas más comunes utilizadas por los sistemas de posicionamiento local (LPS) son:

- **Métodos directos:** Resolver el sistema de ecuaciones generado por un conjunto de medidas. Debido a que la mayoría de los sistemas de ecuaciones son no lineales, el ruido puede producir soluciones imaginarias y no se puede medir directamente el nivel de error de la posición obtenida.
- **Linealización de la función de observación:** Se agregan variables para hacer lineal las ecuaciones. Debido al aumento en el número de variables es necesario un mayor número de medidas para resolver el sistema de ecuaciones.
- **Métodos iterativos:** Se busca el punto $\hat{\mathbf{r}}$ que minimiza una función de coste asociada con el error de las medidas con respecto a las medidas esperadas en dicho punto. Se usan métodos como Gauss-Newton o Levenberg-Marquardt.

- **Métodos probabilísticos:** Se busca el punto \hat{r} que maximiza la probabilidad de ocurrencia de las medidas recibidas.
- **Fingerprinting:** Se comparan las medidas recibidas con respecto a un conjunto de medidas obtenidas en el proceso de calibración. La posición obtenida será aquella posición de la base de datos que tenga medidas más cercanas a las obtenidas.

Si se dispone de una posición proveniente de un LPS, la forma más sencilla y simple de utilizarla en la estimación con PDR es utilizarlo como un sistema desacoplado, cambiando la posición absoluta del sistema cada vez que se recibe una posición. Aunque no es un método nada óptimo, en [102] se utilizan estimaciones de las longitudes y cambios de orientación de los pasos para localizar a una persona y cuando se recibe una posición de un sistema LPS externo se fuerza la posición a la detectada.

Una forma más completa de fusión se logra con una integración suave, disminuyendo el efecto de los multicaminos, fallos de detección de medidas y falta de línea de visión. Usualmente para fusionar ambos sistemas se utilizan filtros bayesianos, donde el sistema PDR provee el modelo de movimiento de los estados, y el LPS inicializa y corrige los estados. Modelando la posición estimada por el LPS como una observación de la posición (una función lineal), la observación será:

$$m^{\text{LPS}} = r(k) + \eta, \quad (2.80)$$

donde η es el modelo de ruido utilizado (usualmente no Gaussiano). Si el sistema no suministra la matriz de error, la solución más común es la asunción de un ruido Gaussiano de covarianza constante, mientras que si se dispone de la matriz de covarianza del error, el error Gaussiano se ajustará a la covarianza suministrada.

Este esquema de fusión es utilizado en [103–105] para fusionar estimaciones PDR con la posición obtenida de diferentes LPS basados en RFID pasivos, WiFi (usando fingerprinting) y ángulos de incidencia respectivamente. En [103, 104] se utiliza un EKF para la fusión, mientras que en [105] se utiliza un filtro de partículas.

2.4.3.3. Ángulos de incidencia

El ángulo de incidencia (AOA) de una señal RF puede ser medido observando la diferencia de fase β de las señales recibidas en un arreglo de M antenas [106]. La relación entre dicha diferencia de fase y el ángulo de incidencia θ , es:

$$\beta = \frac{2\pi d}{\lambda} \sin \theta, \quad (2.81)$$

donde λ es la longitud de onda de la señal y d es la distancia entre antenas.

Una configuración de antenas en línea permite la medición del AOA con respecto al eje de las antenas, pero para determinar la dirección de la señal es necesario medir el ángulo a varios ejes. En [107] se propone una estructura en forma de L en 3 dimensiones como la de la figura 2.10 para determinar la dirección de la señal en función de las diferencias de fase con respecto a cada arreglo de antenas.

Las medidas de los ángulos pueden ser utilizadas en una triangulación de la posición, pero si se dispone de una medida de los desplazamientos de la persona, es posible la utilización de una integración fuerte de las medidas, mejorando la estimación y pudiendo utilizar las medidas aun cuando no hay suficientes para lograr una posición. En [108] se propone utilizar las medidas de la longitud y cambio de ángulo de los pasos de PDR para propagar la estimación en un EKF y

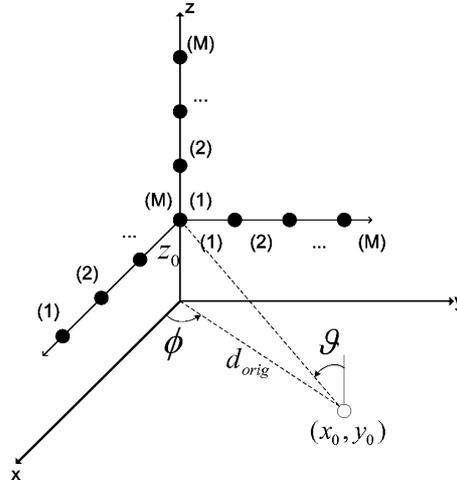


Figura 2.10: Arreglo de antenas en L de 3 dimensiones para la determinación de la dirección de la señal [107].

posteriormente corregir las estimaciones de acuerdo a múltiples medidas recibidas, entre ellas el ángulo de incidencia obtenido de un sistema UWB de Ubisense [109].

Otra alternativa para conocer los ángulos a posiciones conocidas es mediante la utilización de cámaras y marcadores visuales (e.g. códigos QR) en posiciones conocidas. En [110] el autor propone colocar marcadores fiduciales en la IMU llevada por una persona para que un sistema de cámaras con posiciones conocidas puedan medir los ángulos a la persona a ubicar. Estos ángulos de incidencia son utilizados como medidas en un filtro de Kalman propagado con las medidas de la IMU.

2.4.3.4. Distancias a balizas

Para mejorar las estimaciones PDR muchos autores utilizan mediciones asociadas a distancias a puntos conocidos. Las mediciones son usualmente fusionadas independientemente en las estimaciones, lo que genera una integración fuerte de las medidas.

Para medir la distancia entre una estación base y una estación móvil, comúnmente se miden características de las señales asociadas a la distancia como son el tiempo de vuelo, la atenuación o en algunos casos, medidas de la calidad de la señal [25]. La mayoría de los sistemas de radiofrecuencia tienen implementado algún tipo de medición de potencia recibida, por lo que la medida de la atenuación es el más frecuente de los métodos utilizados en RF.

Las ondas electromagnéticas en el espacio libre tienen una atenuación (Path Loss, $PL(d)$) predecible de acuerdo a la distancia recorrida d según [111]:

$$PL(d)_{dB} = PL(d_0)_{dB} + 20 \cdot \log \left(\frac{d}{d_0} \right), \quad (2.82)$$

donde d_0 es una distancia referencia, \log es el logaritmo en base 10 y dB indica que la medida es expresada en decibelios. Esta relación no se cumple en la mayoría de los espacios interiores debido principalmente a las reflexiones y refracciones que ocurren, por lo que la relación se puede

aproximar a:

$$PL(d)_{dB} = PL(d_0)_{dB} + 10 \cdot \beta \cdot \log\left(\frac{d}{d_0}\right) + \varepsilon, \quad (2.83)$$

donde β es un factor que varía en función del ambiente ($\beta = 2$ en espacio libre y $1,6 < \beta < 6$ en ambientes interiores dependiendo de la línea de visión entre emisor y receptor) y ε es una variable aleatoria que también depende del ambiente.

Usualmente los valores de $PL(d_0)_{dB}$, β y la función de densidad de probabilidad de ε (usualmente asumida Gaussiana, Rician o tipo Rayleigh) son obtenidos empíricamente o estimadas de acuerdo a las características del edificio a estudiar. Ésta es una aproximación al modelo de error pero facilita su utilización en otros algoritmos. En [29] se propone la utilización de medidas de RSS de tags RFID activos para evitar la deriva en una estimación PDR con la IMU en el pie.

Una alternativa para evitar aproximar la potencia recibida a (2.83) es comparar el conjunto de medidas RSS recibidas con los datos de calibración usados en fingerprinting. En [112] se utiliza un filtro de rejilla de probabilidades basado en un Hidden Markov Model para estimar la posición de una persona, actualizando las probabilidades de acuerdo a las estimaciones de PDR y corrigiendo de acuerdo a la diferencia entre las medidas recibidas y las medidas esperadas en dicho punto.

La medición del tiempo de vuelo (TOA) esta basada en disponer de 2 dispositivos sincronizados, donde se conoce cuando uno de ellos enviará una señal. Midiendo el tiempo t que tarda la señal en llegar se puede determinar la distancia recorrida d , utilizando la velocidad de la señal en el medio c y la relación $d = c \cdot t$. En el caso de utilizar señales RF es necesaria una sincronización y discretización temporal del orden de 1 nanosegundo para obtener medidas de distancias con una resolución del orden de 30 cm, mientras que con señales ultrasónicas se alcanza la misma precisión con una discretización temporal de 1 ms. En [113] se propone la utilización de tags Chirp Spread Spectrum (CSS), capaces de medir el tiempo de vuelo para acotar una estimación basada en PDR con estimación de la longitud y cambio de ángulo de los pasos.

Otros sistemas asumen que no hay sincronismo, pero utilizan la diferencia con respecto a otra señal recibida, para calcular la diferencia de tiempos de vuelo (TDOA) una medida asociada a la diferencia entre las 2 distancias. Esta medida no necesita una sincronización entre el punto a medir y los puntos conocidos, sino solo sincronismo entre los puntos conocidos al momento de emitir sus señales. El autor en [108] utiliza las diferencias de distancias de un sistema UWB comercial para delimitar el crecimiento del error en una estimación PDR.

Si solo se desea medir la distancia entre dos puntos y no se dispone de sincronización entre ellos, es posible utilizar el tiempo de ida y vuelta (RTT), donde un dispositivo emite una señal y un segundo dispositivo al recibirla espera un retardo fijo t_d y lo envía de nuevo. Si se conoce el retardo se puede calcular el tiempo que tardó la señal en hacer ambos recorridos, por lo que se tendría una estimación de la distancia según $2 \cdot d = c \cdot (t - t_d)$. Utilizando este principio, los autores de [114] miden las distancias entre módulos WiFi, lo que permitiría fusionar esta información con PDR utilizando los puntos de acceso ya instalados.

2.5. Discusión y enmarque de la Tesis

A diferencia del posicionamiento en exteriores usando GNSS, en ambientes interiores, no hay un sistema único que permita obtener la posición de una persona de una manera robusta, continua y estandarizada. En el presente capítulo se han presentado los algoritmos comúnmente utilizados para ello. Cada uno de los métodos estudiados tiene ventajas y desventajas, por lo

que en este trabajo se buscará mejorar los algoritmos utilizados y fusionar la información de múltiples sistemas para obtener un posicionamiento robusto y continuo.

De los métodos estudiados, la navegación inercial con correcciones de velocidad cero ofrece un buen posicionamiento relativo, pero requiere la posición y orientación inicial, además de tener un error de posicionamiento y orientación que crece con la distancia y el tiempo. La utilización del magnetómetro para corregir la orientación podría mejorar la estimación, pero debido a las perturbaciones magnéticas, comunes en ambientes interiores, éste suelen introducir nuevos errores en el posicionamiento que deben ser evitados.

Los sistemas de posicionamiento por balizas permiten tener una posición con un error acotado, pero requieren la instalación de infraestructura y son afectados por la falta de línea de visión.

La presente tesis busca la utilización de sensores inerciales para posicionamiento y su posterior fusión con cualquier información adicional disponible en interiores, por lo que para desarrollar el tema se propone estudiar posibles mejoras a los algoritmos de posicionamiento utilizando sensores inerciales. En particular se han identificado posibles mejoras en las técnicas de detección de pasos, el filtro de estimación utilizado y la utilización de las medidas de campo magnético en ambientes interiores.

El posicionamiento por sensores inerciales requiere de medidas de posiciones absolutas para asociar los desplazamientos a posiciones reales y evitar la deriva de la estimación. Muchas de estas medidas son no lineales y tienen errores no Gaussianos, por lo que la utilización de filtros de Kalman puede generar errores en la estimación. Se propone estudiar métodos para fusionar esta información y poder mejorar las estimaciones. Se estudiaron 2 casos de fusión, el primero se basa en unificar dos estimaciones en el cuerpo de una persona, utilizando la condición de que la distancia entre ellas es limitada. El segundo caso plantea un esquema de fusión con un filtro de partículas, utilizando las estimaciones de desplazamientos de PDR como actualizaciones a las posiciones de las partículas y permitiendo la utilización de cualquier medida en la fase de corrección de los pesos.

Por último se propone estudiar las posibles medidas a aplicar en el esquema de fusión. Para ello se plantean 3 casos de medidas externas. La primera utiliza las mediciones de potencia de la señal y tiempo de vuelo de puntos de acceso WiFi y ZigBee para inicializar y corregir las estimaciones. La segunda utiliza mediciones de diferencias de tiempos de vuelo y ángulos de incidencia de un sistema UWB comercial. El último caso utiliza el plano de los edificios para corregir la trayectoria de las estimaciones de la persona.

2.6. Objetivos específicos de la Tesis

Cada uno de los objetivos planteados se enfocará en mejorar a uno o varios bloques de la estructura del algoritmo PDR presentada en la figura 2.1. Utilizando dicho esquema como base, se plantean los objetivos principales de esta Tesis mostrados en la figura 2.11 y detallados a continuación:

1. Estudio y mejoras en los algoritmos de posicionamiento por sensores inerciales a ser tratado en el capítulo 3.

Objetivo 1.1: Estudiar los métodos de detección de las fases del paso y proponer mejoras a los algoritmos actualmente utilizados. Se enfocará en el bloque de detección de pasos y apoyos

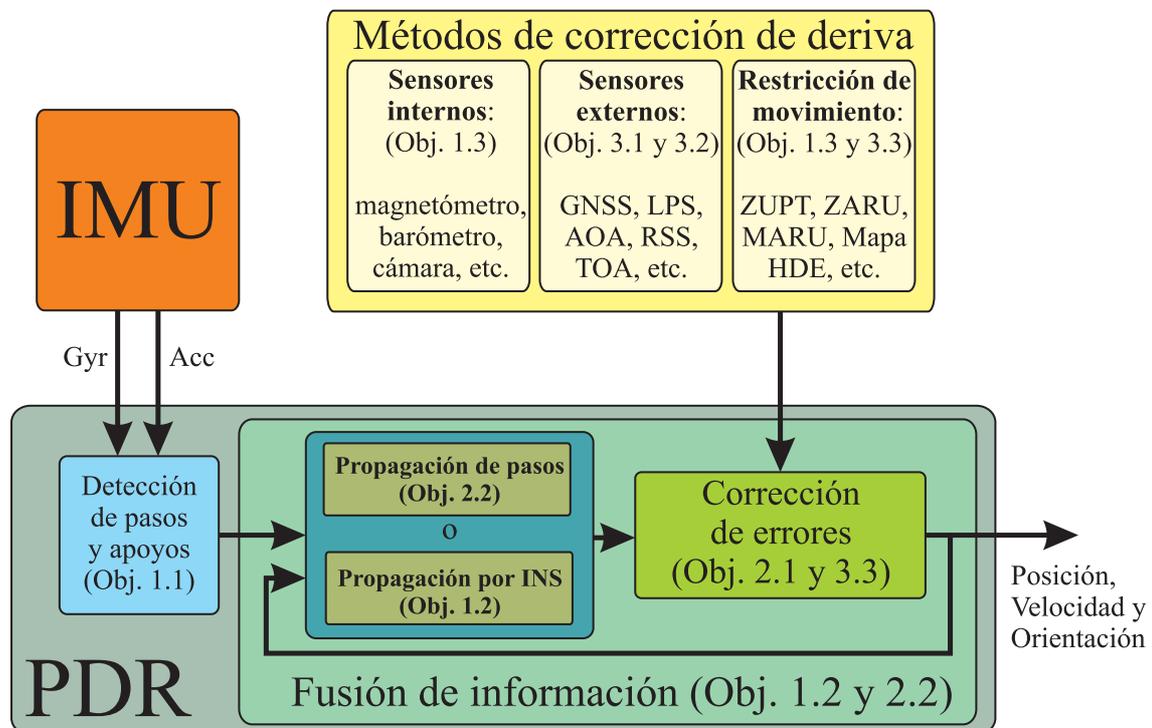


Figura 2.11: Objetivos específicos planteados en cada uno de los bloques del esquema PDR.

Objetivo 1.2: Estudiar el filtro estimador utilizado (EKF) y evaluar la posibilidad de utilizar filtros mejor adaptados a las no linealidades del sistema. Se enfocará en el bloques de fusión de información y propagación por INS.

Objetivo 1.3: Estudiar las medidas de campo magnético en interiores y la posibilidad de ser utilizadas para proveer información de la orientación. Utilizará los sensores internos del dispositivo (el magnetómetro) y las restricciones de movimiento.

2. Estudio de los métodos para corregir la deriva de la estimación por sensores inerciales utilizando medidas externas y el establecimiento de un esquema de fusión basado en la información de PDR. Será tratado en el capítulo 4.

Objetivo 2.1: Estudiar la unificación de múltiples sistemas de posicionamiento mediante la utilización de una relación de distancia máxima entre ellos. Se planteará como un método en el bloque de corrección de errores.

Objetivo 2.2: Fusión de información mediante la utilización de un filtro de partículas con actualizaciones basadas en la información de PDR y correcciones basadas en medidas externa. Propondrá mejoras a los bloques de Fusión de información y propagación de pasos.

3. Inclusión de medidas externas en el algoritmo de posicionamiento basado en filtro de partículas a ser estudiado en el capítulo 5.

Objetivo 3.1: Inclusión de medidas de potencia de la señal y tiempo de vuelo. Mejoras en el bloque de sensores externos.

Objetivo 3.2: Inclusión de medidas de diferencias de tiempos de vuelo y ángulo de incidencia. Mejoras en el bloque de sensores externos.

Objetivo 3.3: Inclusión de la información del mapa en la estimación bajo una estructura de cómputo óptima. Se modificará el bloque de corrección de errores para incluir de manera eficiente medidas del bloque de restricciones de movimiento (mapa).

El presente trabajo se ha podido realizar gracias al apoyo del grupo de investigación LOPSI del Centro de Automática y Robótica (CAR), a las colaboraciones con socios externos (GEINTRA en la Universidad de Alcalá de Henares y WITACA de la Universidad de Valladolid), a los centros receptores en estancias de investigación (German Aerospace Center y Royal Institute of Technology), a la financiación recibida de los proyectos LEMUR y LORIS, y a la beca pre doctoral de la Junta de Ampliación de Estudios (JAE).

Parte II

Desarrollo

Capítulo 3

Mejoras a la localización con PDR

Mejoras a la localización con PDR

En el presente capítulo se estudiarán las posibles mejoras a la técnica de PDR, cuyo esquema generalizado pudo ser observado en las figuras 2.1 y 2.11. En particular nos centraremos en 3 partes del algoritmo de localización propuesto, destacadas con colores azul, verde y amarillo en la figura 3.1:

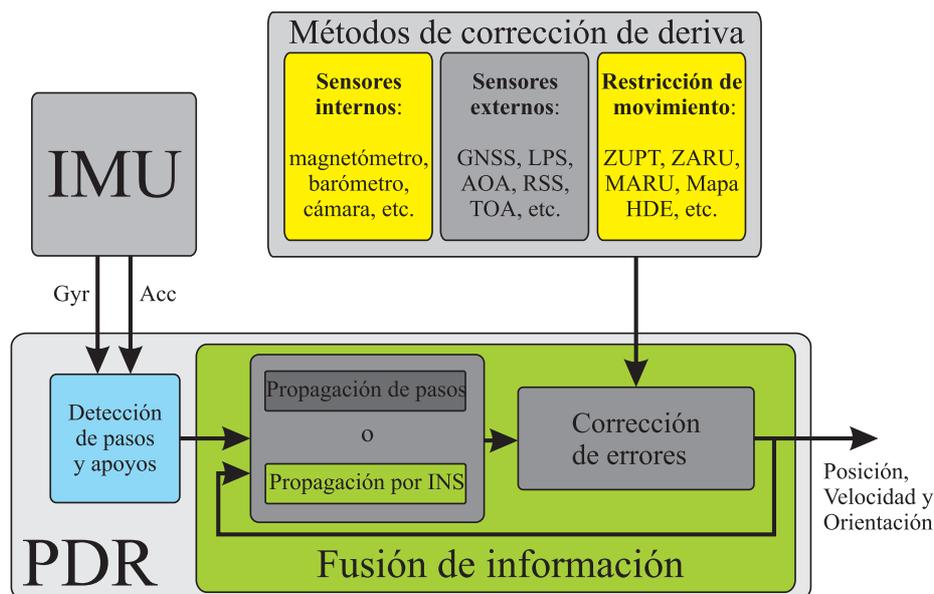


Figura 3.1: Esquema PDR generalizado destacando las aportaciones en el algoritmo.

- **Detección de pasos (azul):** Mejoras en las técnicas de detección de pasos para una IMU en el pie de la persona, observando las señales de la IMU en una ventana de evaluación y midiendo la certeza del apoyo como una medida que permite adaptar las correcciones de errores basadas en velocidad nula.
- **Fusión de información (verde):** Se estudiará el uso del filtro de Kalman Unscented en vez del EKF, debido a su mejor propagación de estados y medidas no lineales.
- **Corrección de la deriva (amarillo):** Limitar la deriva de la orientación mediante la inclusión de medidas de la variación del campo magnético en interiores, método denominado MARU.

Estas modificaciones al algoritmo de PDR fueron resultado de la estancia en el German Aerospace Center bajo la supervisión del Dr. Patrick Robertson y el Dr. Antonio Jiménez (CAR. CSIC-UPM) y fueron presentadas en el Trabajo de Fin de Máster “Localización de personas mediante sensores inerciales usando del filtro de Kalman Unscented” del “Máster Universitario en Sistemas Electrónicos Avanzados. Sistemas Inteligentes“, correspondiente al período formativo del presente doctorado. Adicionalmente fueron presentadas en el congreso Position Location and Navigation Symposium 2012 [28] y se ha solicitado una patente en España (solicitada por el CSIC) y en Alemania (solicitada por el DLR) [115].

3.1. Detección del apoyo

La detección de la fase de apoyo es una de las etapas más importantes de cualquier estimación con PDR, ésta permite detectar y corregir los errores de la estimación INS, pero cualquier error en su detección (por subestimación o sobrestimación de la etapa de apoyo) puede generar fallos significativos en la estimación.

Los detectores de pasos estudiados en la Sección 2.2 utilizan los valores instantáneos o pasados de la aceleración y las velocidades angulares para decidir si el pie se encuentra en la fase de apoyo o no. Utilizar solo el valor instantáneo puede conllevar a posibles falsas detecciones en puntos de velocidad constante que pueden aparecer en el balanceo. Una forma de evitar falsas detecciones es tomar en cuenta los valores cercanos, evaluando una ventana de $2N + 1$ muestras centrada en el punto a evaluar. Esto genera un retardo de N muestras entre las medidas que se reciben de la IMU y el punto a evaluar que será utilizado para actualizar el filtro, pero mediante una serie de estudios se ha observado que utilizando 10 muestras es suficiente y el retardo no es perceptible.

La forma de analizar los datos de la ventana varía con cada autor, pero entre los principales métodos utilizados está la prueba de la tasa de semejanza generalizada de [22] explicada en la Sección 2.2. En el presente trabajo se utiliza una modificación del algoritmo presentado en [18], que obtiene el apoyo instantáneo ($T_i(Acc, Gyr)_{(k)}$) evaluando que los módulos de la aceleración y la velocidad angular se encuentren en los rangos esperados, tal que:

$$T_i(Acc, Gyr)_{(k)} = (\gamma_{lm} < \|Acc_k\| < \gamma_{um}) \& (\|Gyr_k\| < \gamma_{\omega}). \quad (3.1)$$

Por último el algoritmo evalúa si al menos 4 de los 5 valores instantáneos de la ventana indican apoyo. Este algoritmo permite detectar correctamente y evitar falsas detecciones. La figura 3.2 muestra las señales de los módulos de la aceleración y velocidad angular, y los valores de apoyo y apoyo instantáneo estimados utilizando el algoritmo descrito.

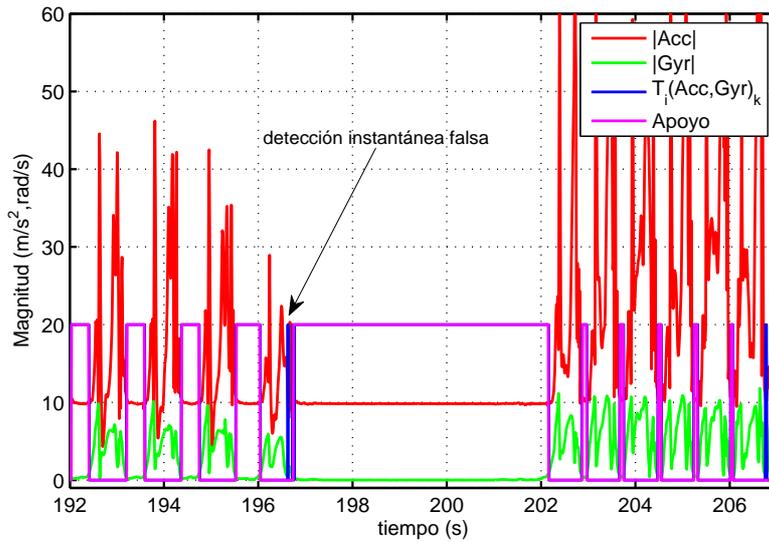


Figura 3.2: Señales de la IMU y su correspondiente detección de apoyo, en un recorrido con caminado, detención y caminado rápido.

3.1.1. Certeza del apoyo

Los métodos comúnmente utilizados solo indican de manera binaria si el pie se encuentra en balanceo o apoyo, pero no todos los pasos y fases del apoyo son igual de estáticos como se puede ver en la figura 3.2. Se ha observado que durante el caminado normal la IMU presenta ligeros movimientos al inicio y fin de la fase de apoyo, adicionalmente en caminado rápido o en superficies deformables (alfombras, jardines, etc.) se acorta la fase de apoyo detectada y el pie presenta ligeros movimientos. Éstos pueden generar alteraciones en las medidas asumidas durante el apoyo por lo que la mayoría de los algoritmos descartan los movimientos eligiendo umbrales de detección que aseguren la condición de apoyo, pero esta estrategia podría no detectar caminados rápidos.

En [22] se observa que estos algoritmos binarios deben ajustar sus umbrales de detección a para cada tipo de caminado, pero en esta tesis buscaremos un algoritmo que sea capaz de detectar todos los tipos de caminado e indique una medida de lo estático que resulta ser el apoyo, para poder ajustar de acuerdo a esto, la ponderación de las medidas de velocidad cero, etc.

Proponemos la generación de una indicación de la certeza que indique cuán real es la condición de apoyo y es lógico asumir que en los bordes de la región temporal de apoyo, será cercana a cero, mientras que en el centro de la región de apoyo tendrá su máximo valor. Una posible alternativa es una señal que crece linealmente desde cero al inicio del apoyo hasta alcanzar su máximo valor en el centro de la región de apoyo y luego decrece linealmente hasta alcanzar cero al final de la región de apoyo. Para generar esa señal, sería necesario conocer toda la region de apoyo antes de poder aplicar ZUPT, por lo que la señal tendría que ser post procesada. Se propone evaluar la señal utilizando el retardo finito de N muestras y la ventana de $2N + 1$ muestras previamente definida. Cuando el número de muestras en apoyo es mayor que el número de muestras en balanceo, obtenemos el número de muestras en apoyo $l(k)$ usando:

$$l(k) = \sum_{j=-N}^N T_i(Acc, Gyr)_{(k+j)}. \quad (3.2)$$

Se puede obtener la función de certeza $T_s(Acc, Gyr)_k$, descrita previamente usando:

$$T_s(Acc, Gyr)_{(k)} = \max \left(\sum_{j=-N'(k)}^{N'(k)} (2 \cdot T_i(Acc, Gyr)_{(k+j)} - 1), 0 \right), \quad (3.3)$$

donde $N'(k)$ puede ser obtenido usando $2 \cdot N'(k) + 1 = l(k)$.

Si el retardo utilizado es muy grande pueden solaparse las detecciones de regiones en apoyo, por lo que utilizaremos un valor de $N = 10$ muestras (que a una tasa de muestreo de 100 muestras/s corresponde a 100 ms). Este algoritmo permite generar a partir de la señal de apoyo instantáneo $T_i(Acc, Gyr)_{(k)}$ (línea azul), una señal gradual que indica la certeza de la medida $T_s(Acc, Gyr)_{(k)}$ (línea roja) y que trata de aproximar una señal de certeza ideal propuesta $T_p(Acc, Gyr)_{(k)}$ (línea verde que inicia en 0 al comienzo del apoyo con una pendiente constante hasta el punto medio y luego decrece con la misma pendiente hasta el fin del apoyo), como puede ser observado en la figura 3.3.

La señal de certeza permite indicar la calidad de la condición de apoyo, mejor en el centro del apoyo y peor al inicio y fin. Si la persona camina rápidamente, se generaran apoyos cortos que producirán una señal de certeza con un pico más bajo que indicará la menor fidelidad de las medidas aplicadas en el apoyo. Hemos observado que modificar la varianza de las actualizaciones

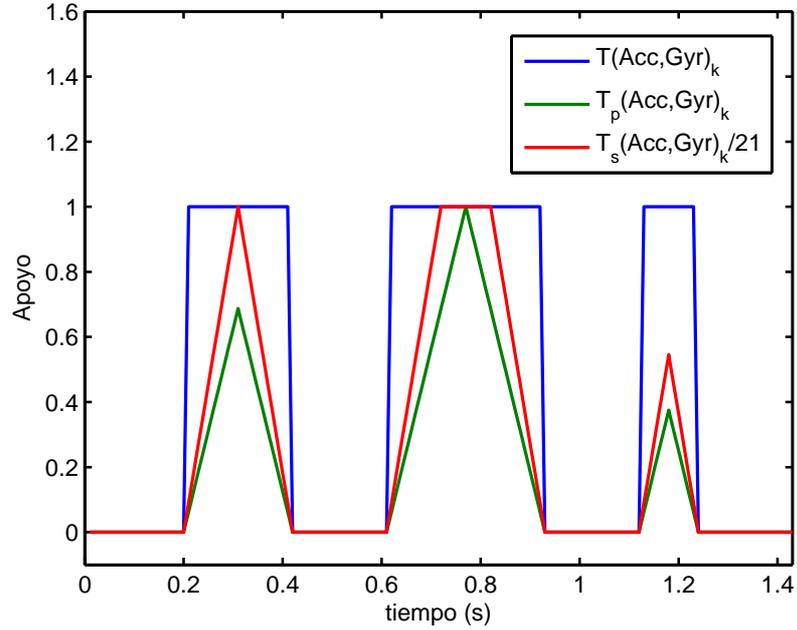


Figura 3.3: Señal de apoyo original ($T(Acc,Gyr)_{(k)}$), señal de certeza ideal propuesta ($T_p(Acc,Gyr)_{(k)}$, requiere postprocesamiento) y señal de certeza con retardo de 10 muestras ($T_s(Acc,Gyr)_{(k)}$), escalada para que tenga un valor máximo de 1.

de velocidad nula (ZUPT) no afecta significativamente la estimación, pero como indicaremos en la Sección 3.3, ésta ayuda a mejorar la utilización del MARU.

3.1.2. Pruebas con señales reales

Para probar el algoritmo de detección de pasos propuesto se utilizaron las señales de prueba propuestas en [116] correspondientes a caminados variados (caminado rápido, lento, detención, etc.). Para comparar los algoritmos se seleccionaron 3 segmentos de la señal donde se aprecia un caminado lento, un caminado lento y luego una detención, y un caminado rápido, aplicando el detector $T_i(Acc,Gyr)_{(k)}$ definido en (3.1) y midiendo la certeza con $T_s(Acc,Gyr)_{(k)}$ definido en (3.3).

Se puede apreciar en la figura 3.4 que la señal de certeza evita las falsas detecciones de apoyos y genera un cambio gradual entre fases. Durante el caminado rápido, las señales de apoyos son menos fiables ya que hay más movimiento durante el apoyo, esto se puede apreciar al observar el valor máximo que alcanza la certeza en cada apoyo.

3.2. Uso del filtro de Kalman Unscented

El EKF es el filtro utilizado en la mayoría de los sistemas de estimación, principalmente por su simplicidad y facilidad de implementación. Sin embargo, en la propagación del INS, los errores de orientación y los bias del giróscopo presentan relaciones no lineales y distribuciones no Gaussianas que podrían alterar la estimación. Se propone como una alternativa, la utilización del filtro de Kalman Unscented UKF (o “sigma-point”), que aproxima mejor los comportamientos

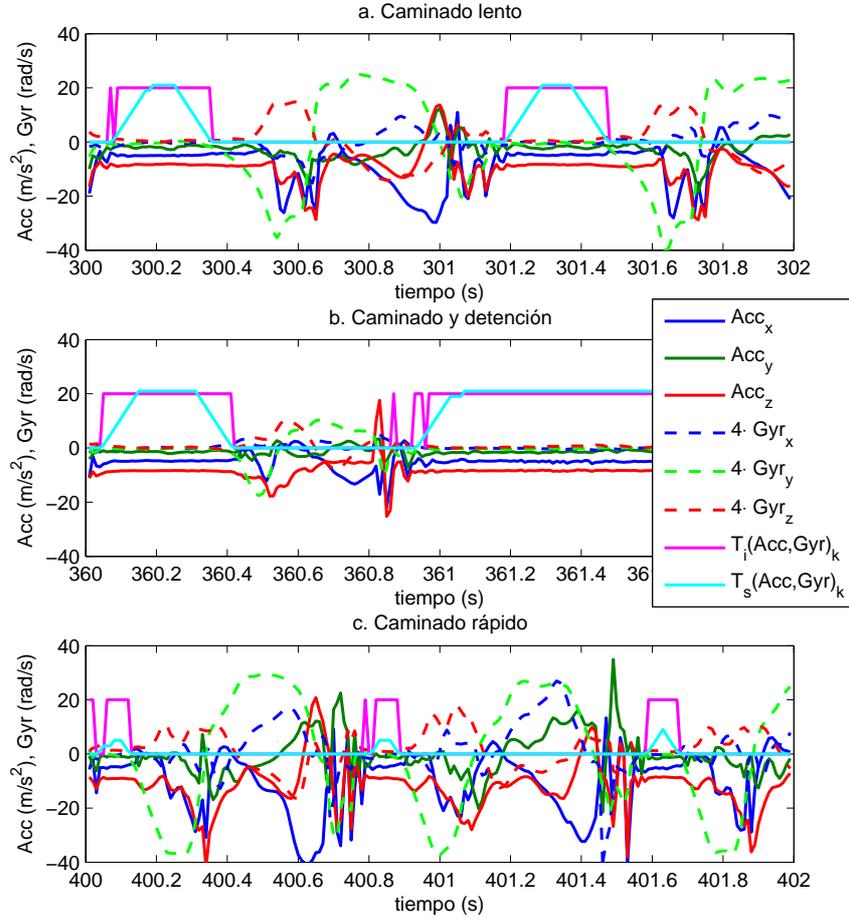


Figura 3.4: Señales para la detección de la fase de apoyo utilizando un algoritmo basado en los módulos de la aceleración y velocidades angulares y su correspondiente señal de la certeza del paso.

no lineales y distribuciones no Gaussianas, mediante la utilización de puntos de evaluación (o puntos sigma) alrededor de la media estimada.

El UKF es capaz de manejar estados no lineales con un menor error que el EKF, por lo que proponemos la utilización de los siguientes estados simplificados:

- Orientación de la IMU con respecto al plano de navegación inercial, expresado como el alabeo (roll), cabeceo (pitch) y guiñada (yaw). $\Psi = [\phi \quad \theta \quad \psi]^T$
- El bias del giróscopo. $\Delta\omega = [\Delta\omega_x \quad \Delta\omega_y \quad \Delta\omega_z]^T$
- La posición de la IMU en el sistema de referencia de navegación inercial. $\mathbf{r} = [r_x \quad r_y \quad r_z]^T$
- La velocidad de la IMU en el sistema de referencia de navegación inercial. $\dot{\mathbf{r}} = [\dot{r}_x \quad \dot{r}_y \quad \dot{r}_z]^T$
- El bias del acelerómetro. $\Delta\mathbf{a} = [\Delta a_x \quad \Delta a_y \quad \Delta a_z]^T$

El vector de estados será

$$\mathbf{X} = [\phi \quad \theta \quad \psi \quad \Delta\omega_x \quad \Delta\omega_y \quad \Delta\omega_z \quad r_x \quad r_y \quad r_z \quad \dot{r}_x \quad \dot{r}_y \quad \dot{r}_z \quad \Delta a_x \quad \Delta a_y \quad \Delta a_z]^T. \quad (3.4)$$

Debido a la representación en ángulos utilizada, es posible que el sistema genere errores al acercarse a los ángulos de “Gimbal Lock” (cabeceo cercano a $\pi/2$ o $-\pi/2$). Para eliminar este problema se propone utilizar una rotación previa $C_{b_0}^b$ del sistema de referencia original del sensor (b_0) al nuevo sistema de de referencia del sensor (b), de modo que cuando se encuentre en apoyo, la gravedad sea paralela al eje Z . De esta manera podremos asumir que el rango de ángulos de cabeceo estará centrado y no se acercará a los ángulos de “Gimbal Lock”. Por facilidad elegiremos el eje X de este sistema de referencia, en dirección a la proyección del eje X original en el plano horizontal. La rotación puede ser obtenida como:

$$C_{b_0}^b = \left[\begin{array}{c} \left[\begin{array}{c} 1 \\ \mathbf{g}^{b_0 \times} \times \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} \end{array} \right] \\ \left[\begin{array}{c} 1 \\ \mathbf{g}^{b_0 \times} \times \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} \end{array} \right] \end{array} \right] \times \frac{\mathbf{g}^{b_0}}{\|\mathbf{g}^{b_0}\|} \left[\begin{array}{c} \left[\begin{array}{c} 1 \\ \mathbf{g}^{b_0 \times} \times \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} \end{array} \right] \\ \left[\begin{array}{c} 1 \\ \mathbf{g}^{b_0 \times} \times \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} \end{array} \right] \end{array} \right] \frac{\mathbf{g}^{b_0}}{\|\mathbf{g}^{b_0}\|}, \quad (3.5)$$

donde \mathbf{g}^{b_0} es la gravedad medida en el sistema de referencia original del sensor.

3.2.1. Etapas del filtro UKF

Para implementar la propagación Unscented y su corrección de acuerdo a actualizaciones de velocidad nula (ZUPT), se propone el esquema de la figura 3.5. Cuando se detecta que el pie está en apoyo, se implementa la corrección, pero si el pie está en balanceo, se utiliza solamente la transformación Unscented para propagar la estimación.

Para propagar los puntos sigma se utilizará la función asociada al INS, tal que:

$$\mathbf{X}_{k,i}^* = f_{\text{INS}}(\mathbf{X}_{k-1,i}, \text{Acc}(k), \text{Gyr}(k)), \quad (3.6)$$

donde i indica el punto sigma utilizado, k la muestra temporal y la matrix de orientación de cada propagación es obtenida de cada grupo de ángulos $\Psi_{k-1,i} = [\phi_{k-1,i} \quad \theta_{k-1,i} \quad \psi_{k-1,i}]^T$. Posteriormente se propaga de acuerdo a las medidas del giróscopo, eliminando el bias $\Delta \mathbf{a}_{k-1,i}$ y usando (2.61). De las matrices de orientación se obtienen los nuevos valores de $\Psi_{k,i}^*$. Los bias del giróscopo y del acelerómetro se asumen constantes, y se calcula la velocidad y posición de acuerdo a (2.2) y (2.3) respectivamente.

Debido a que los ángulos utilizados son periódicos, éstos (principalmente la guiñada) pueden presentar cambios drásticos al acercarse a $\pm\pi$. Para evitar estos saltos se elige el ángulo periódico más cercano al valor medio anterior, en el caso de la guiñada propagada ($\psi_{k,i}^*$):

$$\psi_{k,i}^* = \psi_{k,i}^* - 2\pi \cdot \text{round} \left(\frac{\psi_{k,i}^* - \psi(k-1)}{2\pi} \right). \quad (3.7)$$

Por último se calcula la media y la covarianza de las distribuciones, y en el caso de que el pie este en la fase de balanceo, éstos serán los valores corregidos a utilizar en la próxima propagación.

Si se detecta que el pie se encuentra en apoyo se puede aplicar una corrección de velocidad cero (ZUPT), donde la estimación de la observación Y_i^{ZUPT} será:

$$\mathbf{Y}_i^{\text{ZUPT}} = [\dot{r}_{x,i} \quad \dot{r}_{y,i} \quad \dot{r}_{z,i}]^T, \quad (3.8)$$

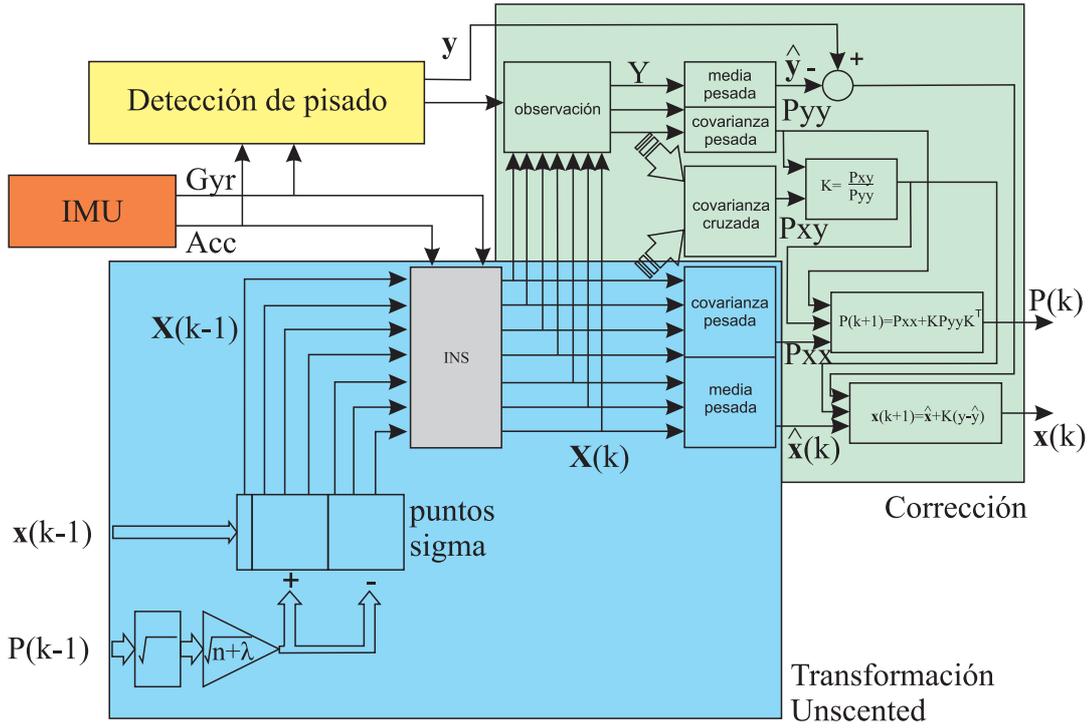


Figura 3.5: Esquema del algoritmo de PDR utilizando un UKF.

y la medida \mathbf{y}^{ZUPT} será:

$$\mathbf{y}^{\text{ZUPT}} = [0 \ 0 \ 0]^T. \quad (3.9)$$

Otra medida muy común son las actualizaciones de velocidad angular nula (ZARU) [3], y su estimación de la observación Y_i^{ZARU} es:

$$\mathbf{Y}_i^{\text{ZARU}} = [\Delta\omega_{x,i} \ \Delta\omega_{y,i} \ \Delta\omega_{z,i}]^T, \quad (3.10)$$

y la medida \mathbf{y}^{ZARU} será:

$$\mathbf{y}^{\text{ZARU}} = \text{Gyr}. \quad (3.11)$$

Cualquier otra medida que se desee utilizar puede ser agregada en los vectores anteriores, pero en esta sección solo se utilizará el ZUPT.

Con la estimación de la observación, la medida y los estados propagados se puede calcular la media y covarianza de la medida, además de la covarianza cruzada, necesarias para el cálculo de la constante de Kalman y la corrección de los estados.

3.2.2. Diferencias entre el EKF y el UKF

Para evaluar las diferencias entre la estimación obtenida utilizando el UKF y el EKF se utilizarán las señales sintéticas propuestas en [19], a las que les agregará ruido obtenido de una IMU estática (con bias nulo). Se propone estudiar la capacidad de estimación del bias agregando un bias constante conocido a la señal, y los errores de posición y orientación utilizando un análisis de Monte Carlo. Por último se compararán los tiempos de cómputo necesarios para la ejecución de ambos algoritmos.

3.2.2.1. Estimación del bias en el giróscopo y el acelerómetro

Debido a que el UKF toma en cuenta los efectos de segundo orden y mayores, es capaz de obtener más información del ZUPT y ZARU, que el EKF usualmente utilizado en PDR. Para probar esto, proponemos evaluar la capacidad de los filtros de estimar correctamente el bias en el acelerómetro y el giróscopo utilizando una señal sintética de un recorrido cerrado de aproximadamente 1000 m, agregando un ruido y bias conocido.

La figura 3.6 muestra la evolución de las estimaciones de los bias con ambos métodos. Se observa que el UKF estima mejor los errores en el giróscopo, mientras que ninguno de los métodos es capaz de estimar correctamente el bias del acelerómetro debido a que esta medida está acoplada al error de orientación. Sin embargo la estimación del UKF tiende a los valores reales del bias, mientras que la estimación del EKF diverge en algunos casos. Para la correcta estimación del bias del acelerómetro es necesaria más información asociada a la orientación como por ejemplo la utilización de magnetómetros.

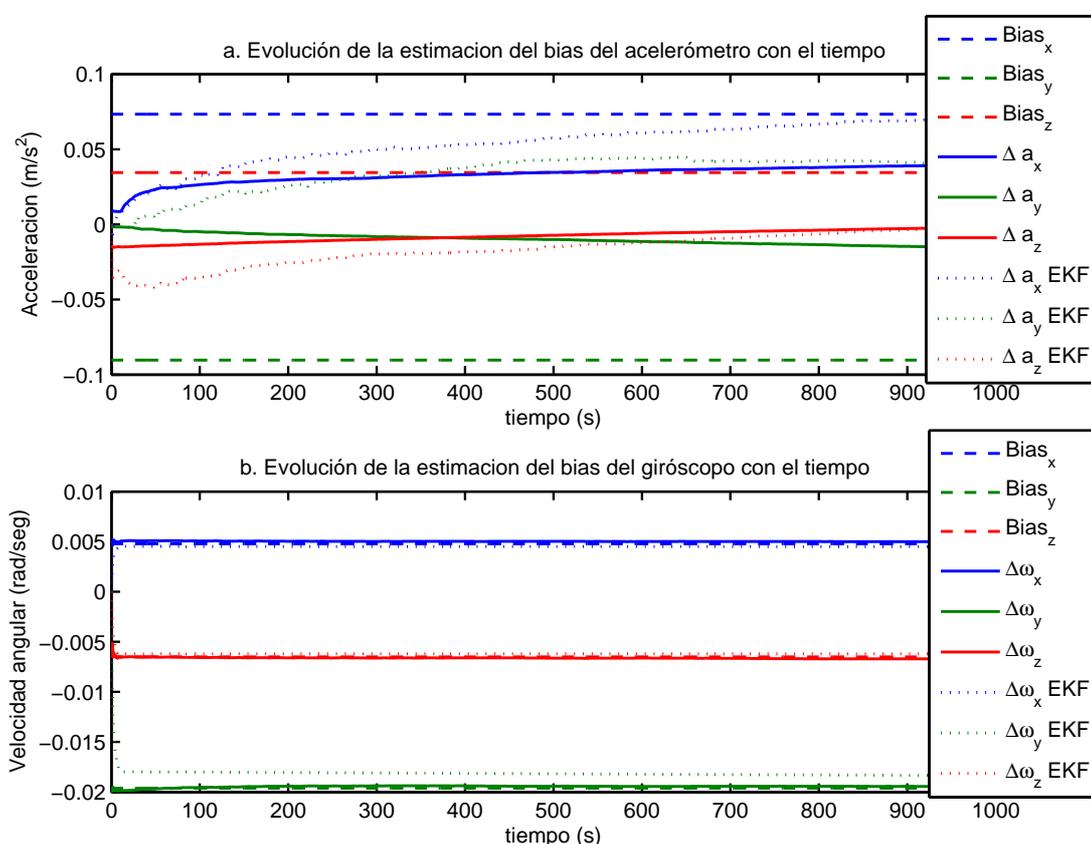


Figura 3.6: Evolución de las estimaciones del bias del acelerómetro (a) y el giróscopo (b) utilizando un EKF y un UKF con medidas de ZUPT y ZARU.

3.2.2.2. Estimación de la posición y orientación

Para comparar las capacidades de posicionamiento de ambos filtros se propone hacer un análisis de Monte Carlo del error cuadrático medio obtenido en posición y orientación. La señal sintética sin ruido utilizada realiza una trayectoria cerrada con curvas suaves de 80 pasos por

vuelta, 10 veces. En ambos casos los filtros, así como la integración directa por INS, estiman correctamente la posición con la señal sin ruido.

En el análisis de Monte Carlo se realizaran 1000 simulaciones utilizando cada filtro. En cada una de las simulaciones se agrega el ruido característico de la IMU (MTi de XSens) y un bias constante durante toda la simulación, que será elegido aleatoriamente al inicio de cada experimento (es elegido de acuerdo a distribuciones Gaussianas de media 0, y $\sigma_a = 0,04 \text{ m/s}^2$ en cada eje del acelerómetro y $\sigma_\omega = 0,015 \text{ rad/seg}$ en cada eje del giróscopo).

La figuras 3.7 y 3.8 muestran la evolución de las distribuciones de estimaciones de la guiñada para el EKF y el UKF respectivamente. Se puede observar que ambas distribuciones presentan evoluciones de las desviaciones estándar algo diferentes y el error en el UKF es ligeramente menor (el UKF tiene una dispersión 25 % menor que el EKF), posiblemente debido a un mejor ajuste del sistema.

Para observar el crecimiento de los errores de posicionamiento y orientación con respecto a las referencias de la señal sintética (superíndice *gt* del inglés ground-truth), se utilizará el error cuadrático medio de la posición $e_r(k)$, definido como:

$$e_r(k) = \sqrt{\frac{1}{N} \cdot \left(\sum_{i=1}^N ((r_{x,i}(k) - r_x^{gt}(k))^2 + (r_{y,i}(k) - r_y^{gt}(k))^2 + (r_{z,i}(k) - r_z^{gt}(k))^2) \right)} \quad (3.12)$$

y el error cuadrático medio de la guiñada $e_\psi(k)$, definido como:

$$e_\psi(k) = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (\psi_i(k) - \psi^{gt}(k))^2}, \quad (3.13)$$

donde N es el número total de simulaciones (en este caso $N = 1000$).

En la figura 3.9 se puede observar el crecimiento de los errores cuadráticos medios cuando se utiliza un EKF y un UKF, ambos de 9 estados (sin estimación de los bias del giróscopo ni el acelerómetro) y de 15 estados (estados previamente descritos). Solo se muestra el error en el punto central del apoyo para disminuir la cantidad de puntos a evaluar y evitar mostrar los errores durante el balanceo.

Se puede observar que ambos filtros tienen un comportamiento similar, pero debido a que el UKF de 15 estados es capaz de estimar con mayor precisión el bias del giróscopo, éste tiene una mejor estimación de la orientación que se traduce en un mejor posicionamiento. La versión de 9 estados del UKF no estima los bias del giróscopo, por lo que el crecimiento de sus errores cuadráticos medios es similar a los EKF.

El UKF ofrece un mejor posicionamiento que la versión en el EKF, pero todavía sufre de la pérdida de la orientación debido a los ruidos y bias no observable en el giróscopo, por lo que se propondrá (en la Sección 3.3) el estudio de los campos magnéticos en ambientes interiores para proveer información de la guiñada. A continuación se analizará la sobrecarga computacional que supone el uso de un UKF frente a un EKF para PDR.

3.2.3. Tiempos de ejecución

El filtro UKF permite una mejor estimación de los estados y maneja mejor las medidas no lineales que podrían presentarse, pero tiene la desventaja de que requiere la propagación de un mayor número de puntos de estimación (el UKF de 15 estados evalúa 31 puntos, mientras que el

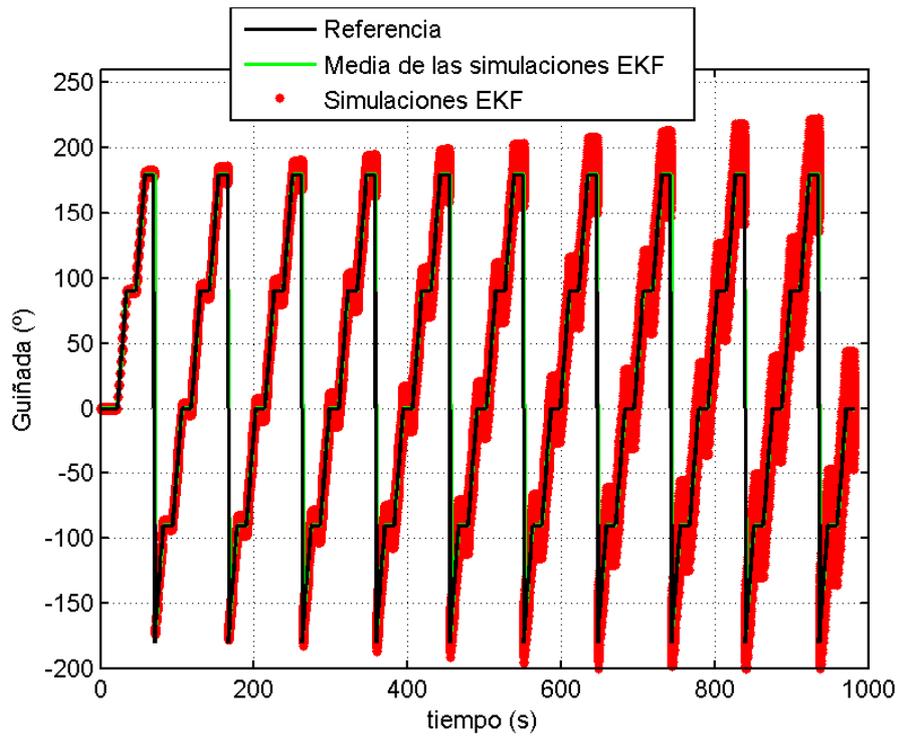


Figura 3.7: Evolución de la guiñada para múltiples experimentos utilizando PDR en un EKF con ZUPT.

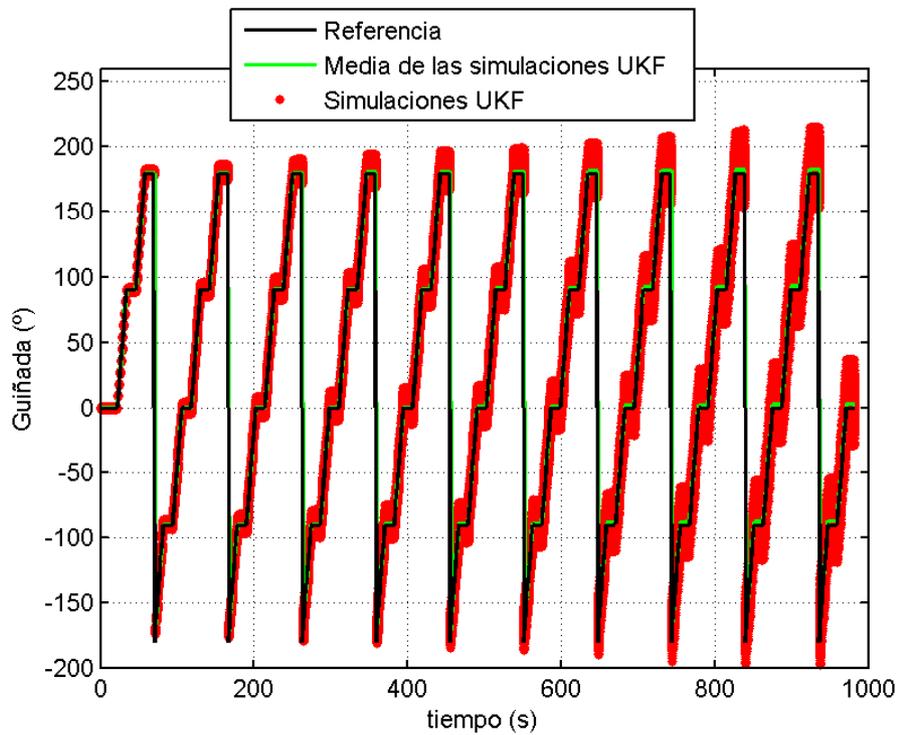


Figura 3.8: Evolución de la guiñada para múltiples experimentos utilizando PDR en un UKF con ZUPT.

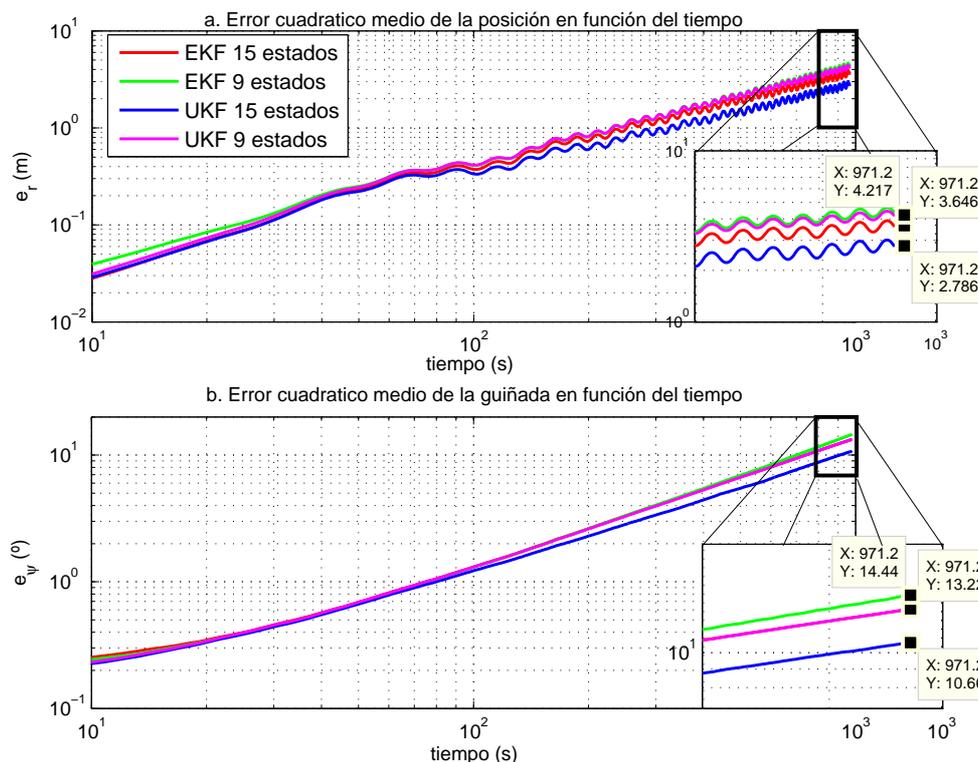


Figura 3.9: Evolución de los errores cuadráticos medios de la posición y la guiñada con respecto al tiempo para métodos PDR utilizando un EKF y un UKF.

UKF de 9 estados evalúa 19 puntos). Para evaluar esta desventaja estudiaremos el tiempo que requiere cada algoritmo en procesar diferentes señales.

Las pruebas fueron realizadas en un ordenador con un procesador Intel Core2 de 2,83 GHz (solo se usó un núcleo del procesador para las pruebas), 4 GB de RAM, en MATLAB R2010b bajo Windows 7 de 64 bits. Las señales utilizadas son:

- **Prueba A:** prueba 14 de las señales propuestas en [116], correspondiente a una IMU en el pie de una persona caminando durante 280,61 segundos, muestreada a 100 Hz.
- **Prueba B:** Señales medidas en el sistema propuesto en [116], de una IMU en el pie de una persona realizando movimientos variados (caminado rápido lento, trote, etc.) durante 657,04 segundos, muestreada a 100 Hz.
- **Prueba C:** Señal sintética de [19] correspondiente a 10 vueltas de una trayectoria cerrada de 80 pasos, duración 981,60 segundos, muestreada a 100 Hz.

En la tabla 3.1 se puede observar que el UKF es entre 6 y 8 veces más lento que el EKF, esto es debido a que el UKF debe propagar una mayor cantidad de puntos que la versión extendida del filtro. Adicionalmente podemos observar que como es esperado la versión del 15 estados del UKF es más lenta que la versión de 9 estados, pues aunque la estructura de los filtros es la misma, el primero propaga 31 puntos y el segundo 19. En el caso del EKF ambos filtros tienen aproximadamente la misma velocidad, se puede observar que la versión de 15 estados es ligeramente más rápida, pero esto se debe a que la versión utilizada está optimizada para usar 15 estados.

Filtro utilizado	Prueba A 280,61 s	Prueba B 657,04 s	Prueba C 981,60 s
EKF 15 estados	7,33 s	17,12 s	26,27 s
EKF 9 estados	7,45 s	17,78 s	26,52 s
UKF 15 estados	57,50 s	137,47 s	210,50 s
UKF 9 estados	42,57 s	101,22 s	160,69 s

Tabla 3.1: Tiempos de ejecución para los diferentes métodos utilizados.

El filtro UKF es más lento que el EKF pero permite una mejor estimación de los bias del giróscopo como ya se observó en la sección 3.2.2.1 y se adapta mejor a la utilización de medidas no lineales como las medidas magnéticas que se proponen en la sección 3.3 a continuación.

3.3. Uso del campo magnético en ambientes interiores

La principal fuente de error en las estimaciones utilizando PDR es la deriva de la guiñada debido al bias no observable en el giróscopo. En exteriores, se puede utilizar un magnetómetro para medir el campo magnético de la tierra y corregir esta deriva, pero en ambientes interiores, el campo magnético suele tener perturbaciones que pueden producir derivas aun mayores en las estimaciones.

Los autores en [18] proponen utilizar la guiñada obtenida del campo magnético cuando no se detectan grandes desviaciones con respecto a la orientación del giróscopo. Este método puede ser útil en exteriores o en edificios simples con pocas perturbaciones. La mejora obtenida en la estimación puede ser observada en la figura 3.10.a donde la utilización de las mediciones del campo magnético corrige los errores de orientación de giróscopo. En edificios grandes donde el campo magnético presenta errores significativos como el de la figura 3.10.b, la utilización de la guiñada magnética introduce errores no Gaussianos en la estimación que generan errores aun mayores en la posición, por lo que se desaconseja su utilización.

En la presente sección se propondrán técnicas para utilizar los campos magnéticos en interiores para mejorar la estimación de PDR, aun en presencia de perturbaciones magnéticas.

3.3.1. Características del campo magnético en interiores

El campo magnético de la tierra cambia de acuerdo a la posición en la que nos encontremos sobre el globo terráqueo. Utilizando un modelo del campo magnético como el “World Magnetic Model” es posible estimar su intensidad, declinación e inclinación para cualquier punto de la tierra. Estos valores son aproximadamente constantes en una misma ciudad, por lo que para posicionamiento en interiores se puede asumir que el campo magnético originado por la tierra es constante en toda la region de estudio. Sin embargo en interiores, las estructuras metálicas de los edificios alteran los campos magnéticos, por lo que muchos autores desaconsejan su uso para navegación inercial.

Para mejorar la estimación de la posición en PDR es necesario obtener algún tipo de información de la orientación. En [28] se observa que durante el apoyo en caminado normal, el pie presenta pequeños giros debidos a los movimientos de la cadera y el tobillo, por lo que no se puede aplicar con garantías una actualización de velocidad angular cero (ZARU) al igual que se hace con la velocidad al aplicar ZUPT.

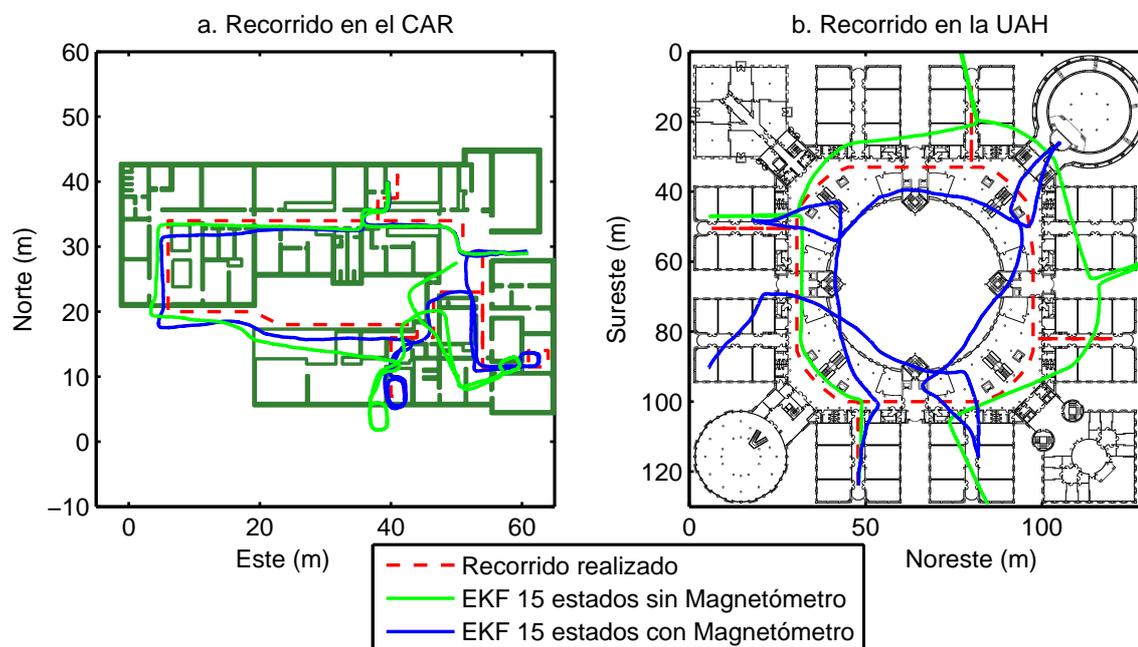


Figura 3.10: Estimaciones de la posición utilizando EKF con y sin Magnetómetro. a. Pruebas realizadas en el Centro de Automática y Robótica (CAR). b. Pruebas realizadas en la Universidad de Alcalá de Henares (UAH).

En la mayoría de los casos las estructuras metálicas que alteran el campo magnético en ambientes interiores son objetos fijos (maquinaria, equipos, barras y vigas metálicas de la estructura del edificio, etc.) y generan perturbaciones en los campos magnéticos que dependerán de la posición de la persona, por lo que no se pueden corregir fácilmente.

Sin embargo las perturbaciones magnéticas observadas durante la fase de apoyo son aproximadamente constantes ya que la IMU no se desplaza, por lo que éstas pueden ser utilizadas para observar el cambio en la orientación de la IMU, más no su orientación absoluta. Bajo esta premisa se propone asociar las variaciones en las mediciones del campo magnético a las variaciones en la orientación de la IMU.

3.3.2. Rotaciones del campo magnético

Debido a que el campo magnético puede tener perturbaciones magnéticas, la orientación magnética no puede ser utilizada directamente para extraer información de la guiñada. Sin embargo, si se asume que dichas perturbaciones permanecerán constantes, las rotaciones de la IMU tendrán un efecto observable en la variación del campo magnético medido en el sensor. El efecto de la rotación de la IMU sobre el campo magnético medido puede ser observado en la figure 3.11 y el uso como medida en un filtro de Kalman se conoce como “Magnetic Angular Rate Update” (MARU) de [28] y patentado en [117]

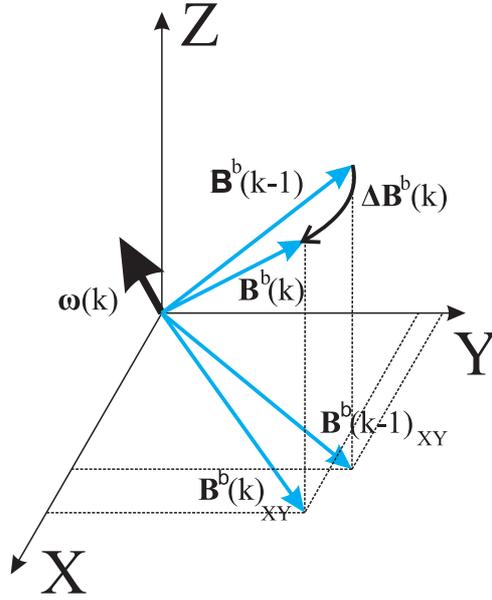


Figura 3.11: Cambio en el vector de campo magnético del sensor debido a una rotación, con respecto al sistema de referencia del sensor.

Para modelar este comportamiento se define el cambio en el campo magnético en el sensor $\Delta \mathbf{B}^b(k)$ como:

$$\Delta \mathbf{B}^b(k) = \mathbf{B}^b(k) - \mathbf{B}^b(k-1), \quad (3.14)$$

donde utilizando las rotaciones entre los sistemas de referencia de navegación inercial y del sensor, $\mathbf{B}^b(k) = C_b^n(k)^T \cdot \mathbf{B}^n(k)$, tenemos:

$$\Delta \mathbf{B}^b(k) = C_b^n(k)^T \cdot \mathbf{B}^n(k) - C_b^n(k-1)^T \cdot \mathbf{B}^n(k-1). \quad (3.15)$$

Al sustituir la propagación de la matriz de orientación de (2.4), tenemos:

$$\begin{aligned} \Delta \mathbf{B}^b(k) &= (C_b^n(k-1) \cdot e^{\Omega_{nb}^b(k) \cdot \Delta t})^T \cdot \mathbf{B}^n(k) - C_b^n(k-1)^T \cdot \mathbf{B}^n(k-1) \\ &= e^{-\Omega_{nb}^b(k) \cdot \Delta t} \cdot C_b^n(k-1)^T \cdot \mathbf{B}^n(k) - C_b^n(k-1)^T \cdot \mathbf{B}^n(k-1). \end{aligned} \quad (3.16)$$

El campo magnético en el instante k es $\mathbf{B}^n(k) = \mathbf{B}^n(k-1) + \varepsilon_B$, donde ε_B es el cambio en la perturbación magnética en el plano de navegación inercial. Si la IMU se encuentra en la fase de apoyo, la perturbación magnética producto de las estructuras metálicas y campos externos fijos será constante, debido a que son campos dependientes de la posición, por lo tanto su efecto en la variación será nula. Sólo campos cambiantes rápidamente podrían modificar esta condición, pero fijando el límite establecido por la medida de las velocidades angulares, se puede asumir que ε_B es producto del ruido de la medida. Sustituyendo $\mathbf{B}^n(k)$ en (3.16), tenemos:

$$\Delta \mathbf{B}^b(k) = e^{-\Omega_{nb}^b(k) \cdot \Delta t} \cdot C_b^n(k-1)^T \cdot (\mathbf{B}^n(k-1) + \varepsilon_B) - C_b^n(k-1)^T \cdot \mathbf{B}^n(k-1) \quad (3.17)$$

$$= (e^{-\Omega_{nb}^b(k) \cdot \Delta t} - I) \cdot C_b^n(k-1)^T \cdot \mathbf{B}^n(k-1) + e^{-\Omega_{nb}^b(k) \cdot \Delta t} \cdot C_b^n(k-1)^T \cdot \varepsilon_B$$

$$\Delta \mathbf{B}^b(k) = (e^{-\Omega_{nb}^b(k) \cdot \Delta t} - I) \cdot \mathbf{B}^b(k-1) + C_b^n(k)^T \cdot \varepsilon_B. \quad (3.18)$$

Si se re escribe $e^{-\Omega_{nb}^b(k) \cdot \Delta t}$ siguiendo la representación propuesta en (2.7), se obtiene:

$$\Delta \mathbf{B}^b(k) = \left(-\frac{\sin(\|\boldsymbol{\omega}(k)\Delta T\|)}{\|\boldsymbol{\omega}(k)\|} \Omega_{nb}^b(k) + \frac{(1 - \cos(\|\boldsymbol{\omega}(k)\Delta T\|))}{\|\boldsymbol{\omega}(k)\|^2} \Omega_{nb}^b(k)^2 \right) \cdot \mathbf{B}^b(k-1) + C_b^n(k)^T \cdot \varepsilon_B. \quad (3.19)$$

donde $\boldsymbol{\omega}(k)$ son las velocidades angulares al eliminar los bias, $\boldsymbol{\omega}(k) = \text{Gyr}(k) - \boldsymbol{\Delta}\boldsymbol{\omega}(k)$.

Para usar el MARU se deben descartar los cambios instantáneos de las perturbaciones magnéticas (objetos metálicos que se muevan cerca del sensor, campos inducidos momentáneos, etc.) por lo que se establece que el cambio del campo magnético no debe ser mayor que el arco que se formaría si la rotación fuese perpendicular a los 2 vectores de campo magnético, en este caso utilizando el límite establecido por la ecuación 2.10, el máximo valor para el módulo del cambio de campo magnético en el sensor, será:

$$\gamma_B = \sqrt{\gamma_\omega} \cdot \Delta t \cdot B^b(k-1). \quad (3.20)$$

La condición de para utilizar el MARU está basada en la detección de la fase de apoyo usando (2.12) y el límite de cambio en el campo magnético:

$$T_{\text{MARU}}(\text{Acc}, \text{Gyr}, \text{Mag})_{(k)} = T_{mc}(\text{Acc}, \text{Gyr})_{(k)} \& (\|\Delta B^b(k)\| < \gamma_B). \quad (3.21)$$

La covarianza de la medida proviene del ruido del Magnetómetro (aproximadamente $20 \cdot 10^{-6}$ en cada eje) y ya que utilizamos la diferencia de las medidas obtenidas será el doble de la covarianza de una medida, entonces: $R_{rm} = 40 \cdot 10^{-6} \cdot I_{3 \times 3}$

Como se puede observar en (3.19), la variación del campo magnético en el sistema de referencia del sensor tiene una relación no lineal con las velocidades angulares y los bias del giróscopo, por lo que se pueden plantear dos opciones para implementar el uso de la medida en el filtro, utilizar las ecuaciones directamente en un UKF o linealizar la relación para poder ser utilizado en un EKF. A continuación planteamos ambas alternativas.

3.3.2.1. Rotación magnética en un UKF

Para implementar el MARU en un UKF es necesario definir la medida \mathbf{y}^{MARU} :

$$\mathbf{y}^{\text{MARU}} = \mathbf{B}^b(k) - \mathbf{B}^b(k-1), \quad (3.22)$$

y la función de observación $\mathbf{Y}_i^{\text{MARU}} = h(\mathbf{X}_{k,i})$, para el punto i , es:

$$\mathbf{Y}_i^{\text{MARU}} = \left(-\frac{\sin(\|\boldsymbol{\omega}_i(k)\Delta T\|)}{\|\boldsymbol{\omega}_i(k)\|} \Omega_{nb}^b(k) + \frac{(1 - \cos(\|\boldsymbol{\omega}_i(k)\Delta T\|))}{\|\boldsymbol{\omega}_i(k)\|^2} \Omega_{nb}^b(k)^2 \right) \cdot \mathbf{B}^b(k-1), \quad (3.23)$$

$$\boldsymbol{\omega}_i(k) = \text{Gyr}(k) - \boldsymbol{\Delta}\boldsymbol{\omega}_{k,i} \quad (3.24)$$

El UKF permite la utilización de las funciones de observación no lineales necesarias para la implementación de la medida del MARU, sin la necesidad de linealización y permiten extraer más información de dicha medida (efectos de segundo y mayor orden).

3.3.2.2. Rotación magnética linealizada en un EKF

El EKF es el filtro más utilizado para estimación y fusión de información pero requiere aproximar el sistema a un comportamiento lineal utilizando linealizaciones de las ecuaciones de propagación de estados y de la función de observación. Para implementar el MARU en un EKF es necesario linealizar la función de observación de (3.18), utilizando la aproximación de primer orden de $e^{-\Omega_{nb}^b(k) \cdot \Delta t}$:

$$\begin{aligned} e^{-\Omega_{nb}^b(k) \cdot \Delta t} &= I - \Omega_{nb}^b(k) \cdot \Delta t \\ &= I - [\boldsymbol{\omega}(k)\Delta t \quad \times]. \end{aligned} \quad (3.25)$$

Esta aproximación corresponde al vector rojo de la figura 3.12, vector tangente a la rotación del campo magnético.

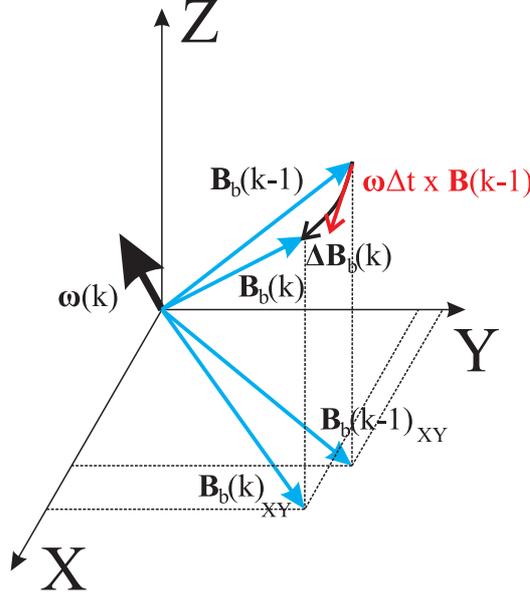


Figura 3.12: Cambio en el vector de campo magnético del sensor debido a una rotación observada en el sistema de referencia del sensor. En rojo la linealización del incremento.

Introduciendo la aproximación en la observación (3.18):

$$\Delta \mathbf{B}^b(k) = -[\boldsymbol{\omega}(k)\Delta t \quad \times] \cdot \mathbf{B}^b(k-1) + C_b^n(k)^T \cdot \boldsymbol{\varepsilon}_B. \quad (3.26)$$

Al agregar el efecto del bias del giróscopo ($\boldsymbol{\omega}(k) = \text{Gyr}(k) - \Delta \boldsymbol{\omega}(k)$) en la ecuación anterior:

$$\begin{aligned} \Delta \mathbf{B}^b(k) &= -[(\text{Gyr}(k) - \Delta \boldsymbol{\omega}(k))\Delta t \quad \times] \cdot \mathbf{B}^b(k-1) + C_b^n(k)^T \cdot \boldsymbol{\varepsilon}_B \\ &= -[\text{Gyr}(k)\Delta t \quad \times] \cdot \mathbf{B}^b(k-1) + [\Delta \boldsymbol{\omega}(k)\Delta t \quad \times] \cdot \mathbf{B}^b(k-1) + C_b^n(k)^T \cdot \boldsymbol{\varepsilon}_B. \end{aligned} \quad (3.27)$$

Para expresar la medida lineal con respecto al estado $\Delta \boldsymbol{\omega}(k)$ se reordena la ecuación como:

$$\Delta \mathbf{B}^b(k) + [\text{Gyr}(k)\Delta t \quad \times] \cdot \mathbf{B}^b(k-1) = [-\mathbf{B}^b(k-1)\Delta t \quad \times] \cdot \Delta \boldsymbol{\omega}(k) + C_b^n(k)^T \cdot \boldsymbol{\varepsilon}_B. \quad (3.28)$$

La medida $\mathbf{m}^{MARU}(k)$ y la matriz de observación $H^{MARU}(k)$ son definidas como:

$$\mathbf{m}^{MARU}(k) = \Delta \mathbf{B}^b(k) + [\text{Gyr}(k)\Delta t \quad \times] \cdot \mathbf{B}^b(k-1) \quad (3.29)$$

$$H^{MARU}(k) = \begin{bmatrix} 0_{3 \times 3} & [-\mathbf{B}^b(k-1)\Delta t \quad \times] & 0_{3 \times 3} & 0_{3 \times 3} & 0_{3 \times 3} \end{bmatrix}. \quad (3.30)$$

Para la detección de la medida se puede usar la misma condición de la medida no lineal de la rotación magnética en un UKF (ecuación 3.21) al igual que la covarianza de la medida. Esta última implementación coincide con la propuesta por Afzal [27] aunque deducida de una manera distinta y en ambos casos solo es válida para un filtro EKF.

3.3.3. Influencia de las perturbaciones magnéticas en la estimación

Para observar el efecto de las perturbaciones magnéticas sobre las estimaciones de PDR con magnetómetro se propone utilizar las señales sintéticas de [19] y agregar perturbaciones magnéticas dependientes de la posición, mediante dipolos magnéticos simulados. El campo de la perturbación en el sistema de referencia de navegación inercial será:

$$\mathbf{B}_{d,i}^n(\mathbf{r}) = \frac{\mu_0}{4\pi} \cdot \left(\frac{3(\mathbf{r} - \mathbf{r}_i)(\mathbf{m}_i \cdot (\mathbf{r} - \mathbf{r}_i))}{\|\mathbf{r} - \mathbf{r}_i\|^5} - \frac{\mathbf{m}_i}{\|\mathbf{r} - \mathbf{r}_i\|^3} \right), \quad (3.31)$$

donde \mathbf{m}_i y \mathbf{r}_i son el momento dipolar y la posición respectivamente del dipolo i .

En el experimento se agregan 2 dipolos, el primero con $\mathbf{m}_0 = [0,8 \ 0 \ 0]^T \cdot (4\pi/\mu_0)A \cdot m^2$ y $\mathbf{r}_0 = [10 \ -1 \ 0]^T m$ y el segundo con $\mathbf{m}_1 = [-0,8 \ 0 \ 0]^T \cdot (4\pi/\mu_0)A \cdot m^2$ y $\mathbf{r}_1 = [0 \ 26 \ 0,1]^T m$. Luego de agregar las perturbaciones se determina el campo magnético en el sensor como:

$$\mathbf{B}^b(k) = C_b^n(k)^T \cdot (\mathbf{B}_{d,1}^n(\mathbf{r}(k)) + \mathbf{B}_{d,2}^n(\mathbf{r}(k)) + \mathbf{B}_e^n), \quad (3.32)$$

donde B_e^n es el campo magnético de la tierra en el sistema de referencia de navegación inercial.

Las señales fueron utilizadas sin ruido añadido de modo que se pueda comprobar el correcto funcionamiento de los filtros y fueron comparados con el método propuesto en [18] basado en un EKF y utilizando el magnetómetro como un compass magnético.

En la figura 3.13 se observa que los métodos propuestos son capaces de reconstruir la posición sin error a diferencia del método del compass magnético (línea roja, EKF compass) que genera una deriva creciente en la posición, aunque mantiene la orientación cuando no hay perturbaciones magnéticas.

Para evaluar el efecto de los métodos estudiados se propone utilizar un experimento de Monte Carlo como el presentado en la Sección 3.2.2.2, pero incluyendo la perturbación magnética de la figura 3.13 y ruido en el magnetómetro.

La figura 3.14 muestra la evolución del error cuadrático medio para los métodos estudiados, Se observa que el método EKF compass (línea azul oscuro) a pesar de tener un error de orientación acotado presenta un error creciente en la posición que en el caso estudiado, genera peores resultados de posicionamiento que el método EKF original (línea roja).

Al introducir el método MARU linealizado en la estimación con EKF (línea azul clara) la estimación es iniciada con un nivel de error ligeramente mayor (debido a la influencia del ruido del magnetómetro) pero rápidamente converge al nivel del EKF y posteriormente genera niveles de error ligeramente inferiores al EKF original. Se espera que este efecto sea mayor a medida que se recorra una mayor distancia.

La mayor mejora es observada al introducir el método MARU en el UKF (línea magenta), lo que permite que, al estimar el bias del giróscopo, el error de la orientación crezca con una menor pendiente y por ende también el error de posición.

Al probar la introducción de las medidas suaves en la señal sintética no se observó mejoría debido a que en éstas, el apoyo es ideal y no presenta movimientos ni desplazamientos durante los instantes de apoyo que puedan afectar la estimación.

3.3.4. Pruebas con señales reales

Para probar el funcionamiento del algoritmo se realizó un recorrido de dos vueltas alrededor del edificio A del CAR. La figura 3.15 muestra las diferentes estimaciones obtenidas en las que se puede observar que al utilizar el filtro UKF se logra mejorar la estimación.

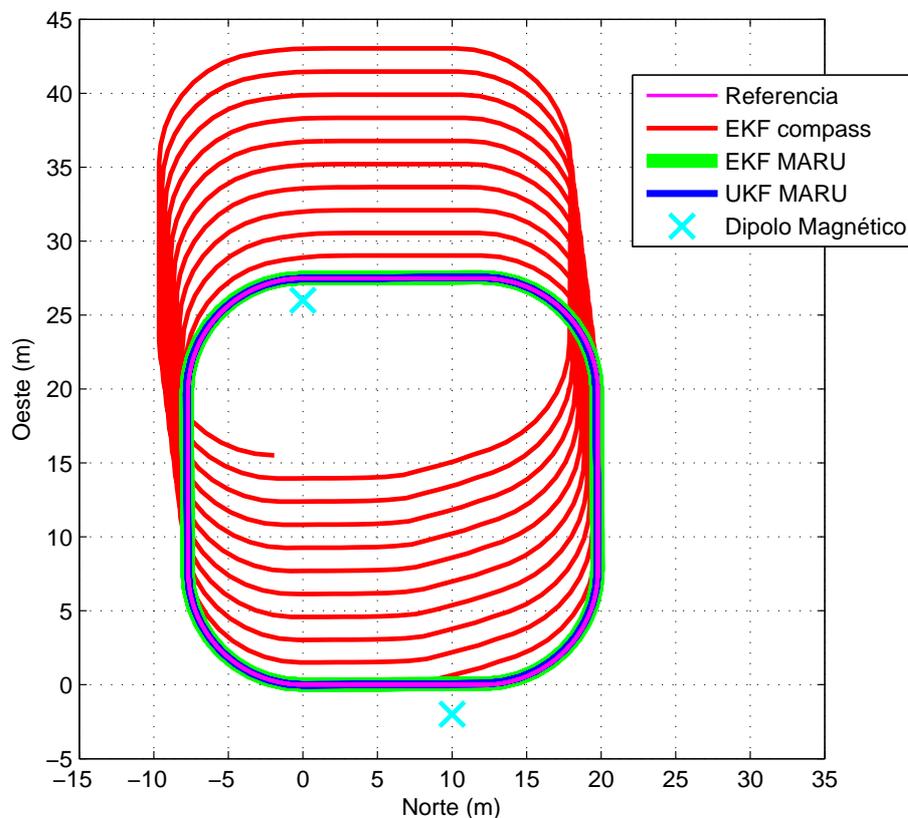


Figura 3.13: Trayectorias reconstruidas a partir de una señal sintética ideal (Acc, Gyr y Mag) con perturbaciones magnéticas generadas en base a los dipolos marcados con una “x” en azul claro.

Al utilizar el MARU, la estimación desmejora ligeramente debido a los movimientos durante las fases de apoyo, pero al cambiar la covarianza de la medida de acuerdo a la certeza del apoyo (medidas suaves) es posible mejorar la estimación. Cabe destacar que al utilizar las medias suaves, el filtro es capaz de extraer más información de las rotaciones durante las fases centrales del apoyo, lo que le permite estimar más rápidamente el bias del giróscopo y minimizar las derivas en la orientación y posición.

3.3.5. Tiempos de ejecución

Siguiendo el esquema de la sección 3.2.3 se estudiaron los tiempos requeridos para el cómputo de la posición utilizando el MARU en un EKF y un UKF. Las señales utilizadas son las mismas, exceptuando que en el caso de la señal sintética (Prueba C) se agregaron las perturbaciones por dipolos magnéticos.

Los tiempos de ejecución de la tabla 3.2 muestran el efecto de agregar cada una de las medidas propuestas a la estimación. Como es de esperarse, cada una de las medidas utilizadas incrementa el tiempo de cómputo necesario para estimar la posición de la persona, sin embargo en todos los casos podrían ejecutarse a tiempo real en ese ordenador. Si se desea ejecutar el algoritmo en sistemas embebidos o teléfonos inteligentes sería necesario escribir el algoritmo en

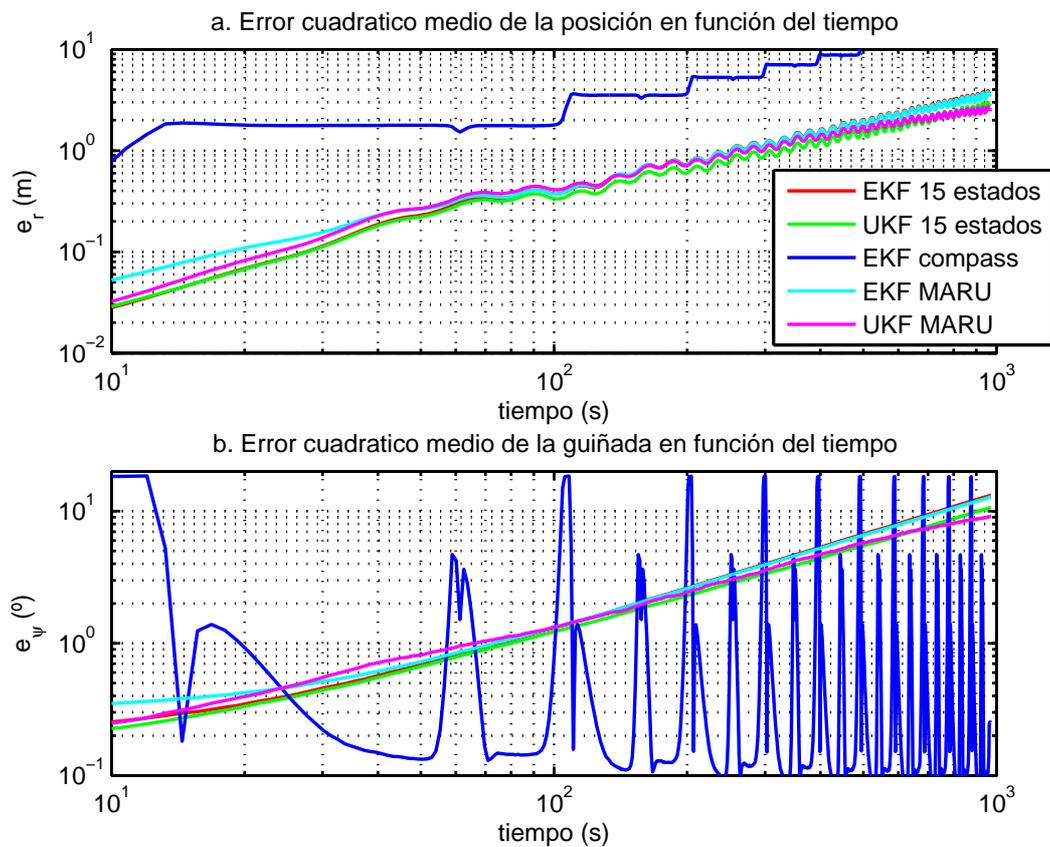


Figura 3.14: Análisis de la evolución del error cuadrático medio de la posición (a) y la orientación en el plano horizontal (b) para el EKF y UKF de 15 estados y diferentes implementaciones de MARU, utilizando una señal sintética.

Filtro utilizado	Prueba A 280,61 s	Prueba B 657,04 s	Prueba C 981,60 s
EKF 15 estados	7,33 s	17,12 s	26,27 s
EKF 15 estados y MARU	7,93 s	18,61 s	27,58 s
EKF 15 estados y MARU suave	7,87 s	18,63 s	27,87 s
UKF 15 estados	57,50 s	137,47 s	210,50 s
UKF 15 estados y MARU	62,19 s	144,92 s	224,56 s
UKF 15 estados y MARU suave	62,69 s	146,63 s	223,94 s

Tabla 3.2: Tiempos de ejecución para los diferentes métodos utilizados con y sin MARU.

lenguajes de programación como Java o C++, lo que permitiría disminuir aún más su tiempo de ejecución.

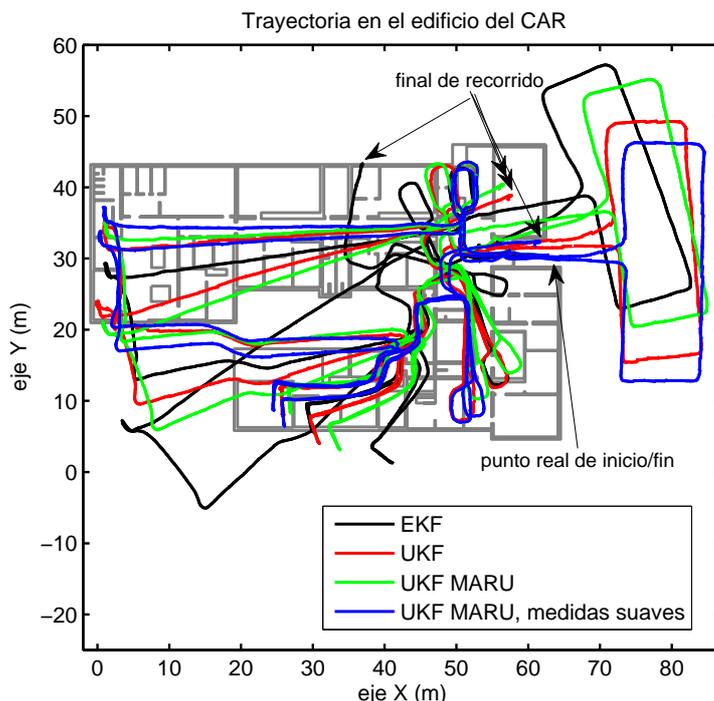


Figura 3.15: Estimación de la posición en el edificio A del CAR utilizando el método EKF original y los algoritmos propuestos de UKF, MARU y medidas suaves.

3.4. Conclusiones

En el presente capítulo se propusieron y mejoraron diferentes aspectos de algoritmos generales en la literatura de posicionamiento en ambientes interiores basado en sensores inerciales. En particular se mejoró el algoritmo de detección de pasos, se propuso cambiar el filtro de fusión de información a uno basado en el filtro de Kalman Unscented, y se desarrolló una medida de las rotaciones angulares durante la IMU durante el apoyo basada en los cambios en el campo magnético observado en la IMU.

El algoritmo de detección de pasos propuesto evalúa ventanas temporales de medidas inerciales lo que le permite decidir de una manera más robusta la ocurrencia de las fases de apoyo. Adicionalmente, mide la certeza de la fase de apoyo generando un cambio gradual entre las fases de balanceo y apoyo. Observando los puntos de máxima certeza es posible conocer los puntos de mínimo movimiento y por ende es posible variar la certeza (covarianza) de medidas heurísticas asociadas al apoyo como el MARU.

La utilización del filtro de Kalman Unscented para la fusión de información permite una mejor propagación de los errores del sistema, así como un mejor manejo de las características no lineales de la navegación inercial. Debido a esto, el UKF es capaz de utilizar medidas menos lineales y extraer una mayor cantidad de información de cada medida, todo ello a tiempo real.

Utilizando la variación del campo magnético observado por los movimientos de la IMU durante el apoyo, se pueden medir las rotaciones de ésta. Esta medida permite disminuir la deriva en la posición y orientación, y mejorar la estimación. Debido a la no linealidad de la medida, necesita ser implementada en un UKF o linealizada para un EKF, presentando mejores resultados en la primera opción debido a su mejor manejo de los efectos de segundo y mayor orden.

La utilización de la variación o rotación del campo magnético como medida permite disminuir el orden de crecimiento del error de orientación, pasando de un error que crece linealmente con el tiempo a uno que crece con la raíz del tiempo (random walk). La disminución del error de orientación se traduce también en un decremento del error de posición, ya que el último depende de la integración del primero.

Capítulo 4

Esquema de fusión de información

Esquema de fusión de información

Como se pudo constatar en el capítulo 3, la utilización del PDR, aun con información del magnetómetro y la posición/orientación inicial, no es capaz de proveer la posición de la persona con un error acotado. Esto es debido a que el algoritmo está basado en la integración de desplazamientos, lo que conlleva un error que crece con el tiempo.

La solución natural a este problema es la utilización de información asociada a la posición absoluta de la persona. Entre las medidas más comunes está la utilización de GNSS, pero debido a que en ambientes interiores la señal de la mayoría de los satélites no tiene línea de vista, no será considerado en este trabajo. Dentro de edificios, es común encontrar múltiples señales RF que estudiadas adecuadamente pueden proveer información de la posición de la persona. Adicionalmente es posible la utilización del mapa del edificio para estimar la posición basados en los desplazamientos obtenidos de PDR, una técnica conocida como Map Matching.

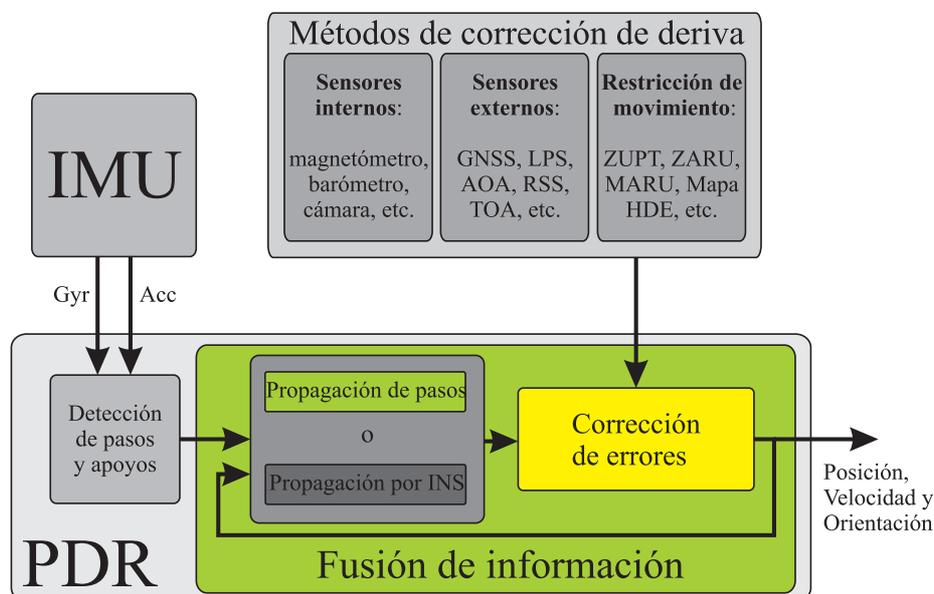


Figura 4.1: Esquema PDR generalizado destacando las aportaciones en fusión de información.

Sin embargo estas y muchas otras medidas tienen fuertes componentes no lineales ni Gaussianas (especialmente cuando queremos hacer emparejamiento con mapas del entorno, map matching) y en la mayoría de los casos no se conoce la posición inicial, por lo que la utilización de filtros de Kalman (Extendidos o Unscented) no es recomendada ya que tiene limitaciones para representar múltiples hipótesis. En el presente capítulo se estudiarán y propondrán mejoras a los algoritmos de fusión de información del esquema de cómputo presentado en las figuras 2.1 y 2.11. Sobre dicho esquema se tratarán los bloques destacados en color amarillo y verde de la figura 4.1 y se proponen las siguientes mejoras:

- Corrección de errores entre múltiples estimaciones de posición con rangos limitados (amarillo):** Se propone un algoritmo para fusionar varias estimaciones paralelas de posición sobre la ubicación de una persona, pero donde los sensores portables se colocan

en lugares distintos, estableciendo un máximo en la distancia entre ellas.

- **Fusión de información por estimación de pasos (verde):** Se proponen modificaciones al esquema de fusión para utilizar un modelo a dos niveles que estima las posiciones y orientaciones mediante un filtro de partículas propagado con las estimaciones de PDR. Se propone un modelo adaptativo del error de los pasos, se evalúa su cota inferior de Cramér Rao y se propone un modelado del bias de la velocidad angular.

4.1. Fusión de estimaciones con una distancia máxima entre ellas

Si una persona dispone de múltiples sensores en el cuerpo (IMU en el pie, teléfono inteligente con mediciones WiFi e IMU, sistema de medición de potencia de balizas RFID, sistema de posicionamiento por UWB, etc), cada uno de esos sensores es capaz de proveer una estimación de la posición de diferentes puntos del cuerpo. En la presente sección se buscará mejorar las estimaciones fusionando la información de todos los sistemas disponibles. En particular, este trabajo se enfocará en fusionar la información de PDR de una IMU en el pie y medidas de posición absoluta de sistemas UWB como el RTLS de Ubisense [109].

Para fusionar la información de varias estimaciones unificando los sistemas bajo un esquema EKF o UKF es necesario conocer la posición relativa entre ellos, pero debido a los movimientos del cuerpo esta no puede ser fácilmente estimada. Otra posibilidad es asumir que ambos puntos están en la misma posición, esto podría hacer inestable el INS si las medidas absolutas son muy precisas como en el caso del RTLS de Ubisense. Se propone utilizar un filtro de límites (Constraint filter [118–120]) que establezca un máximo en la función de densidad de probabilidad (pdf) de la distancia entre ambas estimaciones.

4.1.1. Constraint filter

El filtro de Kalman es una excelente herramienta para agregar información en la estimación de estados, pero cuando las relaciones son no lineales, éste genera errores en las estimaciones o no es capaz de utilizarlas. Entre las relaciones no manejables por los filtros de Kalman (EKF o UKF) se encuentran las desigualdades [120] que limitan los valores de las pdf. Estas desigualdades pueden ser utilizadas para establecer que dos estimaciones de la posición (PDR en el pie y posición del tag UWB) en una persona tendrán un límite en la distancia entre ellos, lo que limitará el crecimiento del error del PDR y mejorará la estimación del tag UWB. El Constraint filter se propondrá como una medida adicional del EKF en la que se modificará la media y la covarianza de un conjunto de estados conjuntos.

Se asumen dos estimaciones de la posición, $\mathbf{X}^1 = [\mathbf{r}^1; \mathbf{X}_o^1]$ y $\mathbf{X}^2 = [\mathbf{r}^2; \mathbf{X}_o^2]$, donde $\mathbf{r}^{(i)}$ es la posición, $\mathbf{X}_o^{(i)}$ son los otros m_i estados del sistema de navegación inercial de la i -ésima estimación de la posición (en este caso i vale 1 o 2, ya que son dos posiciones a calcular) y la notación $[a; b]$ denota la concatenación $\begin{bmatrix} a \\ b \end{bmatrix}$. En el problema no se conoce la posición relativa entre los puntos $\Delta\mathbf{X} = \mathbf{X}^1 - \mathbf{X}^2$, solo se sabe la distancia máxima entre ellos. En [118–120] proponen tratar límites asociados a los estados conjuntos $\mathbf{X} = [\mathbf{X}^1; \mathbf{X}^2]$ como una desigualdad:

$$\|L \cdot \mathbf{X}\| \leq \gamma. \quad (4.1)$$

Si se elige L tal que $L \cdot \mathbf{X} = \mathbf{r}^1 - \mathbf{r}^2 = \Delta r$, es posible limitar la longitud de la distancia relativa a una esfera de radio γ . Si se desea establecer límites diferentes en cada eje es posible implementar

un borde elipsoidal como:

$$L \cdot \mathbf{X} = \begin{bmatrix} (r_x^1 - r_x^2)/d_x \\ (r_y^1 - r_y^2)/d_y \\ (r_z^1 - r_z^2)/d_z \end{bmatrix}, \quad (4.2)$$

donde d_e es el límite de la elipsoide en el eje $e = \{x, y, z\}$.

En [120], el autor propone varios métodos para obtener la media y covarianza de las distribuciones de estos estados conjuntos limitados por (4.2) de los que se tratará la proyección y el truncado de las pdf. Posteriormente se propone una aproximación para calcular la media y la covarianza de los estados.

4.1.1.1. Proyección de la estimación

El autor en [120] propone tratar el problema como una “proyección de la estimación” para distribuciones Gaussianas, donde la media $\tilde{\mathbf{X}}^+$ es obtenida como el valor que minimiza la distancia a los estados luego de truncar sus pdf. Esta proyección puede ser representada como:

$$\tilde{\mathbf{X}}^+ = \arg_{\hat{\mathbf{X}}^+} \min (\mathbf{X} - \hat{\mathbf{X}}^+)^T \cdot W_c \cdot (\mathbf{X} - \hat{\mathbf{X}}^+), \quad (4.3)$$

donde los estados conjuntos \mathbf{X} cumplen la condición (4.1) y W_c es un factor de pesado.

Si W_c coincide con la inversa de la covarianza estimada $W_c = (\hat{P})^{-1}$, la proyección coincidirá con el punto de máxima probabilidad de la estimación entre aquellos que cumplen el límite propuesto, mientras que si se usa la identidad se obtendrá el punto más próximo a la media previamente estimada. En [121] el autor propone obtener la proyección sobre la distribución con el límite cuadrático $(L \cdot \mathbf{X})^T \cdot (L \cdot \mathbf{X}) \leq \gamma^2$ utilizando un método de búsqueda iterativo. En [119] se propone obtener la covarianza de la proyección usando el gradiente de la operación de proyección ∇_p , tal que:

$$\tilde{P}^+ = \nabla_p \cdot P^+ \cdot \nabla_p^T. \quad (4.4)$$

Este método propaga la distribución utilizando el punto de máxima probabilidad (no la media) y debido a que ∇_p es singular se pierden componentes de la covarianza de la estimación.

4.1.2. Truncado de la función de densidad de probabilidad

Una forma alternativa de implementar los límites es propuesta en [122] donde truncando las pdf en 1 dimension pueden obtenerse las nuevas medias y covarianzas de las distribuciones. En el caso a estudiar se desea implementar un límite esférico en 3 dimensiones, el cual no puede ser obtenido teóricamente como en el caso de utilizar solo 1 dimension, por lo que se propone estudiar el problema del truncado de las pdf en más de 1 dimension.

Si se asume que la pdf estimada $p(\mathbf{X})$ es Gaussiana ($\mathbf{X} \sim \mathcal{N}(\hat{\mathbf{X}}, P)$), la pdf de los estados truncados será $p(\mathbf{X}_c) = p(\mathbf{X}|C)$ (en este caso C es la desigualdad $\|L \cdot \mathbf{X}\| \leq \gamma$), tal que:

$$\begin{aligned} p(\mathbf{X}_c) &= \frac{p(C|\mathbf{X}) \cdot p(\mathbf{X})}{\int p(C|\mathbf{X}) \cdot p(\mathbf{X}) d\mathbf{x}} \\ &= \begin{cases} \frac{p(\mathbf{X})}{\alpha} & \text{si } \|L \cdot \mathbf{X}\| \leq \gamma, \\ 0 & \text{otros casos} \end{cases} \end{aligned} \quad (4.5)$$

donde α es:

$$\alpha = \int p(C|\mathbf{X}) \cdot p(\mathbf{X}) d\mathbf{x} = \int_{\mathbf{X}_c^*} p(\mathbf{X}) d\mathbf{x} \quad (4.6)$$

y

$$\mathbf{X}_c^* = \{\mathbf{X} \in \mathfrak{R}^n : \|L \cdot \mathbf{X}\| \leq \gamma\} \quad (4.7)$$

La media $\hat{\mathbf{X}}_c$ y la covarianza P_c pueden ser obtenidas como:

$$\hat{\mathbf{X}}_c = \int_{\mathbf{X}_c^*} \mathbf{X}_c \cdot p(\mathbf{X}_c) d\mathbf{x}_c \quad (4.8)$$

$$P_c = \int_{\mathbf{X}_c^*} (\mathbf{X}_c - \hat{\mathbf{X}}_c) \cdot (\mathbf{X}_c - \hat{\mathbf{X}}_c)^T \cdot p(\mathbf{X}_c) d\mathbf{x}_c \quad (4.9)$$

4.1.2.1. Cálculo de las integrales

Para poder calcular la media y covarianza previamente propuestas es necesario obtener 3 integrales (4.6, 4.8 y 4.9) que solo pueden ser deducidas si \mathbf{X} es unidimensional. Para el caso estudiado es necesario calcular la integral, por lo que se propone utilizar una rejilla de N puntos uniformemente distribuidos alrededor del área acotada ($\mathbf{X}_i \in \mathbf{X}_c^*$), donde se define un intervalo de integración $d\mathbf{x}_c \approx \Delta\mathbf{X}_i$ y si se asume que la probabilidad $p(\mathbf{X})$ es Gaussiana, se pueden obtener las probabilidades de los puntos estudiados $p(\mathbf{X}_i)$. El valor de α puede ser calculado como:

$$\alpha = \sum_{i=1}^N p(\mathbf{X}_i) \Delta\mathbf{X}_i. \quad (4.10)$$

Definiendo la probabilidad normalizada como $p'(\mathbf{X}_i) = p(\mathbf{X}_i)/\alpha$, las ecuaciones (4.8) y (4.9) pueden ser aproximadas a las sumatorias:

$$\hat{\mathbf{X}}_c = \sum_{i=1}^N \mathbf{X}_i \cdot p'(\mathbf{X}_i) \Delta\mathbf{X}_i \quad (4.11)$$

y

$$P_c = \sum_{i=1}^N (\mathbf{X}_i - \hat{\mathbf{X}}_c)(\mathbf{X}_i - \hat{\mathbf{X}}_c)^T p'(\mathbf{X}_i) \Delta\mathbf{X}_i + R_c, \quad (4.12)$$

donde R_c es la covarianza del error introducido por la cuantización.

Las ecuaciones anteriores pueden ser simplificadas si alternativamente se calcula:

$$\alpha' = \sum_{i=1}^N p(\mathbf{X}_i). \quad (4.13)$$

donde $\alpha = \alpha' \Delta\mathbf{X}_i$ y se define $p^*(\mathbf{X}_i) = p'(\mathbf{X}_i) \Delta\mathbf{X}_i = p(\mathbf{X}_i)/\alpha'$, entonces (4.11) y (4.12) pueden ser re escritas como:

$$\hat{\mathbf{X}}_c = \sum_{i=1}^N \mathbf{X}_i \cdot p^*(\mathbf{X}_i) \quad (4.14)$$

y

$$P_c = \sum_{i=1}^N (\mathbf{X}_i - \hat{\mathbf{X}}_c)(\mathbf{X}_i - \hat{\mathbf{X}}_c)^T p^*(\mathbf{X}_i) + R_c, \quad (4.15)$$

4.1.2.2. Transformación de estados

Las sumatorias propuestas para el cálculo de las pdf truncadas requieren una cantidad de puntos a evaluar que crece exponencialmente con el número de dimensiones. Si se desea fusionar 2 estimaciones de sistemas de navegación inercial con 9 estados ($[\Delta\boldsymbol{\Psi}; \dot{\mathbf{r}}; \mathbf{r}]$), el número de puntos a evaluar sería excesivo, por lo que se propone la utilización de una transformación de estados como la propuesta en [34], para enfocar la distribución en los estados de interés.

Si se define un límite esférico, los estados pueden ser representados en un espacio de estados donde $\mathbf{Z} = [\mathbf{Z}_1; \mathbf{Z}_2] = T \cdot \mathbf{X} \in \mathfrak{R}^n$, tal que $\mathbf{Z}_1 = [\mathbf{r}^1 - \mathbf{r}^2]$ y $\mathbf{Z}_2 = [\mathbf{X}_o^1; (\mathbf{r}^1 + \mathbf{r}^2); \mathbf{X}_o^2]$. La transformación lineal será:

$$T = \begin{bmatrix} I_3 & 0_{3 \times m_1} & -I_3 & 0_{3 \times m_2} \\ 0_{m_1 \times 3} & I_{m_1} & 0_{m_1 \times 3} & 0_{m_1 \times m_2} \\ I_3 & 0_{3 \times m_1} & I_3 & 0_{3 \times m_2} \\ 0_{m_2 \times 3} & 0_{m_2 \times m_1} & 0_{m_2 \times 3} & I_{m_2} \end{bmatrix}, \quad (4.16)$$

lo que modifica la condición de truncado a $\|L \cdot T^{-1} \cdot \mathbf{Z}\| = \|\mathbf{Z}_1\| \leq \gamma$. Si se define un límite elipsoidal, se puede utilizar $\mathbf{Z}_1 = L \cdot \mathbf{X}$ de (4.2) y

$$\mathbf{Z}_2 = \begin{bmatrix} \mathbf{X}_o^1 \\ (r_x^1 + r_x^2)/d_1 \\ (r_y^1 + r_y^2)/d_2 \\ (r_z^1 + r_z^2)/d_3 \\ \mathbf{X}_o^2 \end{bmatrix}. \quad (4.17)$$

Esta matriz transforma el límite elipsoidal en uno esférico en el espacio de \mathbf{Z} .

Si se aproxima la pdf de \mathbf{X} a una distribución Gaussiana, la pdf de \mathbf{Z} también será Gaussiana con media $\hat{\mathbf{Z}} = T \cdot \hat{\mathbf{X}}$ y covarianza $P_z = T \cdot P^+ \cdot T^T$. La inversa de la covarianza P_z puede ser dividida de acuerdo a las componentes asociadas a \mathbf{Z}_1 y \mathbf{Z}_2 , como:

$$P_z^{-1} = W = \begin{bmatrix} W_{11} & W_{12} \\ W_{12}^T & W_{22} \end{bmatrix}. \quad (4.18)$$

Si se define $W'_{11} = W_{11} - W_{12}W_{22}^{-1}W_{12}^T$, la pdf de \mathbf{Z}_1 puede ser escrita como

$$p_1(\mathbf{Z}_1) = \frac{\sqrt{|W'_{11}|}}{\sqrt{2\pi}^3} e^{-(\Delta\mathbf{z}_1^T W'_{11} \Delta\mathbf{z}_1)/2}, \quad (4.19)$$

donde $\Delta\mathbf{Z}_1 = \mathbf{Z}_1 - \hat{\mathbf{Z}}_1$ y $\hat{\mathbf{Z}}_1$ es el estimado de la media de \mathbf{Z}_1 . Definiendo un factor de normalización α_z , tal que:

$$\alpha_z = \int_{\mathbf{Z}_1^*} p_1(\mathbf{Z}_1) d\mathbf{Z}_1 \quad (4.20)$$

donde

$$\mathbf{Z}_1^* = \{\mathbf{Z}_1 \in \mathfrak{R}^3 : \|\mathbf{Z}_1\| \leq \gamma\}. \quad (4.21)$$

La pdf normalizada será $p'_1(\mathbf{Z}_1) = p_1(\mathbf{Z}_1)/\alpha_z$ en \mathbf{Z}_1^* . La media de la distribución truncada puede ser dividida como $\hat{\mathbf{Z}}_c = [\hat{\mathbf{Z}}_{c1}; \hat{\mathbf{Z}}_{c2}]$, donde cada término puede ser calculado por separado de acuerdo a [34]:

$$\hat{\mathbf{Z}}_{c1} = \int_{\mathbf{Z}_1^*} \mathbf{Z}_1 p'_1(\mathbf{Z}_1) d\mathbf{Z}_1, \quad (4.22)$$

y:

$$\hat{\mathbf{Z}}_{c2} = \hat{\mathbf{Z}}_2 - W_{22}^{-1} W_{12}^T \cdot (\hat{\mathbf{Z}}_{c1} - \hat{\mathbf{Z}}_1). \quad (4.23)$$

La covarianza de la pdf truncada puede ser separada de acuerdo a cada uno de sus componente (\mathbf{Z}_1 y \mathbf{Z}_2) como:

$$P_{zc} = \begin{bmatrix} P_{c11} & P_{c12} \\ P_{c12}^T & P_{c22} \end{bmatrix} \quad (4.24)$$

donde:

$$P_{c11} = \int_{\mathbf{Z}_1^*} (\mathbf{Z}_1 - \hat{\mathbf{Z}}_{c1})(\mathbf{Z}_1 - \hat{\mathbf{Z}}_{c1})^T p'_1(\mathbf{Z}_1) d\mathbf{Z}_1, \quad (4.25)$$

$$P_{c12} = -P_{c11} W_{12} W_{22}^{-1}, \quad (4.26)$$

y

$$P_{c22} = W_{22}^{-1} + W_{22}^{-1} W_{12}^T P_{c11} W_{12} W_{22}^{-1}. \quad (4.27)$$

Una vez obtenido $\bar{\mathbf{Z}}_c$ y P_{zc} , la transformación lineal T puede ser utilizada para obtener $\hat{\mathbf{X}}_c = T^{-1} \hat{\mathbf{Z}}_c$ y $P_c = T^{-1} P_{zc} (T^{-1})^T$.

4.1.3. Distancia máxima entre puntos de estimación

El filtro de límites propuesto está basado en que dos estimaciones de sistemas de posicionamiento distintos llevados por la misma persona tienen una distancia máxima entre ellas. Las distancias entre las estimaciones dependerán de la posición de los sensores en el cuerpo. En el presente trabajo se busca fusionar la información de una IMU en el pie y otros sensores en el cuerpo.

La mayoría de los sensores utilizados para obtener un posicionamiento absoluto no pueden ser colocados en el pie debido a que requieren una línea de visión con balizas o puntos de referencia. Una posición óptima para estos sensores es en la cabeza de la persona, es por ello que sistemas como el DRM4000L [123] de Honeywell colocan la antena del sistema de posicionamiento por GPS en una gorra.

Para analizar la posición relativa entre dos puntos de estimación en la cabeza y el pie, se propone utilizar un sistema de captura de movimiento por cámaras para obtener las posiciones de los puntos mientras un usuario realiza diferentes movimientos (caminando recto en una cinta de correr y caminado aleatorio en el área de estudio). La figura 4.2 muestra las distribuciones de las posiciones relativas de la cabeza con respecto a los pies derecho e izquierdo para una persona de aproximadamente 1,70 m de altura en el sistema de referencia global $((\mathbf{r}^1)^n - (\mathbf{r}^2)^n)$.

Si se considera la distancia entre la cabeza y el pie cuando una persona se encuentra parada, se puede asumir que el límite en la distancia entre ellos debe ser por lo menos 2 m. Al observar en la distribución en el plano horizontal, se puede notar que no se distancian más de 0,6 m en el plano XY, y en el eje Z, la diferencia de alturas se encuentra distribuido entre 1,5 m y 1,8 m aproximadamente. Como alternativa al límite esférico de 2 m se propone un límite elipsoidal con $d_x = d_y = 0,6$ m y $d_z = 0,3$ m. Este límite desplaza la estimación del PDR a la altura de la cabeza, por lo que para obtener la posición del pie sería necesario desplazarlo en el eje vertical $[0 \ 0 \ -1,65 \text{ m}]^T$.

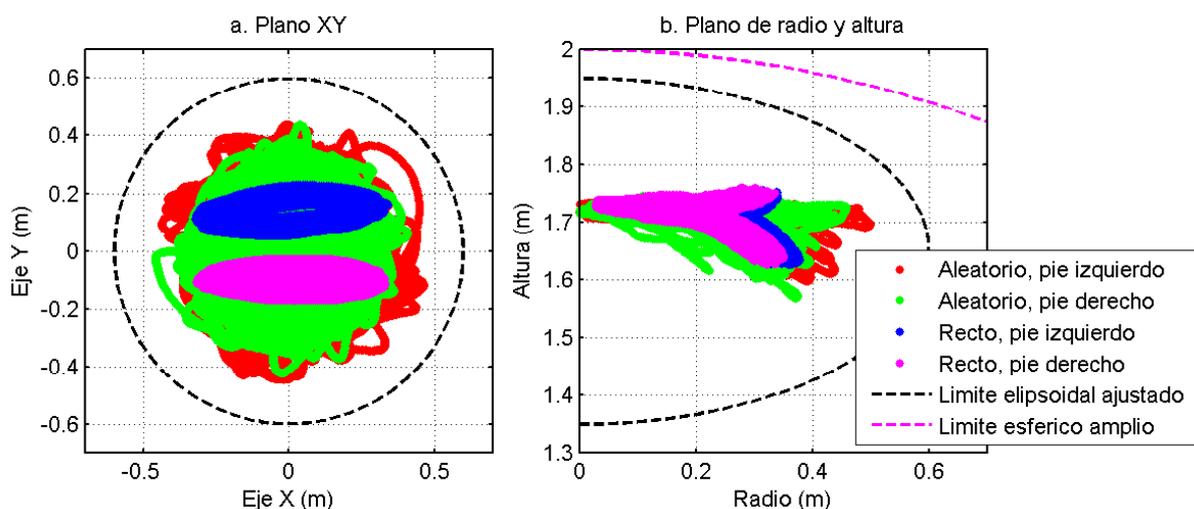


Figura 4.2: Posición relativa del punto en la cabeza con respecto al punto en el pie derecho e izquierdo y los posible límites a implementar.

4.1.4. Pruebas realizadas

Para probar la fusión de información utilizando el filtro, se propone utilizar un método de Monte Carlo con las señales sintéticas utilizadas en la sección 3.2.2.2 y pruebas reales de una persona caminando con una IMU en el pie y usando un tag UWB de Ubisense [109].

4.1.4.1. Prueba de Monte Carlo

Para analizar el error que genera la fusión de sistemas de posicionamiento con el filtro de límites se propone utilizar una señal sintética ideal (sin ruido ni bias) emulando una IMU en el pie derecho de una persona caminando en un recorrido cerrado [19]. Para obtener la segunda estimación en otra parte del cuerpo se modeló la posición, orientación, aceleraciones y velocidades angulares de una IMU en la cabeza de una persona de 1,8 m de altura.

La posición de la cabeza es modelada con una velocidad aproximadamente constante, a 0,1 m a la izquierda del punto simulando del pie, y con una altura constante de 1,8 m. Por otro lado, para modelar las medidas de un sistema de posicionamiento en la cabeza similar al de Ubisense, se propone realizar medidas de posición y se asumirá que el sensor está adherido a la IMU de la cabeza. Los errores de cada sensor son modelados agregando en las IMUs, ruido medido de una IMU real con un bias aleatorio, y en el sensor de posición, ruido Gaussiano de media cero y desviaciones estándar independientes en cada eje $\sigma_x = \sigma_y = 0,3 m$ y $\sigma_z = 1 m$.

Para fusionar la información se utiliza el límite elipsoidal con $d_x = d_y = 0,6 m$ y $d_z = 0,3 m$ y una diferencia de altura entre las estimaciones de 1,65 m. La figura 4.3 muestra el posicionamiento obtenido en una simulación utilizando ambas estimaciones independientemente y al fusionarlas con el filtro de límites. Está claro que al fusionar la información se mejora significativamente las estimaciones, pero para poder medir la mejora es necesario estudiar el comportamiento de múltiples simulaciones.

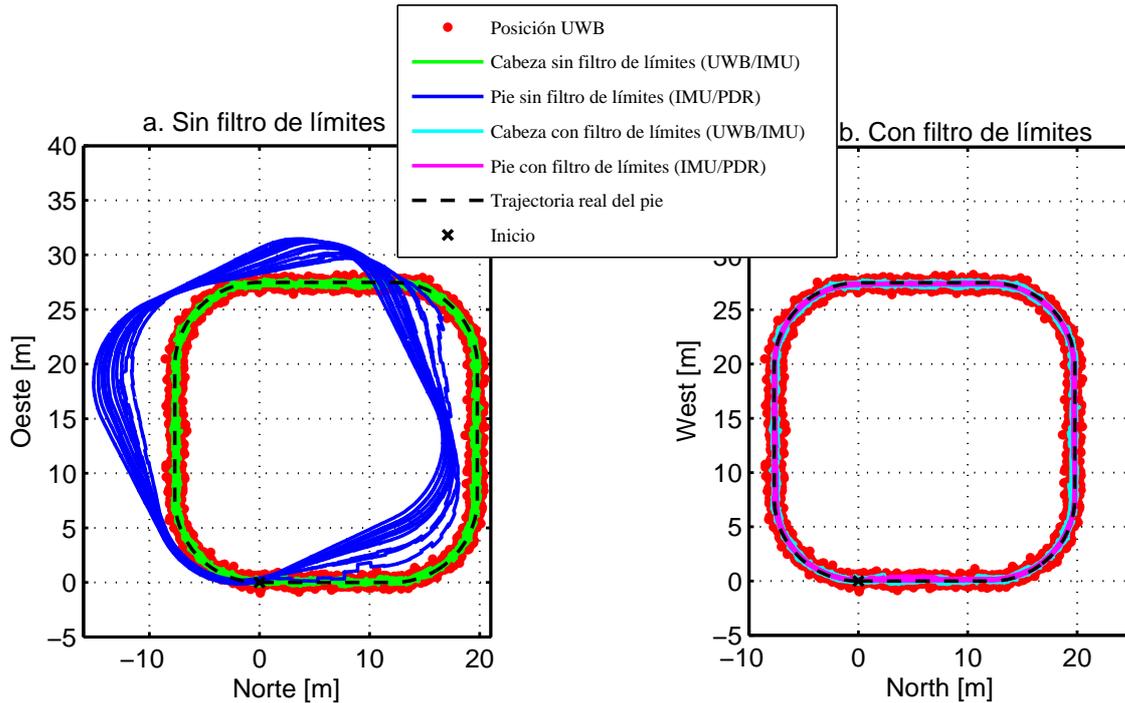


Figura 4.3: Estimaciones de la posición de puntos en la cabeza y el pie independientemente (a) y fusionando su información con el filtro de límites (b).

Se propone utilizar el error cuadrático medio calculado de acuerdo a (3.12) como medida del error de los sistemas y luego de realizar 100 simulaciones de cada caso se obtiene la evolución del error cuadrático medio observado en la figura 4.4.

La evolución del error cuadrático medio de los puntos de estimación después de la fusión propuesta es claramente menor que cualquiera de los puntos sin fusionar su información. Esto se debe a que el punto en el pie ofrece un excelente posicionamiento relativo con un error de alrededor de 1% de la distancia total recorrida, pero no tiene información absoluta de la posición, mientras que el posicionamiento por UWB provee la posición absoluta pero presenta niveles de error cercanos a 1 m en el experimento (en pruebas reales puede ser mayor cuando no hay línea de visión con los sensores).

4.1.4.2. Pruebas con medidas reales

El sistema de fusión por filtro de límites fue probado con medidas reales en la sala de experimentos R1 de KTH (Royal Institute of Technology, Estocolmo-Suecia), el cual cuenta con un sistema de posicionamiento por Ultra Wide Band (UWB) de Ubisense [109] con 8 Sensores. La posición del pie fue estimada utilizando el sistema PDR OpenShoe propuesto en [124], capaz de muestrear las medidas inerciales a 825 Hz. La posición de la cabeza se obtuvo utilizando un tag UWB y una IMU con una tasa de muestreo de 250 Hz. La configuración puede ser observada en la figura 4.5

Para el experimento el sujeto de prueba realizó diez veces un recorrido en forma de 8, siguiendo la trayectoria aproximada mostrada en la figura 4.6. Para inicializar la posición del sistema PDR se utilizó la posición del tag UWB y la guiñada del magnetómetro en la IMU colocada en la

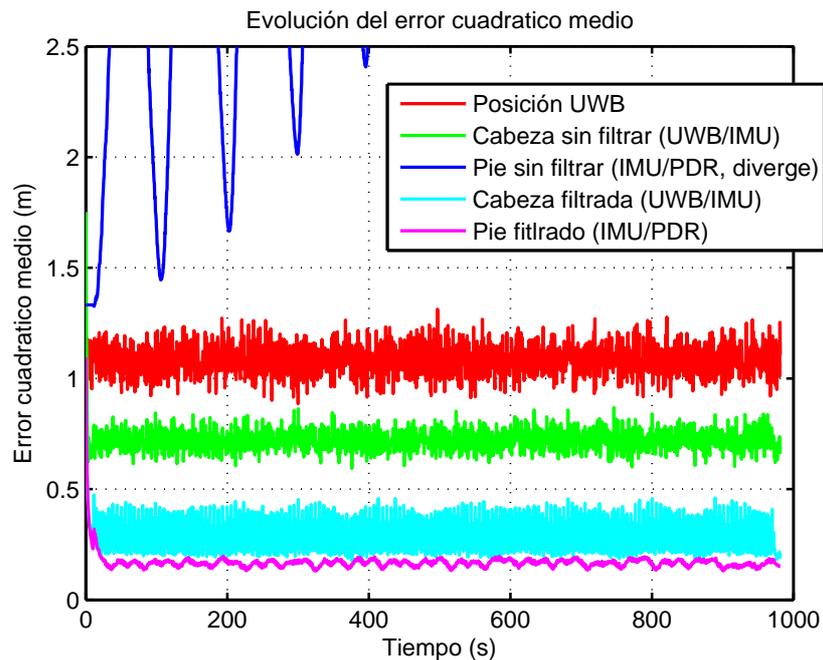


Figura 4.4: Evolución del error cuadrático medio para puntos en la cabeza y el pie, utilizando estimaciones con EKF's independientes en cada punto y fusionando su información con el filtro de límites.

cabeza, esperando que estos estuviesen alineados (el sistema OpenShoe no tiene magnetómetro).

Se puede observar que la fusión con el filtro de límites disminuye el error significativamente en la estimación por PDR, evitando la deriva y corrigiendo la orientación del sistema. El sistema también disminuye el nivel de error de la estimación en la cabeza, principalmente en el lóbulo Este de la trayectoria, donde debido a problemas en la línea de visión el sistema UWB no tiene tan buenas medidas.



Figura 4.5: Equipo utilizado para la evaluación del sistema de fusión de PDR UWB/IMU utilizando un filtro de límites.

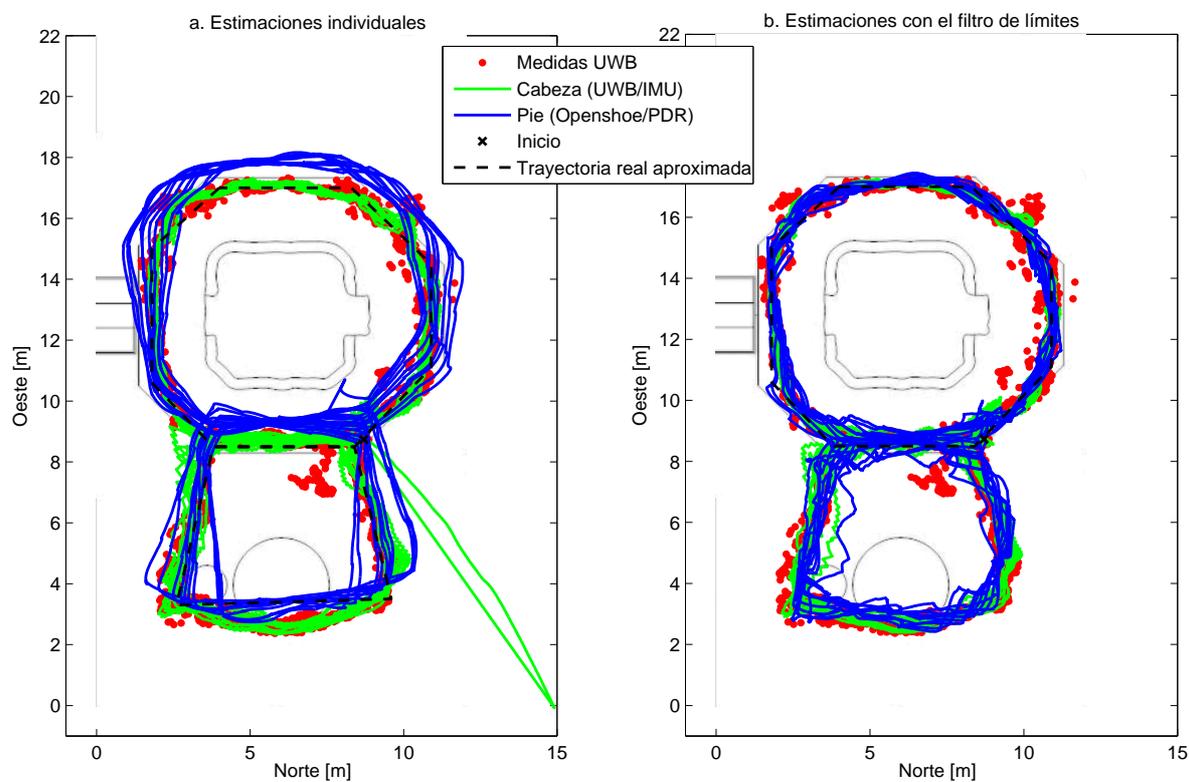


Figura 4.6: Recorridos obtenidos para los puntos estudiados en la cabeza y el pie de la persona utilizando una estimación independiente (a) y con el filtro que limita la distancia entre ambas estimaciones (b).

4.2. Uso de PDR como modelo de desplazamientos en un filtro de partículas de partículas

Los sistemas de localización basados en sensores inerciales no son capaces de proveer un posicionamiento absoluto por sí solos, sin embargo proveen un posicionamiento relativo con errores de entre 1% y 5% de la distancia total recorrida. En particular el PDR con la IMU en el pie ofrece un posicionamiento relativo muy preciso con un mínimo de procesamiento y error. Agregar medidas externas para corregir el posicionamiento puede ofrecer un posicionamiento absoluto, pero también puede alterar la estimación del INS.

En la presente sección se buscará mejorar el esquema de fusión para permitir la introducción de todo tipo de medidas externas (independientemente de la linealidad o tipo de error utilizado) y poder realizar la estimación sin conocer la posición y orientación inicial. Para ello, se utilizará el esquema de estimación a dos niveles propuesto en [54, 55, 66], en el cual en un bajo nivel se utiliza un EKF implementando PDR con propagación por INS y correcciones de ZUPT, y en un alto nivel se utilizan las estimaciones de los pasos obtenidas del bajo nivel para propagar las partículas del filtro y corregir los pesos de éstas de acuerdo a las medidas recibidas.

Sobre dicho esquema se proponen dos modificaciones resaltadas en color amarillo y azul en la figura 4.7 y detalladas a continuación:

- **Modelo del paso (amarillo):** Mejorar el modelo de propagación basado en los pasos obtenidos de PDR, modificando las covarianza del vector de desplazamiento de acuerdo a las características del paso de una persona al caminar.
- **Modelo del bias (azul):** Modelar el bias de la velocidad angular en el eje de giro en guiñada o acimut, como un estado adicional a estimar, para aproximar mejor el comportamiento de las partículas, siguiendo una dispersión más fiel a la incertidumbre real en orientación o guiñada.

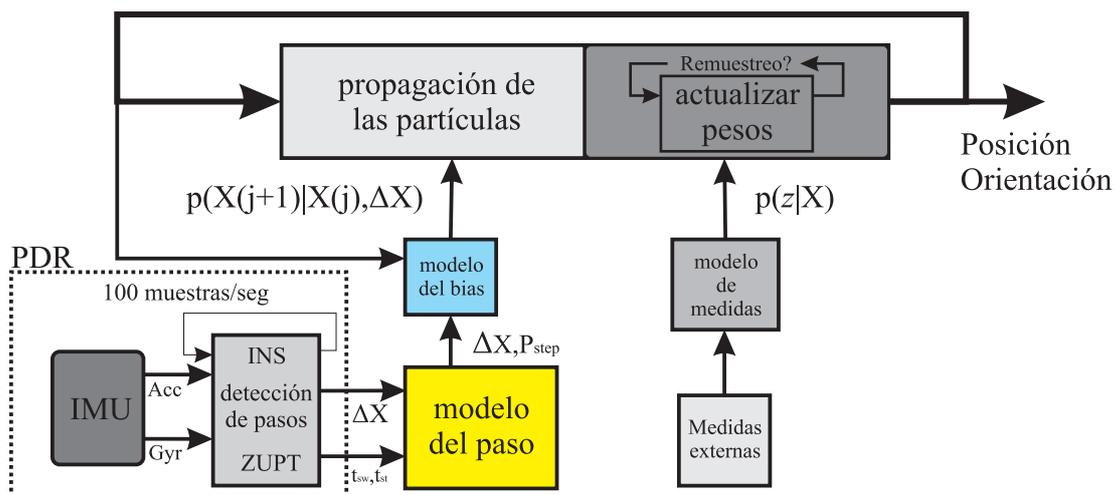


Figura 4.7: Esquema de estimación a dos niveles propuesto en [54, 55, 66], resaltando las modificaciones propuestas en el modelo del paso (amarillo) y el modelo del bias (azul).

En la presente sección primero se presentará el esquema de estimación de dos niveles utilizado, basado en el propuesto en [54, 55, 66]. Luego se presentará el modelo adaptativo de despla-

mientos por pasos (bloque amarillo en la figura), posteriormente se analizará el error cuadrático medio de este modelo y por último se presentará el modelado del bias (bloque azul en la figura) y su efecto en la estimación.

4.2.1. Esquema de estimación a dos niveles

Estimar los 15 (o 9) estados utilizados en PDR con un filtro de partículas puede conllevar a que las estimaciones no puedan ser realizadas a tiempo real por el número de partículas necesarias (debido a un fenómeno conocido como “the curse of dimensionality” [40]) y a la alta tasa de muestreo de una IMU (usualmente 100 muestras/s). Es por ello que la mayoría de los autores buscan simplificar el proceso y los estados de PDR para poder aplicar esta técnica de fusión de información. Como se detalla en [125] varios autores simultáneamente propusieron la utilización de la información proveniente de PDR utilizando INS con ZUPT para propagar las estimaciones de los pasos en un filtro de partículas.

El modelo propuesto en [54, 55, 66] propaga la posición (en 2 o 3 dimensiones de acuerdo al autor) y orientación (guiñada) de la persona, utilizando PDR basado en INS en el pie con actualizaciones de velocidad nula. En este modelo se ejecuta en el nivel bajo un algoritmo PDR a una alta tasa de muestreo (usualmente 100 muestras/s), y luego de cada paso detectado (aproximadamente 1 vez por segundo) se propagan las partículas de la misma manera que una estimación PDR por longitud y cambio de ángulo del paso. A continuación se presentan ambos niveles.

4.2.1.1. Nivel bajo, Pedestrian Dead Reckoning

Para estimar la posición relativa de la persona y por ende su modelo de movimiento, se utiliza el método explicado en la Sección 2.3.3.2 con correcciones de velocidad nula como se proponen en la Sección 2.4.1.1. En el presente trabajo por simplicidad y para evitar la influencia de otros errores, se utilizará el modelo propagando solo 9 estados (error de orientación $\Delta\Psi$, posición \mathbf{r} y velocidad $\dot{\mathbf{r}}$), por lo que el vector de estados en PDR será $\mathbf{X}_{\text{PDR}} = [\Delta\Psi; \mathbf{r}; \dot{\mathbf{r}}]$, y su propagación de acuerdo a:

$$\Delta\hat{\Psi}(k+1) = \Delta\Psi(k), \quad (4.28)$$

$$\hat{\mathbf{r}}(k+1) = \mathbf{r}(k) + (\dot{\mathbf{r}}(k) + \dot{\mathbf{r}}(k+1)) \cdot \Delta T/2, \quad (4.29)$$

$$\hat{\dot{\mathbf{r}}}(k+1) = \dot{\mathbf{r}}(k) + (C_b^n(k) \cdot \text{Acc}_k - \mathbf{g}) \cdot \Delta T, \quad (4.30)$$

donde la orientación es propagada como $\hat{C}_b^n(k+1) = C_b^n(k) \cdot \exp([Gyr_k \times] \cdot \Delta T)$ y el símbolo $\hat{}$ indica las estimaciones (o predicciones) de la media, la covarianza o cualquier variable utilizada.

Agrupando los términos y agregando un término asociado al ruido del proceso w (tal que $Q = E(w \cdot w^T)$) se obtiene la función de propagación de estados:

$$\hat{\mathbf{X}}_{\text{PDR}}(k+1) = f(\mathbf{X}_{\text{PDR}}(k), \text{Acc}(k), \text{Gyr}(k)) + w. \quad (4.31)$$

La covarianza del proceso \hat{P}_{PDR} se puede estimar de acuerdo a:

$$\hat{P}_{\text{PDR}}(k+1) = \Phi(k) \cdot P_{\text{PDR}}(k) \cdot \Phi^T(k) + Q, \quad (4.32)$$

donde Φ es el jacobiano de la función de propagación:

$$\Phi = \begin{bmatrix} I_3 & 0_3 & 0_3 \\ 0_3 & I_3 & I_3 \cdot \Delta T \\ -[\hat{C}_b^n \text{Acc} \times] \cdot \Delta T & 0_3 & I_3 \end{bmatrix}. \quad (4.33)$$

Cuando se detecta un apoyo se implementa una corrección de velocidad nula como una observación de los estados:

$$\mathbf{m}^{\text{ZUPT}} = H \cdot \mathbf{X}_{\text{PDR}}(k) + v, \quad (4.34)$$

donde asumimos que la velocidad es nula ($\mathbf{m}^{\text{ZUPT}} = [0; 0; 0]$), v es el error de la medida tal que $R = E(v \cdot v^T)$ y H es la matriz de observación tal que $H = [0_3 \ 0_3 \ I_3]$.

Con esta medida los estados pueden ser corregidos como:

$$\mathbf{X}_{\text{PDR}}(k) = \hat{\mathbf{X}}_{\text{PDR}}(k) + K \cdot (\mathbf{m}^{\text{ZUPT}} - H \cdot \hat{\mathbf{X}}_{\text{PDR}}(k)), \quad (4.35)$$

$$P_{\text{PDR}}(k) = (I - K \cdot H) \cdot \hat{P}_{\text{PDR}}(k), \quad (4.36)$$

donde la ganancia de Kalman K puede ser calculada como:

$$K = \hat{P}_{\text{PDR}}(k) \cdot H^T \cdot (H \cdot \hat{P}_{\text{PDR}}(k) \cdot H^T + R)^{-1}. \quad (4.37)$$

Luego del j -ésimo apoyo, se selecciona el índice central del apoyo (k_j) y se determina la posición y guiñada en el punto. El desplazamiento $\Delta \mathbf{r}_{\text{PDR}}$ y cambio de ángulo $\Delta \psi_{\text{PDR}}$ del j -ésimo paso medido con respecto a la guiñada del j -ésimo apoyo, será:

$$\Delta \mathbf{r}_{\text{PDR}}(j) = C_z^T(\psi(k_j)) \cdot (\mathbf{r}(k_{j+1}) - \mathbf{r}(k_j)), \quad (4.38)$$

$$\Delta \psi_{\text{PDR}}(j) = \psi(k_{j+1}) - \psi(k_j), \quad (4.39)$$

donde la matriz $C_z(\psi)$ es una rotación de ángulo ψ en el eje Z y puede ser obtenida como:

$$C_z(\psi) = \begin{bmatrix} \cos(\psi) & -\sin(\psi) & 0 \\ \sin(\psi) & \cos(\psi) & 0 \\ 0 & 0 & 1 \end{bmatrix}. \quad (4.40)$$

4.2.1.2. Nivel alto, filtro de partículas

En este nivel se buscará estimar los estados no observables del PDR (en un principio posición y guiñada) utilizando un filtro de partículas que propaga las partículas con los desplazamientos de PDR y corrige sus pesos con cualquier medida recibida. En el filtro de partículas inicialmente definido en [54, 55, 66], los estados de cada partícula $\mathbf{X}^{(i)}$ están compuestos de una posición y una guiñada, tal que $\mathbf{X}^{(i)} = [\mathbf{r}^{(i)}; \psi^{(i)}]$. Al detectarse un apoyo, se puede utilizar el paso $\Delta \mathbf{X}_{\text{PDR}}(j) = [\Delta \mathbf{r}_{\text{PDR}}(j); \Delta \psi_{\text{PDR}}(j)]$ obtenido del filtro del nivel bajo (PDR), para propagar las partículas de acuerdo a:

$$\mathbf{X}^{(i)}(j+1) = \mathbf{X}^{(i)}(j) + C_z^e(\psi^{(i)}(j))(\Delta \mathbf{X}_{\text{PDR}}(j) + \eta_{\Delta X}), \quad (4.41)$$

donde el superíndice (i) indica el índice de cada partícula y $\eta_{\Delta X}$ es el modelo de ruido utilizado, que en [54, 55, 66] es asumido como un modelo Gaussiano de covarianza constante y $C_z^e(\psi)$ es la rotación extendida a 4 dimensiones:

$$C_z^e(\psi) = \begin{bmatrix} C_z(\psi) & 0_{3 \times 1} \\ 0_{1 \times 3} & 1 \end{bmatrix} \quad (4.42)$$

Utilizando esta propagación, las partículas pueden desplazarse como se observa en la figura 4.8. Si durante la propagación se detecta una medida $z(k)$ en el instante k (medido en el eje de tiempo de PDR), es necesario actualizar los pesos de las partículas de acuerdo a:

$$w^{(i)}(j+1) = \frac{w^{(i)}(j) \cdot p(z(k) | \hat{\mathbf{X}}^{(i)}(k))}{p(z(k))}, \quad (4.43)$$

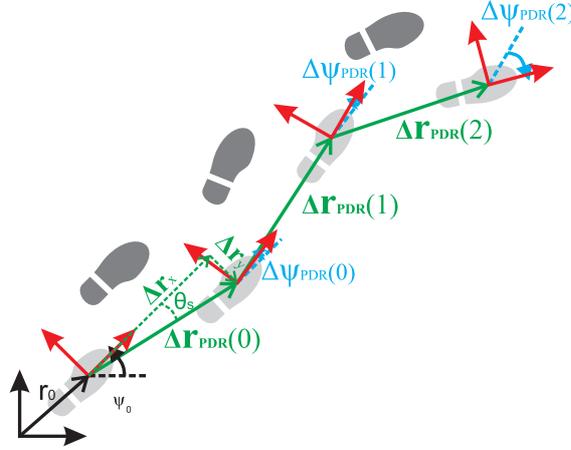


Figura 4.8: Reconstrucción de la posición utilizando los desplazamientos (verde) y cambios de ángulos (azul), respecto a la última posición y orientación del pie (rojo), obtenidos de PDR.

donde $p(z(k)|\hat{\mathbf{X}}^{(i)}(k))$ es la probabilidad de ocurrencia de la medida dado que el punto de recepción es $\hat{\mathbf{X}}^{(i)}(k)$ (aproximación de la posición de la partícula en el instante k) y $p(z(k))$ es la probabilidad de la medida que funciona como un factor de normalización de los pesos.

La medida puede ser modelada con alguna función de observación, tal que:

$$z(k) = h(\hat{\mathbf{r}}(k)) + v, \quad (4.44)$$

donde $h()$ es la función de observación, $\hat{\mathbf{r}}(k)$ la aproximación de la posición en el instante k y v el modelo del ruido. Si se asume un ruido Gaussiano de media cero y covarianza σ^2 , se puede aproximar la probabilidad de la medida en $\hat{\mathbf{X}}^{(i)}(k)$ de acuerdo a:

$$p(z(k)|\hat{\mathbf{X}}^{(i)}(k)) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(z(k) - h(\hat{\mathbf{r}}(k)))^2}{2\sigma^2}\right) \quad (4.45)$$

Para conocer la aproximación de la posición de la partícula en el instante k (asumiremos que ocurrió entre el instante k_j y k_{j+1}) se asume una velocidad constante entre los puntos de apoyo y se obtiene:

$$\hat{\mathbf{r}}(k) = \mathbf{r}(k_j) + \frac{(k - k_j)}{(k_{j+1} - k_j)} \cdot (\mathbf{r}(k_{j+1}) - \mathbf{r}(k_j)). \quad (4.46)$$

Para evitar calcular $p(z(k))$ muchos autores calculan pesos temporales $w^{(i)}$, tales que:

$$w^{(i)} = w^{(i)}(j) \cdot p(z(k)|\hat{\mathbf{r}}^{(i)}(k)), \quad (4.47)$$

y luego proceden a normalizar los pesos tal que:

$$w^{(i)}(j+1) = w^{(i)} / \sum w^{(i)}. \quad (4.48)$$

Después de actualizar los pasos con las medidas recibidas, se verifica que las partículas no presenten una degeneración utilizando (2.50) y si es necesario se remuestrea la distribución, utilizando el algoritmo propuesto en la Sección 2.3.2.2.

Esta sección se centrará en el modelo de fusión, proponiendo métodos de propagación de las partículas, mientras que el Capítulo 5 presentará las posibles medidas a utilizar para limitar el crecimiento del drift y las pruebas realizadas con cada medida.

4.2.2. Modelo adaptativo de desplazamientos por pasos

Los desplazamientos y cambios de ángulo obtenidos de la IMU en el pie con PDR tienen una precisión del orden de 1% de la distancia recorrida [19], por lo que son una excelente fuente de información para la propagación de las partículas, pero es necesario conocer el nivel de error de estas medidas.

Como se comentó previamente las estimaciones propuestas en [54, 55, 66] utilizan un modelo del error del paso con una covarianza constante, pero como se mostrará a continuación la covarianza de la medida varía de acuerdo a las características de paso. Como trabajo original de esta tesis se propone estudiar la evolución del error en el paso al variar las características de éste y desarrollar un modelo de error que se adapte a las características del paso para mejorar la propagación en el filtro de partículas.

Para analizar el nivel de error de las propagaciones PDR se utilizarán señales sintéticas de un paso lento (longitud del paso $SL = 0,725\text{ m}$, tiempo entre pasos $t_{st} = 2,1\text{ s}$ y tiempo en balanceo $t_{sw} = 0,64\text{ s}$) y un paso rápido ($SL = 1,2\text{ m}$, $t_{st} = 1,2\text{ s}$ y $t_{sw} = 0,8\text{ s}$), ambos en el eje X y obtenidas utilizando el método propuesto en [19]. Para observar el nivel de error, a la señal sin ruido se le agregaron diferentes segmentos del ruido grabado en una IMU en estático (MTi de XSens). La figura 4.9 muestra las distribuciones en posición y orientación obtenidas para cada tipo de paso.

Se puede observar que diferentes pasos tienen diferentes distribuciones de error y estas diferencias no se adaptan a los modelos previamente propuestos, por lo que en esta tesis se propone el estudio de la evolución del modelo de error al variar las características del paso. Luego de estudiar múltiples variables se determinó que las principales fuentes de variación del error fueron: la dirección del paso ($\theta_s = \text{atan2}(\Delta r_y, \Delta r_x)$), la longitud del paso ($SL = \|\Delta \mathbf{r}\|$), el tiempo en balanceo (t_{sw}) y el tiempo entre pasos ($t_{st} = t_{sw} + \text{tiempo en apoyo}$).

La dirección del paso tiene un efecto directo sobre la distribución del error. Si el paso forma un ángulo θ_s con el eje X del apoyo previo, la distribución esperada es equivalente a girar una distribución recta ($\theta_s = 0$) un ángulo de θ_s en el plano XY, y manteniendo las distribuciones en el eje Z y la orientación. La covarianza de la distribución puede ser obtenida utilizando (4.42) y:

$$P_{\text{step}} = C_z^e(\theta_s) \cdot P_{\text{step}, \theta_s=0} \cdot C_z^e(\theta_s)^T, \quad (4.49)$$

donde $P_{\text{step}, \theta_s=0}$ es la covarianza de un paso con $\theta_s = 0$.

Se ha observado que aumentos en la duración del balanceo aumentan la desviación estándar de las distribuciones en los ejes X e Y, pero no afectan significativamente las distribuciones en el eje Z ni la guiñada. El tiempo entre pasos parece tener un efecto mayoritario en la distribución del cambio de ángulo, mientras que la longitud del paso parece influenciar mayoritariamente el eje perpendicular al desplazamiento. Estas observaciones guían la elección de un modelo, pero es necesario cuantificar el efecto de cada variable en la distribución, por lo que se propone estudiar la variación de la covarianza del error de medida utilizando el método propuesto en [126] que utiliza diferentes descomposiciones de la covarianza para simplificar la información. En el presente trabajo se propone la utilización de la factorización inferior de Cholesky de la covarianza del error en el paso ($\Delta \mathbf{X}_{\text{PDR}}$).

Para medir el efecto de la longitud del paso y la duración del balanceo se generaron señales

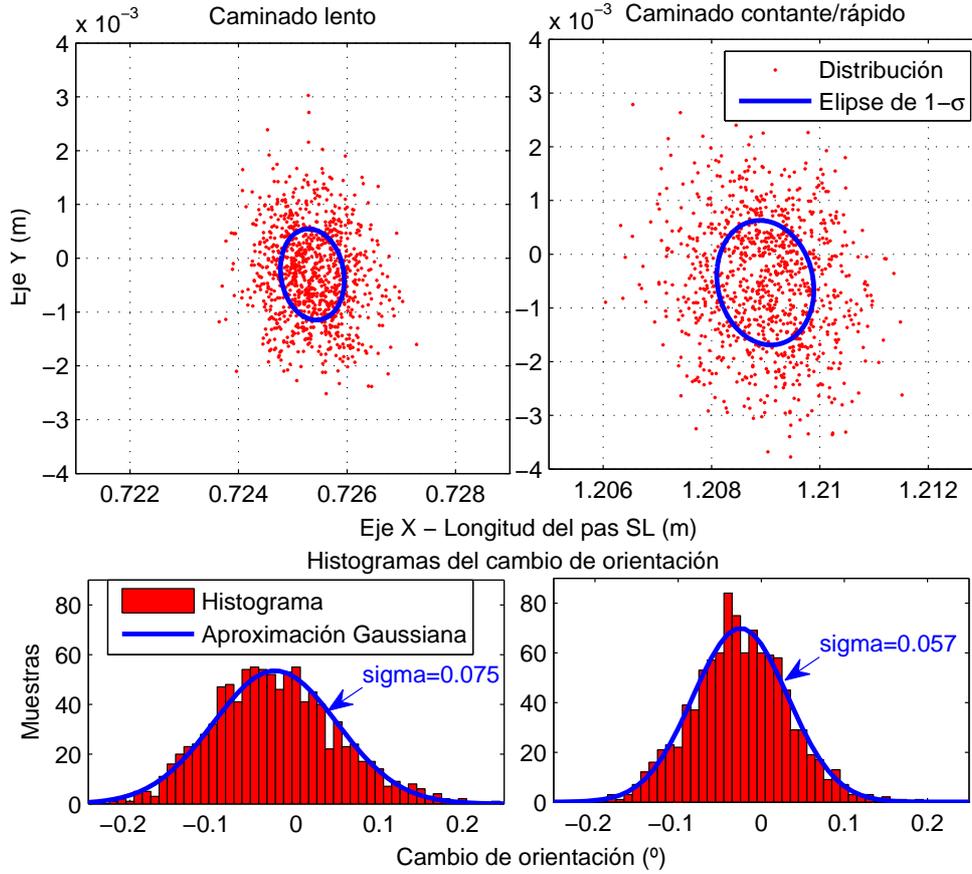


Figura 4.9: Distribución del error de posición y orientación para 1000 reconstrucciones de un caminado lento (izquierda, $SL = 0,725 \text{ m}$, $t_{st} = 2,1 \text{ s}$ y $t_{sw} = 0,64 \text{ s}$) y un caminado rápido (derecha, $SL = 1,21 \text{ m}$, $t_{st} = 1,2 \text{ s}$ y $t_{sw} = 0,8 \text{ s}$). En la parte superior las distribuciones en el plano XY, en la parte inferior histograma del cambio de guiñada.

sinécticas con 10 valores de entre 60 % y 150 % de la longitud y duración del balanceo del paso original. Para evaluar el efecto de la duración total del paso se alargó la fase de apoyo para generar 10 valores de tiempos totales del pasos entre 1.2 s y 2.1 s. Se observó que los elementos de las factorizaciones de Cholesky aumentaban linealmente al aumentar la longitud del paso y el tiempo de balanceo, pero cuadráticamente con el tiempo total del paso, por lo que se propone estudiar el incremento con respecto a la raíz cuadrada de esta variable ($\sqrt{t_{st}}$). Con estas 1 000 variaciones de las factorizaciones de Cholesky de la covarianza del error ($\sqrt{P_{step, \theta_s=0}}$, cada una obtenida de 1 000 simulaciones), se propone en esta tesis aproximar linealmente el efecto de cada una de las variables previamente descritas, obteniendo un modelo como el presentado a continuación:

$$\sqrt{P_{step, \theta_s=0}}(SL, t_{sw}, t_{st}) = A \cdot SL + B \cdot t_{sw} + C \cdot \sqrt{t_{st}} + D. \quad (4.50)$$

Según el modelo las matrices A, B y C son mediciones experimentales de los gradientes de cada uno de los elementos de $\sqrt{P_{step, \theta_s=0}}$ con respecto a las variable estudiadas, obtenidas de una rejilla de 10 valores por variable a estudiar (para un total de 1 000 puntos de estudio) y sus

valores son:

$$A = \begin{bmatrix} -6,8 \cdot 10^{-5} & 0 & 0 & 0 \\ 0 & 9,8 \cdot 10^{-4} & 0 & 0 \\ 9,2 \cdot 10^{-5} & 0 & 2,2 \cdot 10^{-4} & 0 \\ 0 & 2,3 \cdot 10^{-4} & 0 & -1,2 \cdot 10^{-3} \end{bmatrix}, \quad (4.51)$$

$$B = \begin{bmatrix} 2,8 \cdot 10^{-3} & 0 & 0 & 0 \\ 0 & 1,2 \cdot 10^{-3} & 0 & 0 \\ -7,3 \cdot 10^{-5} & 0 & 5,1 \cdot 10^{-5} & 0 \\ 0 & -6,5 \cdot 10^{-4} & 0 & 3,4 \cdot 10^{-3} \end{bmatrix}, \quad (4.52)$$

$$C = \begin{bmatrix} -8,6 \cdot 10^{-4} & 0 & 0 & 0 \\ 0 & -2,6 \cdot 10^{-4} & 0 & 0 \\ -1,5 \cdot 10^{-4} & 0 & 1,3 \cdot 10^{-5} & 0 \\ 0 & 5,5 \cdot 10^{-4} & 0 & 5,5 \cdot 10^{-3} \end{bmatrix}, \quad (4.53)$$

$$D = \begin{bmatrix} 8,6 \cdot 10^{-4} & 0 & 0 & 0 \\ 0 & 7,1 \cdot 10^{-4} & 0 & 0 \\ 2,7 \cdot 10^{-4} & 0 & 1,3 \cdot 10^{-4} & 0 \\ 0 & 4,1 \cdot 10^{-5} & 0 & -3,6 \cdot 10^{-3} \end{bmatrix}, \quad (4.54)$$

Utilizando el modelo, las partículas pueden ser propagadas de acuerdo a:

$$\sqrt{P_{\text{step}}} = C_z^e(\theta_s) \cdot \sqrt{P_{\text{step}, \theta_s=0}}(SL, t_{sw}, t_{st})$$

for $i=1:N$

$$\mathbf{X}^{(i)}(j+1) = \mathbf{X}^{(i)}(j) + C_z^e(\psi^{(i)}(j))(\Delta \mathbf{X}_{\text{PDR}}(j) + \sqrt{P_{\text{step}}} \cdot \text{randn}(4, 1))$$

end

donde $\text{randn}(4, 1)$ es una columna de 4 elementos pseudoaleatorios con una distribución normal.

4.2.3. Cota inferior de Cramér-Rao

Para analizar el efecto de esta propagación utilizando pasos obtenidos de PDR proponemos analizar la cota inferior de Cramér-Rao (CRLB) de la estimación, una cota que establece un mínimo al error cuadrático medio que se puede obtener de un estimador sin sesgo [127–129]. La CRLB permite conocer que tan cerca está un método de estimación de la implementación óptima.

La versión Bayesiana de la CRLB se conoce como Van Trees CRLB [130] o CRLB a posteriori, ya que es obtenido de distribuciones a posteriori [131]. En este caso, en el instante j la CRLB está dada por:

$$\mathbb{E}\{(g(\mathbf{Z}(j)) - \mathbf{X}(j))(g(\mathbf{Z}(j)) - \mathbf{X}(j))^T\} \succeq \mathbf{J}_j^{-1},$$

donde $\mathbf{Z}(j)$ denota todas las medidas disponibles hasta el paso j . Adicionalmente, $g(\mathbf{Z}(j))$ es un estimador sin sesgo de $\mathbf{X}(j)$, y \mathbf{J}_j es la matriz de información de Fisher (FIM) obtenida como,

$$\mathbf{J}_j = -\mathbb{E}\{\nabla_{\mathbf{X}(j)}[\nabla_{\mathbf{X}(j)} \log p(\mathbf{Z}(j)|\mathbf{X}(j))]\}^T.$$

Tichasvský *et al.* propuso en [132] un método recursivo para obtener la FIM, sin la necesidad de invertir grandes matrices de $((j+1)\dim(\mathbf{X})) \times ((j+1)\dim(\mathbf{X}))$. Ésta es obtenida como,

$$\mathbf{J}_{j+1} = \mathbf{D}_j^{22} - \mathbf{D}_j^{21}(\mathbf{J}_j + \mathbf{D}_j^{11})^{-1}\mathbf{D}_j^{12}, \quad (j > 0) \quad (4.55)$$

donde

$$\begin{aligned}
\mathbf{D}_j^{11} &= -\mathbb{E}\{\nabla_{\mathbf{X}(j)}[\nabla_{\mathbf{X}(j)} \log p(\mathbf{X}(j+1)|\mathbf{X}(j))]^T\} \\
\mathbf{D}_j^{21} &= -\mathbb{E}\{\nabla_{\mathbf{X}(j)}[\nabla_{\mathbf{X}(j+1)} \log p(\mathbf{X}(j+1)|\mathbf{X}(j))]^T\} \\
\mathbf{D}_j^{12} &= [\mathbf{D}_j^{21}]^T \\
\mathbf{D}_j^{22} &= -\mathbb{E}\{\nabla_{\mathbf{X}(j+1)}[\nabla_{\mathbf{X}(j+1)} \log p(\mathbf{X}(j+1)|\mathbf{X}(j))]^T\} \\
&\quad -\mathbb{E}\{\nabla_{\mathbf{X}(j+1)}[\nabla_{\mathbf{X}(j+1)} \log p(z(j+1)|\mathbf{X}(j+1))]^T\}.
\end{aligned}$$

El término asociado a las medidas ($\mathbf{J}_{j+1}^z = -\mathbb{E}\{\nabla_{\mathbf{X}(j+1)}[\nabla_{\mathbf{X}(j+1)} \log p(z(j+1)|\mathbf{X}(j+1))]^T\}$) solo es incluido en el cálculo cuando se perciben medidas externas, por lo que para estudiar exclusivamente la propagación de las partículas, éste será descartado.

Asumiendo una distribución Gaussiana para $\mathbf{X}(j+1)$ y partiendo de (4.41), el logaritmo de su probabilidad (descartando la componente constante) puede escribirse como:

$$\begin{aligned}
& -\log(p(\mathbf{X}(j+1)|\mathbf{X}(j))) = \\
& \left(\mathbf{X}(j+1) - \mathbf{X}(j) - C_z^e(\psi(j)) \cdot \Delta \mathbf{X}(j) \right)^T P_{\text{step}}(j)^{-1} \left(\mathbf{X}(j+1) - \mathbf{X}(j) - C_z^e(\psi(j)) \cdot \Delta \mathbf{X}(j) \right) / 2, \quad (4.56)
\end{aligned}$$

donde $P_{\text{PF}}(j+1)$ es la covarianza de la distribución del j -ésimo paso, obtenida de (4.49).

Bajo dicha asunción los coeficientes de (4.55) pueden ser obtenidos como:

$$\begin{aligned}
\mathbf{D}_j^{11} &= \Phi_{\text{PF}}(j)^T \cdot P_{\text{step}}(j)^{-1} \cdot \Phi_{\text{PF}}(j) \\
\mathbf{D}_j^{21} &= -P_{\text{step}}(j)^{-1} \cdot \Phi_{\text{PF}}(j) \\
\mathbf{D}_j^{12} &= -\Phi_{\text{PF}}(j)^T \cdot P_{\text{step}}(j)^{-1} \\
\mathbf{D}_j^{22} &= P_{\text{step}}(j)^{-1} + \mathbf{J}_{j+1}^z,
\end{aligned}$$

donde $\Phi_{\text{PF}}(j)$ es el gradiente de la función de propagación del filtro de partículas (4.41):

$$\Phi_{\text{PF}}(j) = \begin{bmatrix} 1 & 0 & 0 & -\sin(\psi(j))\Delta r_x - \cos(\psi(j))\Delta r_y \\ 0 & 1 & 0 & \cos(\psi(j))\Delta r_x - \sin(\psi(j))\Delta r_y \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad (4.57)$$

por lo que (4.55) se puede escribir como:

$$\mathbf{J}_{j+1} = P_{\text{step}}(j)^{-1} + \mathbf{J}_{j+1}^z - P_{\text{step}}(j)^{-1} \Phi_{\text{PF}}(j) \left(\mathbf{J}_j + \Phi_{\text{PF}}(j)^T P_{\text{step}}(j)^{-1} \Phi_{\text{PF}}(j) \right)^{-1} \Phi_{\text{PF}}(j)^T P_{\text{step}}(j)^{-1}, \quad (4.58)$$

simplificando la expresión, se obtiene:

$$\mathbf{J}_{j+1} = \mathbf{J}_{j+1}^z + \left(P_{\text{step}}(j) + \Phi_{\text{PF}}(j) \cdot \mathbf{J}_j^{-1} \cdot \Phi_{\text{PF}}(j)^T \right)^{-1}. \quad (4.59)$$

Para comprobar que el filtro de partículas estima correctamente la posición de la persona se propone utilizar la señal sintética de la Sección 4.1.4.1, correspondiente a un recorrido cerrado de 10 vueltas describiendo un rectángulo redondeado y con una distancia total recorrida de aproximadamente 1 000 m.

Para la trayectoria estudiada, se compara el error cuadrático medio del método PDR (INS en un EKF con ZUPT) obtenido de una simulación de Monte Carlo, el error cuadrático medio del filtro de dos niveles basado en los desplazamientos reales de PDR y por último el mínimo del

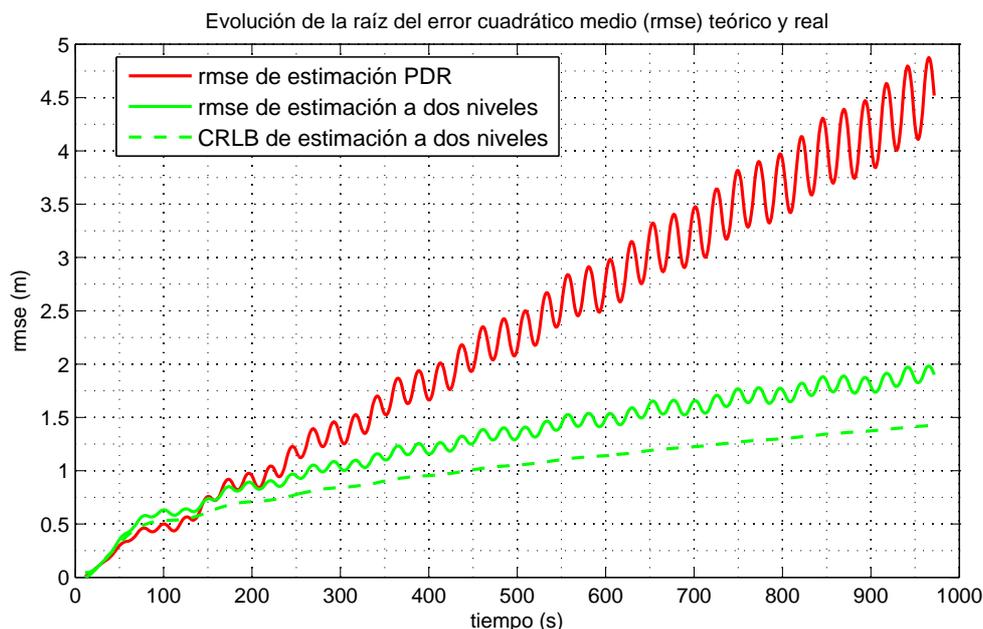


Figura 4.10: Evolución de la raíz del error cuadrático medio de PDR con propagación por INS y correcciones de ZUPT, obtenida por un método Monte Carlo (rojo), y del filtro de estimación a dos niveles propuesto, obtenida de la CRLB (verde punteada) y de la distribución observada en las partículas (verde continua).

error cuadrático medio obtenido de la CRLB. La figura 4.10 muestra la evolución con respecto al tiempo de los 3 métodos estudiados

Se puede observar que la cota obtenida (línea verde punteada) delimita el error cuadrático obtenido por las partículas en el filtro de estimación a dos niveles (línea verde continua). Adicionalmente, se observa que el error de posición crece como un caminado aleatorio (proporcional a la raíz del tiempo), por lo que difiere del error real (PDR, línea roja) con crecimiento lineal con el tiempo. Esta discrepancia se debe a la simplificación del modelo de movimiento introducida en el filtro, que subestimará el error si no se perciben medidas externas que corrijan la estimación. Aun así este modelo puede ser utilizado si se esperan medidas externas a lo largo de todo el recorrido.

4.2.4. Modelado del bias en la propagación

Como se comentó previamente el modelo de dos niveles estimando la posición y orientación tiene un crecimiento del error cuadrático medio similar a un caminado aleatorio, mientras que la estimación que utiliza como base (PDR) tiene un crecimiento del error lineal. Esto genera una subestimación del error real, si no se perciben medidas externas con frecuencia, por lo que se buscará un mejor modelo de movimiento en esos casos.

En crecimiento lineal observado en el PDR es debido a múltiples factores, pero como se comenta en [19], la mayor fuente de error en PDR, es el bias del giróscopo. Las componentes horizontales de dicho bias pueden ser estimadas con las actualizaciones de velocidad nula, pero la componente vertical no es observable con dicha medida lo que genera un error de crecimiento lineal en la orientación y por ende en la posición.

Para corregir dicho comportamiento, se propone incluir un estado adicional asociado al bias en la velocidad angular en el eje z ($\delta\psi$), por lo que el vector de estados sería $X^{(i)} = [r_x^{(i)} \ r_y^{(i)} \ r_z^{(i)} \ \psi^{(i)} \ \delta\psi]$. Las partículas se propagarían según:

$$\mathbf{X}^{(i)}(j+1) = F \cdot \mathbf{X}^{(i)}(j) + U \cdot (\Delta\mathbf{X}^{(i)}(j) + \eta_{\Delta x}) + N \cdot \eta_{\delta\psi}, \quad (4.60)$$

donde la matriz de transición F es:

$$F = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & t_{st} \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}, \quad (4.61)$$

el tiempo entre pasos es t_{st} , la matriz del desplazamiento U es:

$$U = \begin{bmatrix} C_z^e(\psi^{(i)}(j)) \\ 0_{1 \times 4} \end{bmatrix}, \quad (4.62)$$

la matriz de ruido es $N = [0; 0; 0; 0; 1]$ (este término solo maneja el ruido del bias ya que los ruidos de proceso de los otros estados son agregados en el desplazamiento) y $\eta_{\delta\psi}$ es el modelo de ruido del bias.

El bias del giróscopo es usualmente modelado como un caminado aleatorio con un coeficiente K (bias rate random walk coefficient) que mide la desviación estándar del cambio en el bias después de un segundo. Dicho coeficiente puede ser obtenido estudiando el comportamiento de la señal y el método más utilizado es el estudio de la varianza de Allan (Sección 2.1.3, en este caso $K = 1 \cdot 10^{-3} \text{ }^\circ/\sqrt{s^3}$). Debido a que la varianza del cambio incrementa linealmente con el tiempo pasado, la covarianza de $\eta_{\delta\psi}$ dependerá del tiempo del paso t_{st} de acuerdo a:

$$\sigma_{\delta\psi}^2 = K^2 \cdot t_{st} \quad (4.63)$$

Para obtener la cota CRLB sería necesario modificar el gradiente de la función de propagación del filtro de partículas ($\Phi_{PF}^e(j)$), para incluir el efecto del bias en el cálculo. El gradiente sería:

$$\Phi_{PF}(j) = \begin{bmatrix} 1 & 0 & 0 & -\sin(\psi(j))\Delta r_x - \cos(\psi(j))\Delta r_y & 0 \\ 0 & 1 & 0 & \cos(\psi(j))\Delta r_x - \sin(\psi(j))\Delta r_y & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & t_{step} \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}, \quad (4.64)$$

y modificar la covarianza del paso ($P_{step}^e(j)$) para incluir el efecto del bias en la velocidad angular:

$$P_{step}^e(j) = \begin{bmatrix} P_{step} & 0 \\ 0 & K^2 \cdot t_{step} \end{bmatrix}, \quad (4.65)$$

por lo que la matriz de información para el modelo a dos niveles con bias en la velocidad angular en el eje vertical es:

$$\mathbf{J}_{j+1} = \mathbf{J}_{j+1}^z + \left(P_{step}^e(j) + \Phi_{PF}^e(j) \cdot \mathbf{J}_j^{-1} \cdot \Phi_{PF}^e(j)^T \right)^{-1}. \quad (4.66)$$

La figura 4.11 muestra la evolución de la cota CRLB y el error cuadrático medio de las partículas para el modelo con estimación del bias y los comparará con el comportamiento del modelo PDR y el modelo sin estimación del bias.

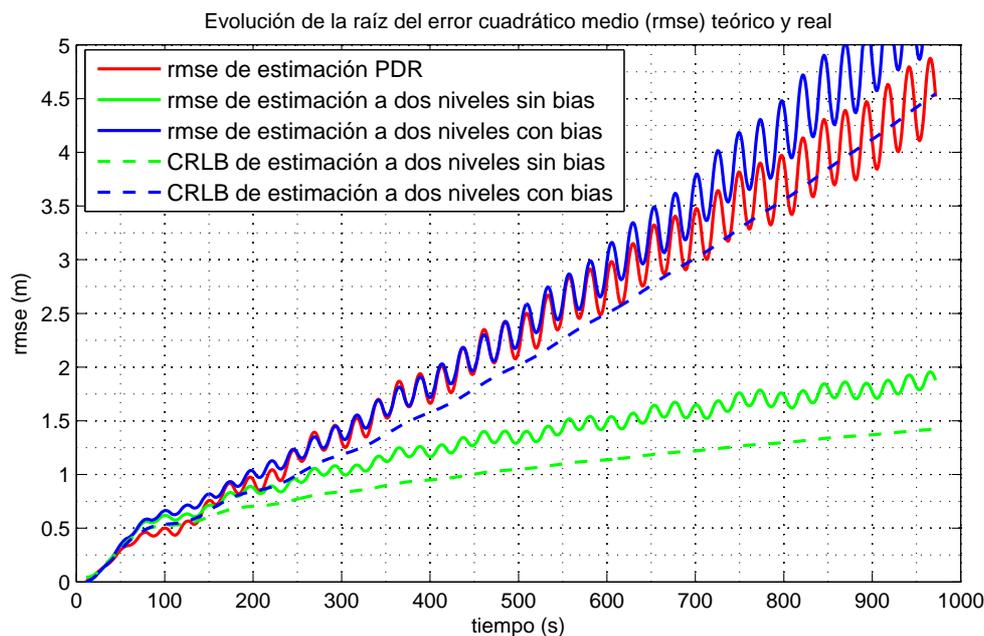


Figura 4.11: Evolución de la raíz del error cuadrático medio de PDR con propagación por INS y correcciones de ZUPT, obtenida por un método Monte Carlo (rojo), y del filtro de estimación a dos niveles propuesto con bias (azul) y sin bias (verde), obtenida de la CRLB (líneas punteadas) y de la distribución observada en las partículas (líneas continuas).

El modelo propuesto con bias permite estimar en mejor medida la dispersión esperada de las partículas, especialmente cuando no hay medidas externas durante periodos largos de tiempo y así evitando la subestimación observada en el modelo sin bias. El efecto de la introducción de estos estados será estudiado al introducir medidas externas frecuentes o ocasionales en las secciones 5.1.1 y 5.2.3.2, respectivamente.

4.3. Conclusiones

En el presente capítulo se han presentado dos esquemas de fusión de la información proveniente de PDR, el primero basado en la asunción de un límite máximo en la distancia entre dos estimaciones de posición (en particular uno inercial y uno absoluto). El segundo esquema presentado está basado en la utilización de los desplazamientos detectados en PDR para propagar un filtro de partículas donde se mejoró el modelo de desplazamiento por pasos y se estudió el modelo del error generado.

El filtro de límites introducido es un filtro no lineal que permite asociar dos puntos de estimación en el cuerpo, sin necesidad de conocer la posición relativa entre ellos. En este trabajo se propone implementarlo como una medida no lineal en un EKF, utilizando el truncado de las densidades de probabilidad de una rejilla de puntos. Para disminuir el número de estados a evaluar en la rejilla de puntos, se propone una transformación de estados que simplifica el problema a un truncado en 3 dimensiones.

Al utilizar los límites de distancia entre un sistema inercial por PDR y uno con posicionamiento absoluto se pueden observar mejoras en el posicionamiento de ambas estimaciones. En

el primero, al utilizar medidas externas se limita la deriva de la estimación, mientras que en el segundo, el modelo de movimiento de PDR ayuda a estimar en mejor medida la evolución del sistema, algo particularmente importante en ausencia de medidas externas (falta de línea de visión, fallos de detección de la medida, etc.) donde al prolongarse el tiempo sin medidas, el crecimiento lineal con la distancia del error de PDR se hace significativamente mejor que el crecimiento cúbico con el tiempo en INS.

El esquema de dos niveles utilizado está basado en un modelo introducido por otros autores en el que se utiliza el desplazamiento del PDR para propagar partículas, pero en el presente trabajo se propone un modelo adaptativo de movimiento que modifica el error estimado del paso de acuerdo a las características de éste.

El estudio de la cota inferior de Cramér-Rao de la estimación a dos niveles permite conocer el crecimiento esperado del error en el sistema. Al comparar su comportamiento con la estimación utilizando PDR exclusivamente se observa que el modelo tiene una tendencia distinta (aunque utilizable en presencia de medidas externas frecuentes), por lo se propuso la modificación de los estados modelados.

Para compensar por las diferencias en el crecimiento del error, se complementó el modelo del paso agregando un estado asociado al bias de la velocidad angular en el eje vertical, el cual no era observable en el filtro de bajo nivel, pero tiene un efecto significativo en la estimación a largo plazo. Agregando este estado se puede constatar que el modelo de dos niveles utilizando un filtro de partículas representa en mejor manera la estimación de PDR y permite la utilización de cualquier medida ya sea o no lineal o Gaussiana.

Capítulo 5

Utilización de métodos de corrección de la deriva

Utilización de métodos de corrección de la deriva

Como se ha comentado previamente, cualquier estimación basada exclusivamente en medidas inerciales tendrá únicamente una posición relativa y va a divergir con el paso del tiempo, por lo que es necesario utilizar información adicional para conocer la posición real (absoluta) y evitar su divergencia. Entre los esquemas de fusión más completos cuando no se conoce la posición y orientación inicial está el presentado en la Sección 4.2 usando un filtro de partículas, ya que permite simplificar el modelo de movimiento y evaluar múltiples hipótesis simultáneamente, sin embargo, requiere una mayor cantidad de operaciones que exigen una utilización eficiente de las medidas.

Para implementar las medidas externas en el esquema, el presente capítulo se centrará en el bloque de métodos de corrección de la deriva del esquema general de algoritmos de posicionamiento (Figuras 2.1 y 2.11). La figura 5.1 muestra los bloques a tratar en este capítulo, destacando en verde y amarillo las bloques con aportaciones. Estas son:

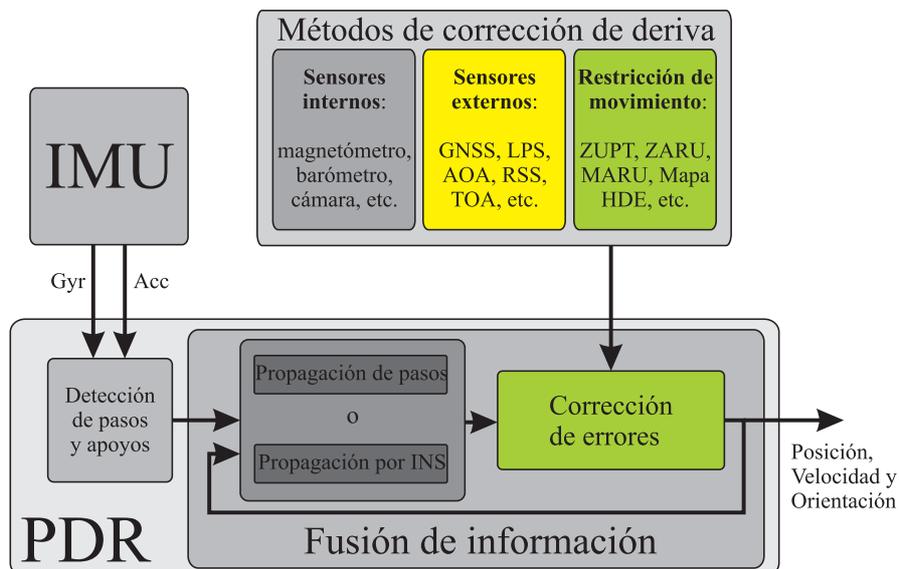


Figura 5.1: Esquema PDR destacando las aportaciones descritas en este capítulo, respecto a medidas para corrección de la deriva.

- **Utilización de sensores externos (amarillo):** Se propone estudiar la utilización de medidas externas para actualizar los pesos de las partículas en el esquema propuesto, presentando 2 casos reales utilizando medidas de distancias, y de diferencias de distancias y ángulos para corregir los errores de posición (Sección 5.1).
- **Método de corrección de errores por restricciones de movimiento (verde):** Se propone verificar los cruces de los desplazamientos de las partículas con las paredes de una forma vectorizada, agrupando de acuerdo a la habitación (o área) en la que se encuentren y solo comparando con las paredes relevantes (Sección 5.2).

- **Utilización conjunta de restricciones de movimiento (verde) y sensores externos (amarillo):** Se propone observar el efecto de inicializar la estimación utilizando las medidas iniciales de los sensores y posteriormente corregirla utilizando la información del mapa y las mediciones externas (Sección 5.3).

5.1. Utilización de medidas externas

Debido a la falta de un sistema estandarizado de posicionamiento en interiores (a diferencia de los GNSS en exteriores), los sistemas de posicionamiento en interiores utilizan una amplia gama de tecnologías, entre las que predominan diferentes señales de radio frecuencia. En la actualidad la mayoría de los edificios cuentan con sistemas de redes inalámbricas WiFi (protocolo IEEE 802.11) entre otros para facilitar la comunicación y conexión de las personas. Estas y otras redes de sensores pueden ser explotadas para permitir la localización de personas o en este caso, mejorar la estimación de un sistema basado en medidas inerciales. La figura 5.2 muestra la ubicación de los diferentes dispositivos RF instalados en el edificio A y la nave del Centro de Automática y Robótica, donde en cada punto del edificio A, se pueden recibir señales de por lo menos 3 puntos de acceso WiFi y 60 tags RFID, mientras que el sistema UWB de Ubisense esta instalado únicamente en la nave. En la presente sección explotaremos las medidas RF externas para mejorar la estimación por PDR, evaluando su efecto y mostrando el posicionamiento obtenido

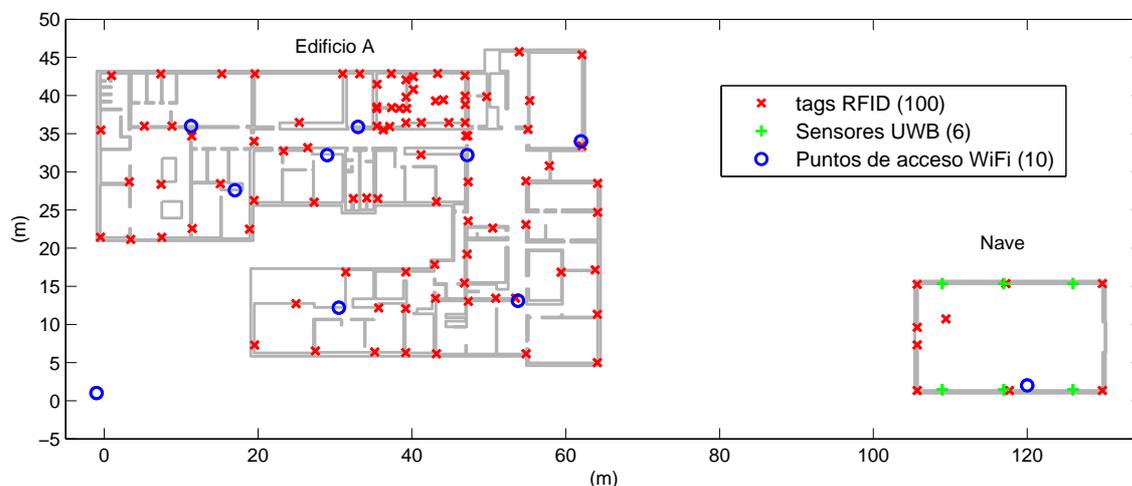


Figura 5.2: Posición de los diferentes dispositivos RF instalados en el CAR (Edificio A y nave).

5.1.1. Introducción de medidas RF

Las señales RF presentan atenuaciones y cambios de fase que están relacionados con la posición relativa entre emisor y receptor. Como se describió en las Secciones 2.4.3.3 y 2.4.3.4, estas características de la señal pueden ser utilizadas para medir la distancia (o diferencia de

distancias) y ángulo entre dispositivos. En general se puede representar un conjunto de medidas mediante un vector \mathbf{z} (de dimensiones $m \times 1$) y una función de observaciones en el instante k :

$$\mathbf{z}(k) = \mathbf{h}(\mathbf{X}(k)) + \boldsymbol{\eta}, \quad (5.1)$$

donde $\boldsymbol{\eta}$ es el ruido de la medida con covarianza R (de dimension $m \times m$).

Con esta información es posible actualizar las estimaciones de PDR en el esquema de fusión propuesto en la Sección 4.2, utilizando una corrección de los pesos de las partículas de acuerdo a la probabilidad de ocurrencia de las medidas. Si se asume un error Gaussiano, los pesos de las partículas se podrían actualizar con (4.43) y la probabilidad del vector de medidas $\mathbf{z}(k)$:

$$\begin{aligned} p(\mathbf{z}(k)|\hat{\mathbf{X}}^{(i)}(k)) &= \phi(\mathbf{z}(k); \mathbf{h}(\hat{\mathbf{X}}^{(i)}(k)), R) \\ &= \frac{1}{\sqrt{2\pi\|R\|}} \exp\left(-\frac{(\mathbf{z}(k) - \mathbf{h}(\hat{\mathbf{X}}^{(i)}(k)))^T \cdot R^{-1} \cdot (\mathbf{z}(k) - \mathbf{h}(\hat{\mathbf{X}}^{(i)}(k)))}{2}\right), \end{aligned} \quad (5.2)$$

donde R es la covarianza de la medida y el superíndice (i) es el identificador de la partícula. Utilizando esta expresión se puede estimar la posición primero propagando las partículas de acuerdo a los pasos de PDR y luego corrigiendo los pesos de acuerdo a las medidas recibidas. Este proceso es ejemplificado en la figura 5.3 donde se reciben tres tipos de medida (RSS, AOA y TDOA) que actualizan los pesos de las partículas de acuerdo a la probabilidad de la medida.

Para estimar el efecto de medidas de potencia en la señal se propone utilizar la cota inferior de Cramér-Rao propuesta en la Sección 4.2.3. La CRLB puede ser obtenida de manera recursiva utilizando la propagación de la matriz de información de Fisher (4.59):

$$\mathbf{J}_{j+1} = \mathbf{J}_{j+1}^z + \left(P_{\text{step}}(j) + \Phi_{\text{PF}}(j) \cdot \mathbf{J}_j^{-1} \cdot \Phi_{\text{PF}}(j)^T\right)^{-1}. \quad (5.3)$$

donde la información asociada a las medidas \mathbf{J}_j^z se calcula como [133]:

$$\begin{aligned} \mathbf{J}_j^z &= -\mathbb{E}\{\nabla_{\mathbf{X}(j)}[\nabla_{\mathbf{X}(j)} \log p(z(j)|\mathbf{X}(j))]^T\} \\ &= \left(\nabla_{\mathbf{X}(j)} h(\mathbf{X}(j))\right)^T \cdot R^{-1} \cdot \left(\nabla_{\mathbf{X}(j)} h(\mathbf{X}(j))\right). \end{aligned} \quad (5.4)$$

En la actualidad, la mayoría de los dispositivos inalámbricos instalados en edificios no son diseñados para localización y por ende no miden características como el tiempo de retardo o el ángulo de incidencia, pero sí la potencia de la señal recibida. La relación entre esta medida z_m (en dB) y las posiciones de la persona \mathbf{r} y el m -ésimo dispositivo \mathbf{r}_m puede aproximarse a:

$$z_m(r) = \alpha_m - 10\beta_m \log_{10}(\|\mathbf{r} - \mathbf{r}_m\|/d_0) + \eta_m, \quad (5.5)$$

donde η_m es el error de la medida con desviación estándar σ_m y media nula, α_m es la potencia recibida a una distancia d_0 (usualmente 1 m) y β_m es el exponente de pérdida, los cuales son usualmente obtenidos en una etapa de calibración. Las medidas de potencia a diferencia de las medidas de distancia tienen la desventaja de que se ven afectadas significativamente por el ambiente y la falta de línea de visión entre emisor y receptor, generando errores dependientes de la posición. A pesar de ello utilizando el modelo de (5.5) se puede aproximar el comportamiento, y si se dispone de suficientes medidas, el error promedio de múltiples sistemas tendrá una media nula.

Como se comentó previamente los dispositivos RF que más frecuentemente se encuentran en edificios son los puntos de acceso WiFi. Estos incluyen en el protocolo la medición de la potencia

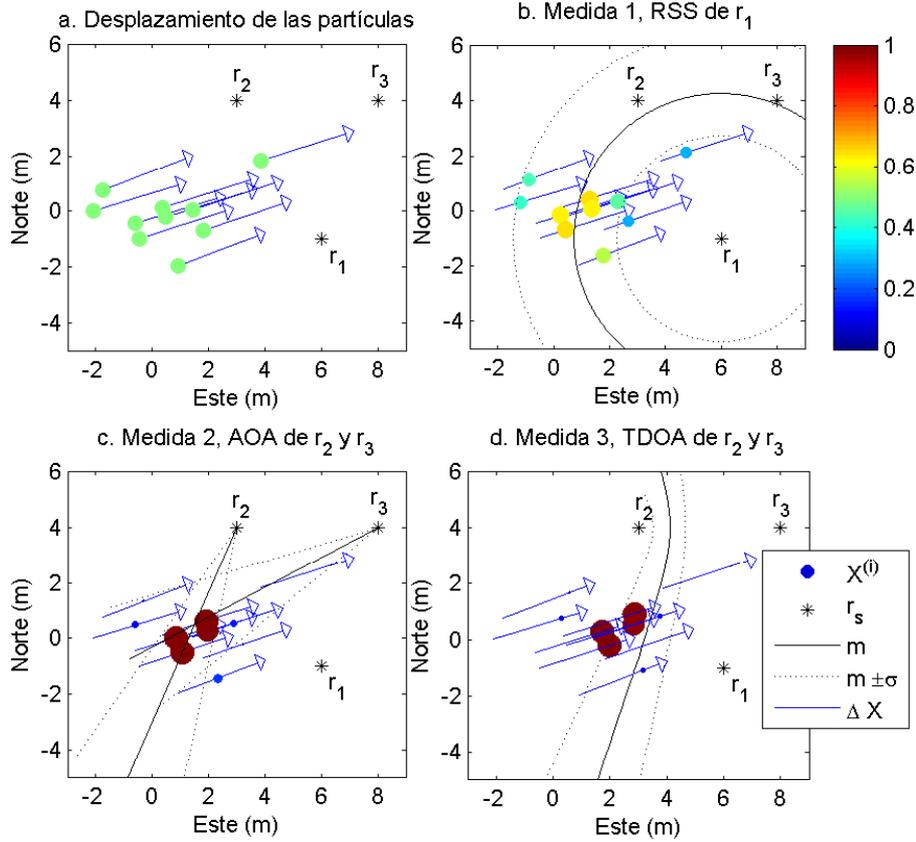


Figura 5.3: Proceso de estimación de la posición utilizando los desplazamientos obtenidos de PDR o $\Delta \mathbf{X}$ (a) y las medidas recibidas (líneas negras con leyenda m) de una baliza RSS (b), dos balizas AOA (c) y dos balizas TDOA (d). La probabilidad de las partículas está representada en el color (según la barra adjunta) y es proporcional al tamaño de éstas.

recibida, pero no el tiempo de vuelo. Sin embargo, utilizando los paquetes de comunicación es posible una estimación del tiempo de ida y vuelta (RTT - Round Trip Time-of-Flight) utilizando el hardware propuesto en [114]. Como se describe en [134] la estimación es más precisa si se utilizan estos tiempos para estimar los coeficientes α_m y β_m , y se utilizan medidas RSS con los coeficientes estimados.

Para observar el efecto de incluir las medidas externas en la estimación de PDR se propone analizar las cotas de error de los sistemas de manera independiente y fusionando su información con el filtro de partículas propuesto. Para ello, se utilizará una trayectoria basada en el recorrido mostrado en la figura 5.4, proveniente de la trayectoria sintética cerrada de [19], agregando 4 balizas para simular la potencia recibida desde esos puntos medidos cada segundo.

En el caso de medidas de potencia de la señal en dB, la matriz de información de Fisher sería:

$$\mathbf{J}_j^z = \begin{bmatrix} \sum_{m=1}^M \left(\frac{10\beta_m}{\sigma_m \|\mathbf{r}(j) - \mathbf{r}_m\| \ln(10)} \right)^2 \mathbf{u}_m \mathbf{u}_m^T & 0_{3 \times 1} \\ 0_{1 \times 3} & 0_{1 \times 1} \end{bmatrix}, \quad (5.6)$$

donde el vector $\mathbf{u}_m = (\mathbf{r}(j) - \mathbf{r}_m) / \|\mathbf{r}(j) - \mathbf{r}_m\|$ representa la dirección de la persona al m -ésimo

dispositivo RF de los M observados y $0_{i \times j}$ son matrices de ceros (de dimensiones i por j) debidos a la independencia de $z(j)$ de la orientación.

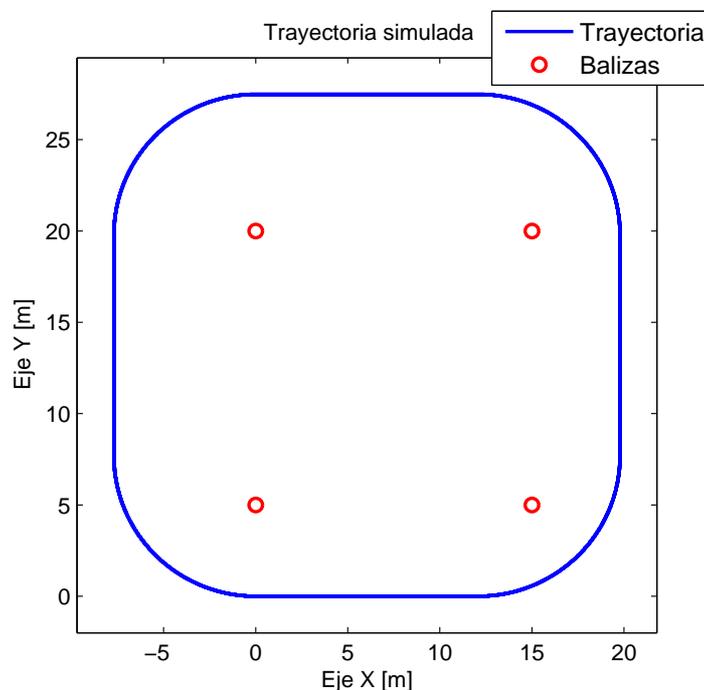


Figura 5.4: Trayectoria simulada y posición de las balizas a utilizar.

La evolución de las CRLB puede ser observada en la figura 5.5 evaluando la estimación de la posición con medidas de RSS, por propagación del PDR y fusionando ambas medidas. En los dos últimos casos se estudió también el efecto de modelar o no el bias del giróscopo.

Al analizar la figura, se puede concluir que la utilización del modelo de movimiento de PDR para mejorar las estimaciones de las medidas externas (en este caso RSS) reduce significativamente los niveles de error, de más de 3 m de RMSE en el caso de solo utilizar medidas RSS a menos de 0,4 m al fusionarlo con PDR y como es de esperarse, se pasa de un error con un crecimiento con el tiempo en PDR (aunque se conozca la posición y orientación inicial) a un error acotado en la fusión (partiendo sin información de la posición o orientación inicial).

Como se comentó previamente, debido a que la estimación de la posición es corregida frecuentemente con las medidas RSS, el error de orientación está acotado y no es necesario estimar el bias de la velocidad angular entre los estados de las partículas, ya que no afecta significativamente el nivel de error obtenido de la fusión. Para futuras simulaciones mientras se reciban mediciones absolutas con frecuencia se podrá utilizar el modelo de movimiento sin el bias de la velocidad angular.

Para comprobar la cota obtenida se propone realizar un experimento de Monte Carlo utilizando la señal sintética de la figura 5.4 con ruido grabado de una IMU MTi de XSens y se comparan las cotas obtenidas con el error cuadrático medio observado de las múltiples simulaciones.

La figura 5.6 muestra la evolución de los errores cuadráticos medios y se puede observar que al igual que en el caso de la CRLB, al utilizar el modelo de movimiento de PDR para propagar las partículas con medidas de RSS el error del sistema baja significativamente (de 4 m con RSS únicamente a cerca de 0,5 m con la fusión) a pesar de que el error real de las medidas RSS sea

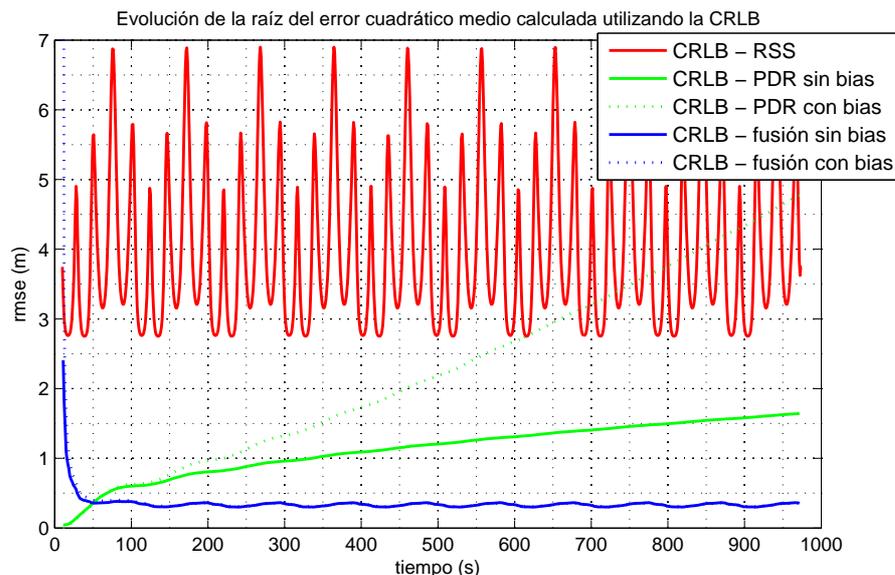


Figura 5.5: Evolución del rmse calculado a partir de las CRLB para los posicionamientos por medidas RSS, la propagación del PDR con posición y orientación inicial conocida (con y sin estimación del bias en el giróscopo), y la estimación integrando las medidas de RSS en PDR mediante el filtro de partículas (posición/orientación inicial desconocida, con y sin estimación del bias en el giróscopo).

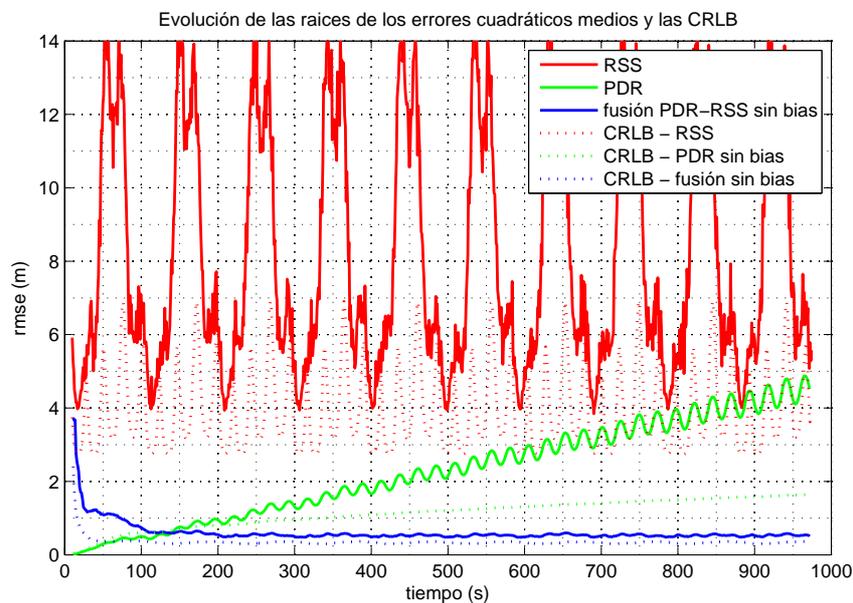


Figura 5.6: Evolución del RMSE obtenidos de experimentos de Monte Carlo para posicionamiento por medidas RSS, la propagación del PDR con posición y orientación inicial conocida, y la estimación integrando las medidas de RSS en PDR mediante el filtro de partículas (posición/orientación inicial desconocida).

mayor que la cota.

A continuación se presentan dos pruebas reales utilizando este método para integrar con PDR las medidas externas, utilizando dispositivos con medidas de balizas ZigBee y puntos de acceso WiFi [135], e integrando medidas de sistemas de posicionamiento comerciales (UWB de Ubisense) y potencia de la señal de balizas RFID.

5.1.2. Fusión de PDR con potencia de la señal y tiempo de vuelo

La mayoría de los dispositivos RF instalados en edificios actuales disponen de una medida de la potencia de la señal que suele utilizarse para seleccionar el dispositivo más cercano con el cual conectarse. Esta información es comúnmente utilizada para obtener o mejorar la posición de una persona. Sin embargo, en la mayoría de los edificios la falta de línea de visión y las posibles modificaciones en el ambiente, alteran significativamente la relación entre la distancia y la potencia de la señal recibida, por lo que es necesario utilizar otras medidas para mejorar el posicionamiento. En la presente sección se explicará el modelo utilizado para integrar las medidas de manera robusta y luego el experimento realizado.

En [134] los autores proponen integrar las medidas de tiempo de vuelo y potencia de la señal para mejorar el modelo de la medida, adaptándolo al ambiente y haciéndolo robusto ante cambios en el ambiente. El método está basado en corregir dinámicamente los exponentes de pérdida del modelo de atenuación de la señal de acuerdo a las medidas RSS y TOA.

Utilizando el modelo de atenuación de la señal (5.5) se puede obtener la relación entre las medidas RSS, obtenidas en la posición de la persona, y la posición de la baliza emisora. Esta relación depende de varios factores desconocidos, entre ellos, los exponentes de pérdida juegan un papel fundamental. Las medidas RSS del dispositivo o baliza s está asociada a la posición de la persona en el instante k de acuerdo a un modelo de la medida como:

$$z_m^{\text{RSS}}(k) = h_m(\mathbf{r}(k)) + \eta^{\text{RSS}} \quad (5.7)$$

donde $h_m()$ se obtiene de (5.5) y depende de α_m , β_m y la posición de la baliza emisora \mathbf{r}_m , y η^{RSS} es el ruido debido al desvanecimiento (fading) de la señal, asumido Gaussiano de media cero si se conoce α_m y β_m [136]. Usualmente el valor de α_m puede estimarse previamente conociendo la potencia transmitida y la ganancia de la antena independientemente de la baliza [137], pero β_m varía significativamente de acuerdo al ambiente y las condiciones de línea de visión.

Para estimar dinámicamente los exponentes de pérdidas se puede utilizar la técnica de obtención de la distancia basada en medidas RSS, explicada en [138]. Esta está basada en buscar los exponentes que maximizan un función de compatibilidad que relaciona las medidas recibidas con la posición de las balizas en rango. Sin embargo, debido a que las condiciones del camino de propagación cambian al desplazarse la persona, no es posible maximizar la función de compatibilidad de manera global, sino en conjuntos de medidas en la misma posición. Para delimitar los rangos iniciales de los exponentes se utilizan los límites heurísticos propuestos en [138] incluyendo limitaciones de acuerdo a las medidas TOA recibidas como se propone en [134]. En cada instante k se puede estimar un arreglo $\{\widehat{\beta}_m(k)\} = [\widehat{\beta}_1(k) \ \dots \ \widehat{\beta}_M(k)]^T$ de M exponentes de acuerdo a:

$$\{\widehat{\beta}_m(k)\} = \arg \max_{\{\beta_m(k)\}} C(\{\beta_m(k)\}, \{z_m(k)\}, \{\alpha_m\}, \tilde{\mathbf{r}}(k), \{\mathbf{r}_m\}), \quad \text{con } \beta_m(k)_{m=1,\dots,M} \in \Psi \quad (5.8)$$

donde Ψ es el conjunto de exponentes posibles limitados por los razonamientos heurísticos y distancias obtenidas de las medidas TOA según [134], $C()$ es la función de compatibilidad descrita

en [138], $\{z_m(k)\}$ es el conjunto de medidas RSS recibidas en el instante k , $\tilde{\mathbf{r}}(k)$ es la estimación inicial de la posición, y $\{\mathbf{r}_m\}$ es el vector de posiciones de las balizas.

Para integrar estas medidas en el filtro de partículas una vez que se han estimado los exponentes de pérdida de cada baliza, se asumen independientes las medidas y se utiliza (4.43) y (5.2). La probabilidad del conjunto de medidas se calcula según:

$$p(\{z_m(k)\}|\hat{\mathbf{r}}[k]) = \prod_{m=1}^M \phi(z_m(k); h_m(\hat{\mathbf{r}}(k)), \sigma_m) = \prod_{m=1}^M \frac{1}{\sigma_m \sqrt{2\pi}} \exp\left(-\frac{\Delta z_m(k)^2}{2\sigma_m^2}\right), \quad (5.9)$$

donde σ_m es la desviación estándar de la medida con los exponentes $\{\alpha_m, \beta_m\}$ y:

$$\Delta z_m(k) = (z_m(k) - (\alpha_m - 10\hat{\beta}_m(k) \log_{10}(\|\hat{\mathbf{r}}(k) - \mathbf{r}_m\|))). \quad (5.10)$$

Al estimar β_m en (5.8), se agregan errores que afectan el error de la medida total, por lo que la desviación estándar de la medida se debe ajustar a:

$$\sigma_m = \sqrt{\frac{\sigma_{\text{RSS}}^2}{N_{\text{RSS}}} + (10 \cdot \sigma_\beta)}, \quad (5.11)$$

donde σ_{RSS} es la desviación estándar del sensor, N_{RSS} es el número de medidas que internamente se toman por baliza en cada instante k y σ_β es el error obtenido de aproximar $\hat{\beta}_m(k)$ en (5.8).

Utilizando estas medidas los pesos de todas las partículas pueden actualizarse tras cada paso j de esta forma:

```

w' = w[j - 1]
for k > 0    s.t. (tPDR[j - 1] < tm[k] ≤ tPDR[j])
  Obtain {β̂m[k]}
  γ = (tm[k] - tPDR[j - 1]) / (tPDR[j] - tPDR[j - 1])
  for i = 1 : N
    r̂(i)[k] = r(i)[j - 1] + γ · (r(i)[j] - r(i)[j - 1])
    w'(i) = w'(i) ∏m=1M φ(zm[k]; hm(r̂(i)[k]), σm)
  end
  w' = w' / ∑i=1N w'(i)
end
w[j] = w'
```

Utilizando el esquema previamente descrito se realizaron dos experimentos en el edificio ETSIT de la universidad de Valladolid siguiendo los recorridos mostrados en la figura 5.7. Los datos fueron tomados en 2 etapas, la primera consistió en medir las señales de una IMU MTx de XSens en el pie de una persona describiendo ambos recorridos predefinidos y marcados en el suelo (8 vueltas y un total de 920 m para el recorrido WiFi, y 10 vueltas y un total de 1 020 m para el recorrido ZigBee), en ambos casos se generaba una marca temporal cada vez que se pasaba por un punto marcado en el suelo. La segunda etapa consistió en tomar las medidas RF con un ordenador en las posiciones predefinidas marcadas en el suelo y sincronizar ambas señales con las marcas temporales obtenidas. Se tomaron 50 medidas de cada emisor RF por posición.

Para tomar las medidas WiFi se utilizaron como balizas los puntos de acceso WiFi (IEEE 802.11b/g) como el mostrado en la figura 5.7, mientras que la persona a localizar lleva un adaptador IEEE 802.11b/g para portátiles capaz de medir directamente la potencia de la señal.

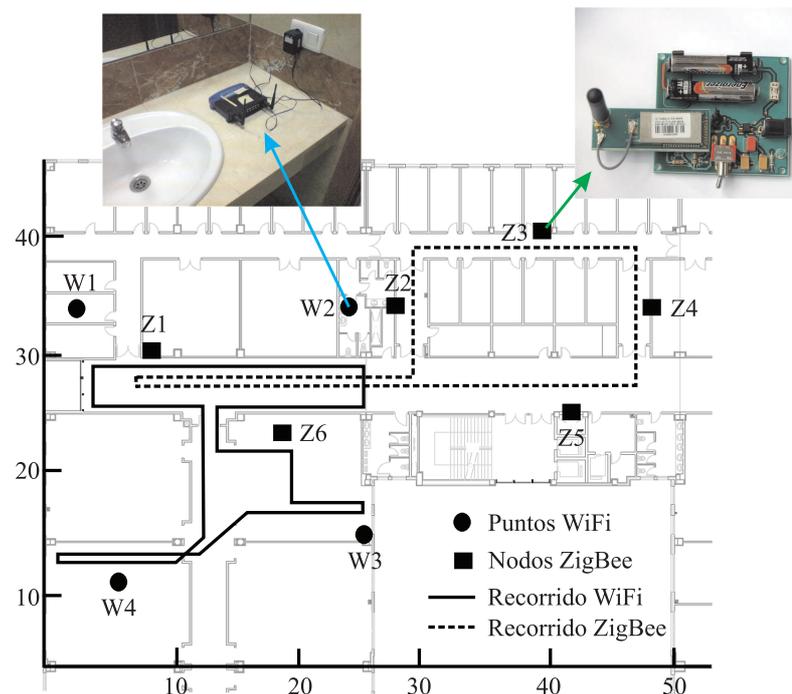


Figura 5.7: Trayectorias cerradas, repetidas 8 y 10 veces, con distancias totales recorridas de 920 m y 1020 m y utilizando dispositivos WiFi y ZigBee respectivamente. Corredores del ala Oeste del edificio ETSIT de la Universidad de Valladolid.

Los tiempos de vuelo fueron medidos enviando periódicamente paquetes Request-to-Send (RTS) y midiendo el tiempo que tardaban en recibirse los paquetes Clear-to-Send (CTS)

En el caso de las medidas ZigBee, se utilizaron seis nodos IEEE 802.15.4 (JN5148-001-M004 de NXP Inc.) como el observado en la figura 5.7. Las medidas de potencia y tiempo fueron realizadas con un módulo igual a los utilizados como balizas, pero conectado a un portátil. Los dispositivos utilizados se encargan de medir el RTT con un procedimiento similar al utilizado en WiFi, pero al ser implementado en el hardware del módulo, tiene una mayor precisión. La potencia de la señal también es registrada cada vez que se miden los tiempos. Al igual que en el caso de la medidas de señales WiFi se registraron 50 medidas RSS y RTT por cada punto de medida pero solo de los 4 nodos con mayor potencia recibida.

Las partículas fueron inicializadas con una distribución inicial Gaussiana, centrada en la posición obtenida en el método linealizado propuesto en [25], utilizando las estimaciones de las distancias basadas en las potencias de la señal. La covarianza de la distribución fue elegida de acuerdo al error cuadrático medio obtenido por las medidas en esa posición. La orientación fue inicializada uniformemente entre $-\pi$ y π radianes debido a la falta de información sobre la guiñada.

Las trayectorias obtenidas al fusionar PDR con WiFi o ZigBee se muestran en las figuras 5.8 y 5.9 respectivamente. En ambos casos se observa que la primera vuelta presenta un nivel de error mayor que las demás, esto es debido a que al no tener información de la orientación, las partículas se dispersan en todas direcciones, pero al desplazarse por el edificio, la estimación es capaz de corregir la orientación. En la segunda y posteriores vueltas, la trayectoria converge y mantiene un nivel de error limitado.

Para evaluar la distribución de los errores de posición se propone comparar las estimaciones obtenidas con las posiciones previamente marcadas en el recorrido realizado. La figura 5.10

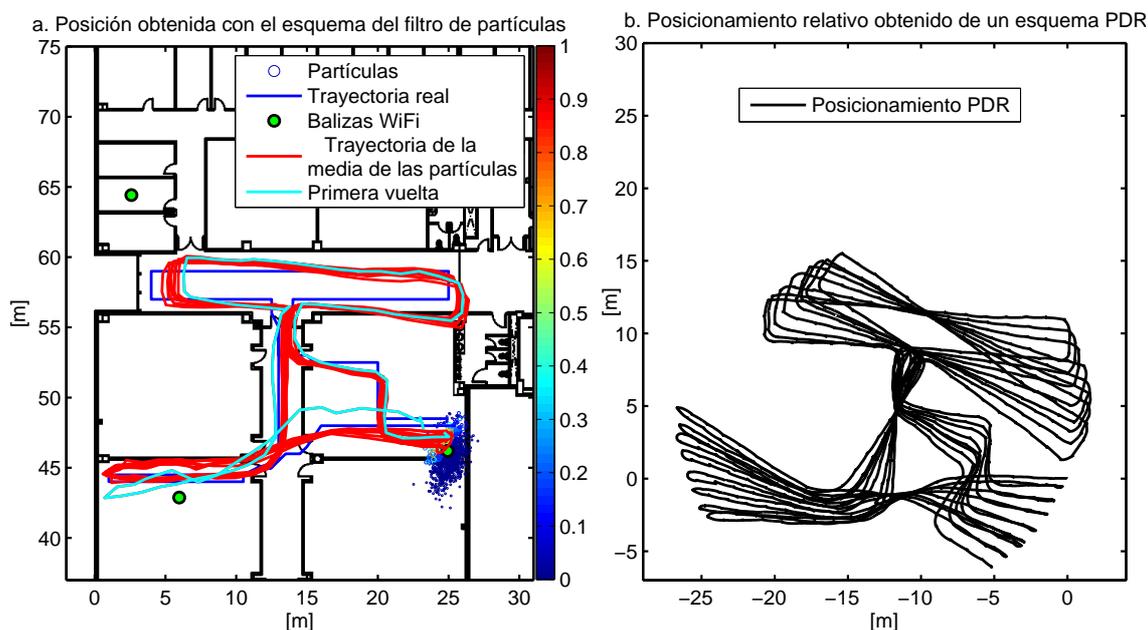


Figura 5.8: Posición de una persona en el edificio ETSIT de la UVA. a. Posición obtenida utilizando un filtro de partículas para fusionar la información de PDR y los rangos a 4 puntos de acceso WiFi (la probabilidad de las partículas es proporcional al tamaño con que se representan y el color, rojo>amarillo>verde>azul). b. Reconstrucción del posicionamiento relativo con PDR.

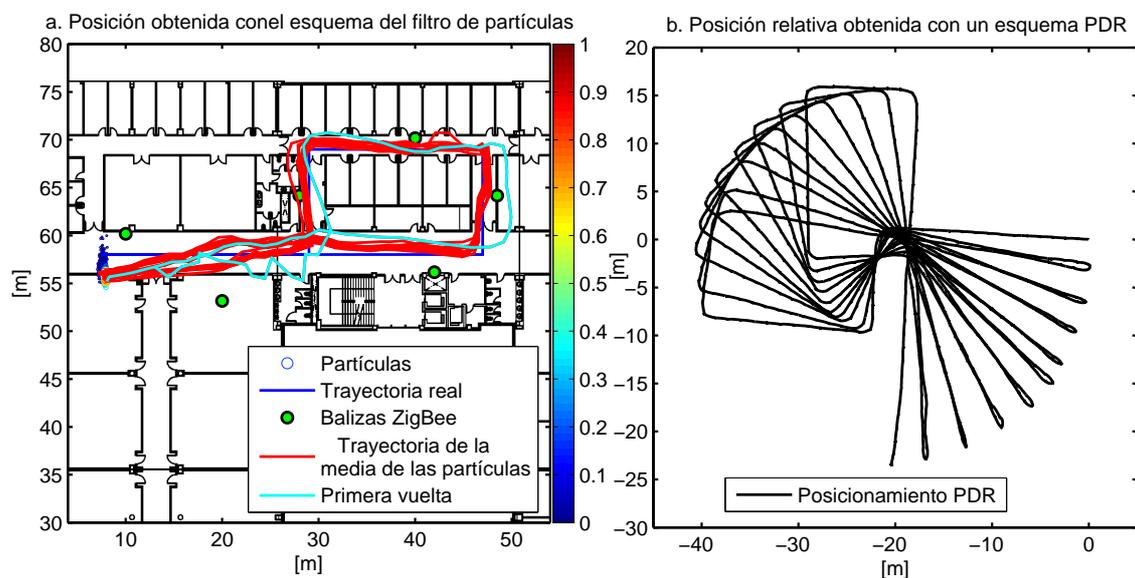


Figura 5.9: Posición de una persona en el edificio ETSIT de la UVA. a. Posición obtenida utilizando un filtro de partículas para fusionar la información de PDR y los rangos a 6 balizas ZigBee (la probabilidad de las partículas es proporcional al tamaño con que se representan y el color, rojo>amarillo>verde>azul). b. Reconstrucción del posicionamiento relativo con PDR.

muestra las funciones de distribución acumulada (CDF) para la fusión de PDR con WiFi y con ZigBee, utilizando el método de propagación propuesto en el capítulo 4.2.2. El método es comparado con sistemas LPS utilizando medidas RSS y/o TOA [134] y con la fusión utilizando el modelo de propagación con covarianza fija propuesto en [55]. Para el cómputo de las CDF se descartaron los errores durante la primera vuelta para evitar el efecto de la ambigüedad en la orientación inicial.

Se observa que el método propuesto es capaz de obtener errores inferiores a $1,75\text{ m}$ en al menos 90% de las muestras, en ambos casos para recorridos de aproximadamente $1\ 000\text{ m}$. Los niveles de error obtenidos al fusionar las medidas WiFi o ZigBee son aproximadamente la tercera parte del obtenido con el mejor LPS (sin PDR), y en ambos casos inferior al obtenido con un modelo de movimiento de covarianza constante [55]. De esta manera se puede observar claramente la mejora introducida al fusionar PDR y posicionamiento RF con un modelo adaptativo del paso.

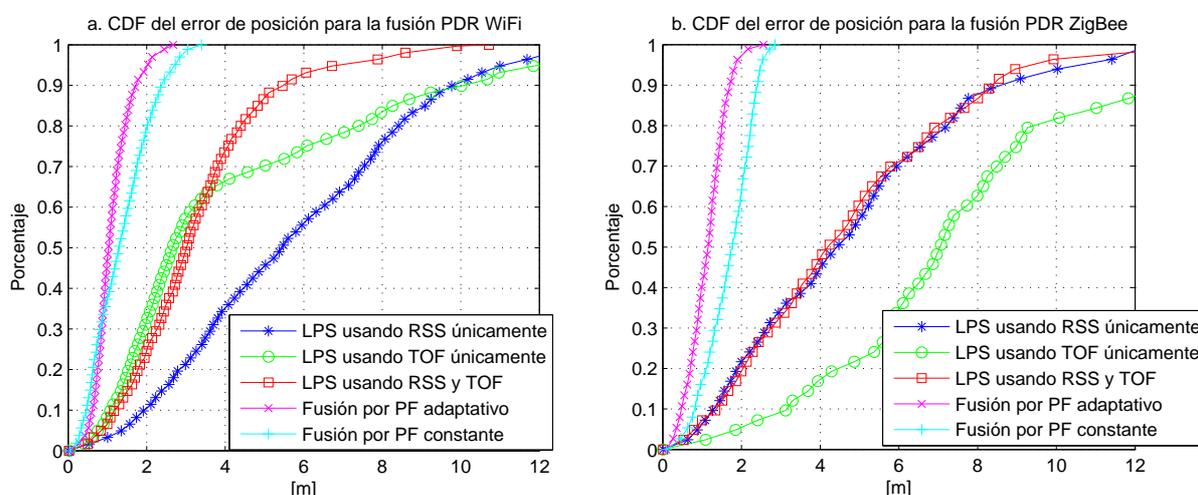


Figura 5.10: Funciones de distribución acumulada (CDF) de los error de posición utilizando WiFi (a) y ZigBee (b), comparando posicionamiento RF [134], fusión PDR RF con el modelo adaptativo del paso propuesto y con el modelo constante del paso [55].

5.1.3. Fusión de PDR con TDOA y AOA UWB, y RSS RFID

Además de los sistemas WiFi comúnmente instalados en muchos edificios, es posible encontrar en algunas instalaciones, sistemas específicos de posicionamiento como el RTLS de Ubisense basado en medidas UWB [109]. Estos sistemas ofrecen un posicionamiento con niveles de error mucho menores que los sistemas no desarrollados para localización (como WiFi), pero debido a su costo solo pueden instalarse en zonas pequeñas donde haya una buena línea de visión. En la presente sección se buscará fusionar las estimaciones de PDR con ambos sistemas (sistemas basados en RSS y sistemas especializados) y observar la mejora que introducen en la estimación.

Las medidas RSS pueden ser introducidas utilizando la actualización de pesos (4.43), la probabilidad de ocurrencia de una medida asumiendo error Gaussiano (5.2) y el modelo de observación para la potencia de la señal recibida en dB (5.5). En el presente experimento se utilizarán medidas RSS de balizas RFID, debido a su fácil de instalación y alta tasa de muestreo (están programadas para emitir una señal de identificación cada segundo).

La segunda medida a introducir proviene de un sistema de posicionamiento basado en UWB que es capaz de localizar un tag (emisor) con errores de 30 cm si todos las unidades de medida

con posición conocida (sensores según la nomenclatura de Ubisense ya que mide las señales del emisor) tienen línea de visión. Sin embargo, si varios de los sensores no tienen línea de visión con el tag, éste presenta fuertes errores no Gaussianos. El sistema basa su estimación de la posición en medidas de TDOA y AOA, y proporciona una estimación de la posición que podría ser integrada en el filtro utilizando una integración suave. Sin embargo, en el presente experimento se propone la utilización de los pseudo rangos y ángulos generando una integración fuerte que manejaría mejor los errores no Gaussianos del sistema.

Para introducir las medidas se define la medida del tiempo de vuelo donde se desconoce el desfase entre el temporizador del emisor y el de los sensores receptores (se asume que éstos últimos están sincronizados). Para un sensor i , ubicado en posición \mathbf{r}_i el tiempo de vuelo recibido será:

$$t_{\text{TDOA}_i} = \|\hat{\mathbf{r}}(k) - \mathbf{r}_i\|/c + t_0 + \eta_t, \quad (5.12)$$

donde c es la velocidad de la luz, η_t es el ruido de la medida con desviación estándar de la medida σ_t y t_0 es el tiempo entre la emisión de la señal y el comienzo del contador en los sensores. Una forma común de evitar tener que estimar t_0 es restar dos medidas de dos sensores sincronizados (i y j). Si a las medidas $i = 1, \dots, N-1$ se les resta el primer tiempo observado ($j = 0$), las medidas serían:

$$\begin{bmatrix} t_{\text{TDOA}_{1,0}} \\ \vdots \\ t_{\text{TDOA}_{N-1,0}} \end{bmatrix} = \begin{bmatrix} (\|\hat{\mathbf{r}}(k) - \mathbf{r}_1\| - \|\hat{\mathbf{r}}(k) - \mathbf{r}_0\|)/c \\ \vdots \\ (\|\hat{\mathbf{r}}(k) - \mathbf{r}_{N-1}\| - \|\hat{\mathbf{r}}(k) - \mathbf{r}_0\|)/c \end{bmatrix} + \boldsymbol{\eta}_{\text{TDOA}}. \quad (5.13)$$

donde $\boldsymbol{\eta}_{\text{TDOA}}$ es ruido Gaussiano con covarianza R_{TDOA} , cuyos elementos de la diagonal valen $2\sigma_t^2$ y el resto σ_t^2 . Utilizando esta medida las ecuaciones no dependen de t_0 , pero requieren de al menos una medida adicional para su cálculo.

Adicionalmente, el sistema UWB de Ubisense utiliza arreglos de antenas para estimar los ángulos de llegada midiendo los desfases de las señales recibidas en las múltiples antenas [107]. Utilizando este principio, los sensores son capaces de medir la elevación φ y el acimut λ de la señal recibida del tag. Utilizando la deducción de [108], los ángulos medidos desde el i -ésimo sensor UWB (u_i) están relacionados con la posición del tag $\mathbf{r}^{u_i} = [r_x^{u_i} \ r_y^{u_i} \ r_z^{u_i}]$ en el sistema de referencia del sensor/receptor UWB (indicado con el superíndice u_i) como se observa en la figura 5.11, y de acuerdo a las ecuaciones:

$$\lambda_i = \tan^{-1} \left(\frac{r_y^{u_i}}{r_x^{u_i}} \right) + \eta_\lambda, \quad (5.14)$$

$$\varphi_i = \tan^{-1} \left(\frac{r_z^{u_i}}{\sqrt{(r_x^{u_i})^2 + (r_y^{u_i})^2}} \right) + \eta_\varphi, \quad (5.15)$$

donde η_λ y η_φ son los errores de las medidas con covarianzas σ_λ^2 y σ_φ^2 respectivamente, además, \mathbf{r}^{u_i} puede obtenerse conociendo la posición del tag $\mathbf{r} = \mathbf{r}^n$ en el sistema de referencia local (superíndice n), la posición del sensor $\mathbf{r}_{u_i}^n$, y la guiñada ψ_i y cabeceo θ_i del sensor con respecto al sistema de referencia local (el sensor está instalado con un alabeo $\phi = 0$). Haciendo la transformación de coordenadas respectiva, el vector es:

$$\mathbf{r}^{u_i} = R(\theta_i, \psi_i) \cdot (\mathbf{r} - \mathbf{r}_{u_i}^n), \quad (5.16)$$

donde la rotación $R(\theta_i, \psi_i)$ es:

$$R(\theta_i, \psi_i) = \begin{bmatrix} \cos \psi_i \cos \theta_i & \sin \psi_i \cos \theta_i & -\sin \theta_i \\ -\sin \psi_i & \cos \psi_i & 0 \\ \cos \psi_i \sin \theta_i & \sin \psi_i \sin \theta_i & \cos \theta_i \end{bmatrix} \quad (5.17)$$

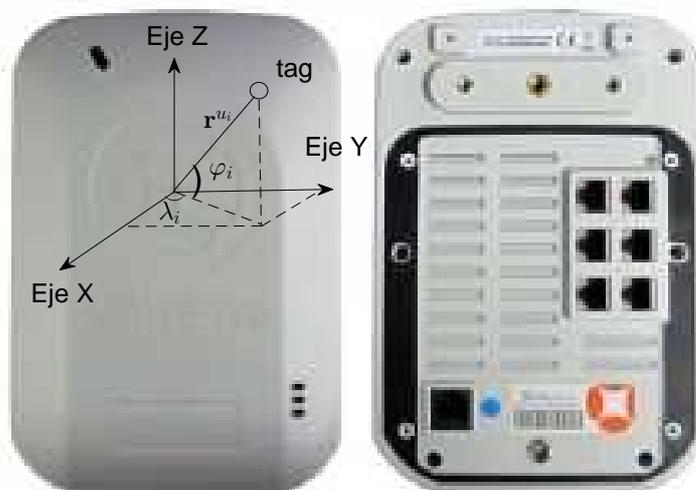


Figura 5.11: Relación de las medidas de elevación φ y acimut λ del sensor Ubisense con la posición del tag emisor en el sistema de referencias del sensor.

Las medidas propuestas en (5.5), (5.14) y (5.15) son no lineales, por lo que los esquemas propuestos en [108] y [29] utilizan linealizaciones de las medidas que pueden introducir errores en las estimaciones. En la presente sección se propone usar un filtro de partículas para manejar de una mejor manera las características no lineales de las medidas.

Como se ha descrito previamente, al utilizar un número significativo de medidas RSS con un modelo basado en la atenuación de la señal con la distancia (5.5), el sistema se hace robusto ante modificaciones en el ambiente, porque aunque algunas medidas cambien, en promedio el conjunto de los errores de todas las balizas puede asumirse Gaussiano y de media nula. Para aproximar el modelo se utilizará la calibración de [29] para balizas RFID en una oficina, donde $\alpha = -60$ dBm, $\beta = 2,3$ y $\sigma_{RSS} = 6$ dBm.

El sistema RTLS de Ubisense es capaz de estimar la posición de una persona con $\sigma_t \cdot c = 2$ m y $\sigma_\lambda = \sigma_\varphi = 18^\circ$, pero si alguna de las señales no tiene línea de visión con el tag emisor, aparecerán medidas atípicas debidas a la reflexión o difracción de la señal (en adelante, “outlier”), que podrían generar que la mayoría de los pesos de las partículas se hiciesen casi nulos y muy pocas o ninguna partícula sobreviva un remuestreo (este proceso es conocida como “particle deprivation”). En [38] se propone modelar todas las posibles fuentes de error al introducir el modelo de error, pero este modelo de error incrementaría el tiempo de cómputo de la propagación de las partículas y la complejidad del esquema. Para evitarlo se propone agregar una capa de detección y eliminación de outliers ya que esas medidas no aportan información importante a la estimación.

El dispositivo utilizado dispone de un algoritmo interno de detección de outliers, pero se observó que este no era lo suficientemente robusto para detectar todos los outliers, lo que alteraba la estimación. En el presente trabajo se propone un algoritmo de detección de outliers, basado en la compatibilidad de las medidas de posición obtenida y valor calculado de d_0 como se explica a continuación, y que fue publicado en [135].

Bajo el esquema descrito se realizó una prueba en el edificio A y la Nave del Centro de

Automática y Robótica, inicializando las partículas con una distribución aleatoria centrada en la estimación inicial de la posición obtenida de los rangos de RFID y con una dispersión proporcional al nivel de error de las medidas. En la figura 5.12 se observa el equipo utilizado para la captura de las medidas IMU, RFID y UWB. Las medidas inerciales son capturadas a 100 muestras por segundo utilizando una IMU MTi de XSens colocada en el pie de la persona, las potencias recibidas de los emisores RFID son registradas con un lector RFID M220 de RFCode y se colocó un tag UWB de Ubisense a la altura del pecho de la persona a localizar (programado para emitir un identificador cada 100 ms). Todas las medidas fueron registradas y sincronizadas en una tablet Motorola Xoom 2.



Figura 5.12: Dispositivos utilizados en el experimento. Se observa como uno de los sensores UWB no tiene línea de visión con el tag.

La persona a localizar realizó el recorrido mostrado en la figura 5.13, que inicia en la nave (6 sensores UWB y 10 tags RFID instalados en un área de $15 \times 25 \text{ m}^2$) y luego de hacer un corto trayecto en esta, se dirige al edificio A (90 tags RFID instalados en un área de $40 \times 65 \text{ m}^2$) recorriendo la planta en sentido contrario a las agujas del reloj y regresando a la nave. Esta trayectoria se repite 2 veces y se termina en el punto de inicio. Los tags o emisores RFID utilizados son el modelo M100 de RFCode y cada uno transmite un identificador una vez por segundo en la banda de 433 MHz. Los sensores UWB utilizados son el modelo Ubisense serie 7000, sincronizados entre ellos y como se observa en la figura 5.12, algunos de ellos tienen poca línea de visión debido a que están obstruidos por equipos en el área.

El sistema UWB utilizado tarda entre 50 y 60 s en detectar la emisión de los tags, por lo que en los recorridos en la nave el usuario permanece por lo menos 120 s en dicha área esperando ser detectado por el sistema.

Las trayectorias obtenidas con los diferentes sistemas pueden ser observadas en la figura 5.14. Como es de esperarse, la utilización de PDR con medidas UWB permite un posicionamiento

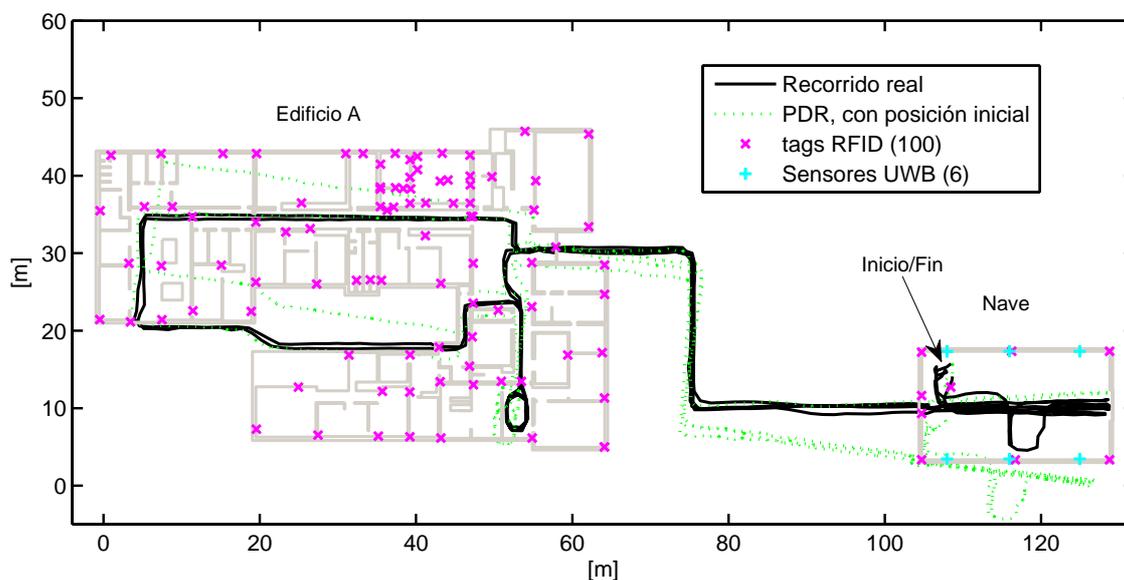


Figura 5.13: Trayectoria del experimento, ubicación de los tags RFID y sensores UWB utilizados, y ejemplo de reconstrucción de la posición utilizando solo PDR.

con un bajo nivel de error en la nave, lo que permite estimar la posición y orientación inicial rápidamente y proveer un posicionamiento preciso en el área, pero al salir del área de cobertura del sistema UWB, la estimación depende exclusivamente de PDR, por lo que se acumulan errores debidos al bias y el ruido en los sensores, que curvan la trayectoria. Al reentrar en la nave (y luego de los 60 s necesarios para que el sistema detecte los tags) la posición se corrige rápidamente debido al bajo nivel de error de las medidas de diferencias de distancias y ángulos de incidencia.

Al utilizar PDR con medidas RFID se obtiene un posicionamiento robusto a largo plazo, pero debido a la poca información en los pasos iniciales de la trayectoria, el algoritmo tarda en converger a la verdadera posición y orientación, por lo que una parte significativa de las muestras se ve afectada. Sin embargo una vez que la estimación converge se observa que la trayectoria sigue correctamente la posición de la persona.

Cuando se incluyen ambas medidas en la estimación PDR, el sistema UWB rápidamente estima la posición y orientación inicial, mientras que las medidas del sistema RFID ayudan a evitar la deriva cuando el sistema sale del área de cobertura del UWB. Para comparar los niveles de error de dichos sistemas se calcularon las CDF de las tres trayectorias que se muestran en la figura 5.15.a.

Como se observó en las trayectorias estimadas, el uso de medidas RFID y UWB ofrece el menor nivel de error (menos de 2 m de error, 90% del tiempo), principalmente porque logra estimar la posición y orientación inicial rápidamente y luego mantiene limitado el crecimiento del error fuera de la zona con cobertura UWB (la mayor parte del tiempo). Se puede notar que el uso de un sistema RSS con mayor cobertura es preferible a un sistema de menor error pero poca cobertura, ya que si la persona sale del área de cobertura del último, la estimación de su posición dependerá exclusivamente de PDR, lo que acumulará errores con el tiempo y la distancia.

Para analizar la influencia del número de tags utilizados se repitió el experimento variando

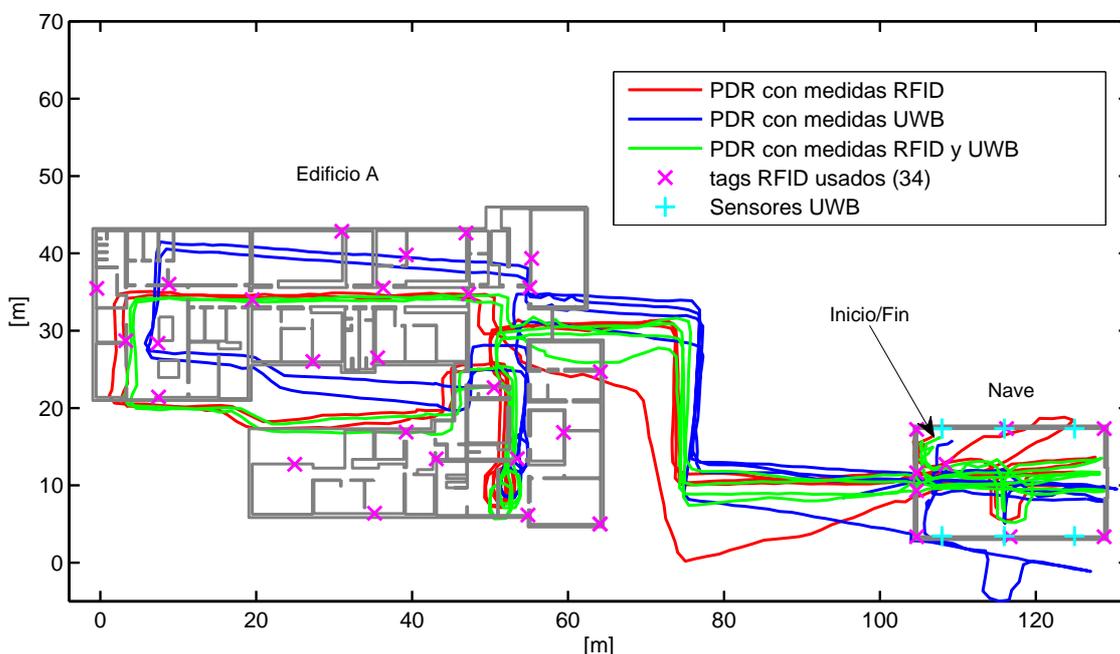


Figura 5.14: Estimación de la posición utilizando los diferentes métodos estudiados. Todos los métodos fueron inicializados sin posición u orientación inicial.

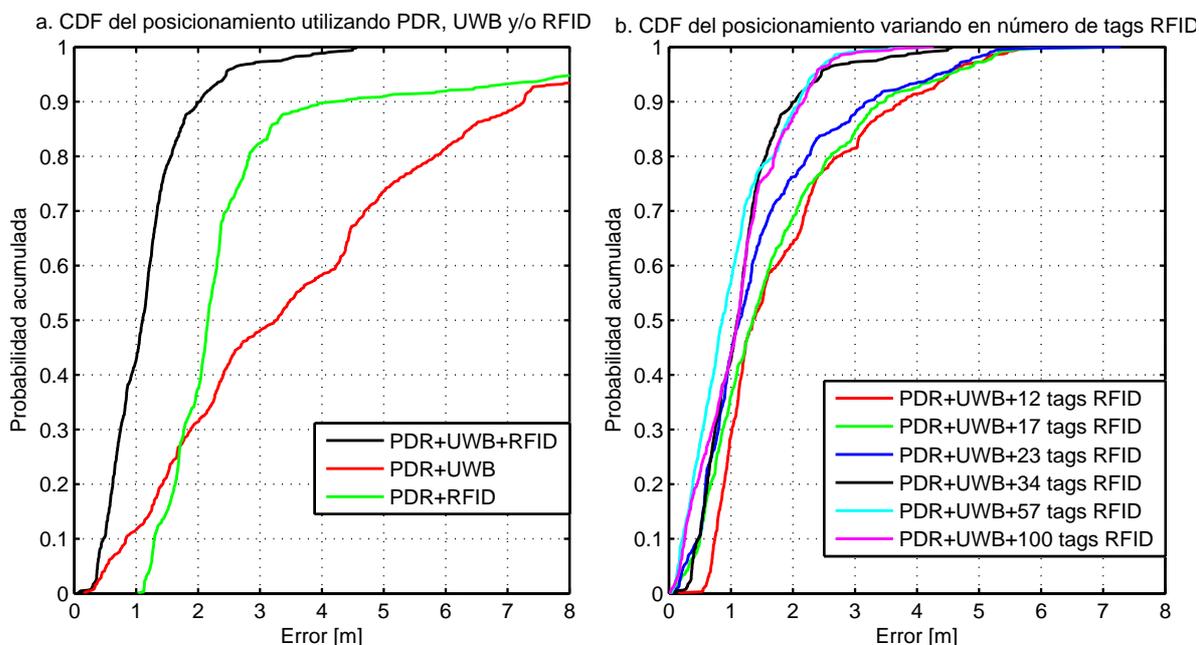


Figura 5.15: Función de probabilidad acumulada (CDF) de los métodos de estimación de la posición basados en PDR con medidas RF. a. Cambios en la CDF al incluir medidas UWB y/o RFID. b. Cambios en la CDF utilizando PDR y medidas UWB, y variando el número de tags RFID.

el número de tags RFID activados, utilizando medidas UWB y se calculó la CDF de cada combinación en la figura 5.15.b. Se puede observar que la CDF mejora a medida de que se agrega una mayor cantidad de tags, pero una vez superada la barrera de 34 emisores, se mantiene el nivel de error, lo que proporciona una idea de la densidad óptima de tags que puede usarse en posicionamiento.

5.2. Map matching

Como se ha comentado previamente, los mapas de los edificios además de ayudar a representar de mejor manera la posición de una persona permiten mejorar la estimación de la posición, ya sea ajustando las trayectorias a caminos conocidos o corrigiendo las estimaciones para que no crucen paredes. En particular, este trabajo utilizará como base el algoritmo de Map Matching introducido por Woodman en [55], donde utilizando un esquema de filtro de partículas con desplazamientos obtenidos de PDR descarta las partículas que cruzan por paredes. En esta tesis se propone la optimización de la detección de cruces por paredes utilizando operaciones matriciales y la agrupación de operaciones de acuerdo a la habitación de la partícula, lo que minimizaría el cómputo necesario y permitiría utilizar cálculos en paralelo. Esta sección está dividida en tres partes, explicando la vectorización propuesta para las operaciones de detección de cruces por paredes, luego el algoritmo para agrupar las partículas en una misma habitación y por último se presentarán pruebas de experimentos utilizando estos algoritmos.

5.2.1. Vectorización de la detección de cruces por paredes

Para incluir la información de los mapas en la estimación se utilizará un algoritmo que elimina las partículas que cruzan las paredes del mapa. El tiempo requerido para ejecutar esta operación es proporcional al producto del número de paredes con el número de partículas. Para una estructura como el edificio A del CAR (cerca de 700 segmentos de paredes), una ejecución a tiempo real en MATLAB requiere ejecutar el cálculo como operaciones matriciales (vectorización), por lo que en esta sección se plantearán las operaciones para la detección de los cruces con paredes con operaciones vectorizadas.

El algoritmo a utilizar en este trabajo está basado en la detección de intersecciones entre segmentos de líneas, mostrado en la figura 5.16 desarrollado por Goldman en [139] y que esta tesis adapta al caso bidimensional. Está basado en obtener los coeficientes $\gamma_{i,s}$ y $\lambda_{i,s}$ para los segmentos de línea \mathbf{p}^i (definido entre \mathbf{p}_1^i y \mathbf{p}_2^i) y \mathbf{l}^s (definido entre \mathbf{l}_1^s y \mathbf{l}_2^s), y el punto de intersección $I_{i,s}$. Estos puntos y coeficientes se relacionan de acuerdo a:

$$I_{i,s} = \mathbf{p}_1^i + \gamma_{i,s}(\mathbf{p}_2^i - \mathbf{p}_1^i) = \mathbf{l}_1^s + \lambda_{i,s}(\mathbf{l}_2^s - \mathbf{l}_1^s), \quad (5.18)$$

y si ambos $\gamma_{i,s}$ y $\lambda_{i,s}$, son mayores que 0 e inferiores que 1, los segmentos se interceptan. Los coeficientes se derivan de (5.18) como:

$$\gamma_{i,s} = \frac{(\mathbf{l}_1^s - \mathbf{l}_2^s)_y(\mathbf{l}_1^s - \mathbf{p}_1^i)_x - (\mathbf{l}_1^s - \mathbf{l}_2^s)_x(\mathbf{l}_1^s - \mathbf{p}_1^i)_y}{(\mathbf{l}_1^s - \mathbf{l}_2^s)_y(\mathbf{p}_2^i - \mathbf{p}_1^i)_x - (\mathbf{l}_1^s - \mathbf{l}_2^s)_x(\mathbf{p}_2^i - \mathbf{p}_1^i)_y} \quad (5.19)$$

y

$$\lambda_{i,s} = \frac{(\mathbf{p}_2^i - \mathbf{p}_1^i)_x(\mathbf{l}_1^s - \mathbf{p}_1^i)_y - (\mathbf{p}_2^i - \mathbf{p}_1^i)_y(\mathbf{l}_1^s - \mathbf{p}_1^i)_x}{(\mathbf{l}_1^s - \mathbf{l}_2^s)_y(\mathbf{p}_2^i - \mathbf{p}_1^i)_x - (\mathbf{l}_1^s - \mathbf{l}_2^s)_x(\mathbf{p}_2^i - \mathbf{p}_1^i)_y}. \quad (5.20)$$

Si se asocian estos puntos al esquema del filtro de dos niveles, los segmentos de líneas son definidos de $\mathbf{p}_1^i = \mathbf{r}^{(i)}(j)$ a $\mathbf{p}_2^i = \mathbf{r}^{(i)}(j+1)$ (el desplazamiento del paso), y de \mathbf{l}_1^s a \mathbf{l}_2^s (segmento de

línea s correspondiente a un segmento de la pared). En [140] se pone a disposición de las personas una implementación vectorizada del algoritmo, pero comprobamos que no es lo suficientemente rápida para ejecutar 100 000 partículas en nuestro edificio, por lo que en esta tesis se propone evaluar otras mejoras al algoritmo.

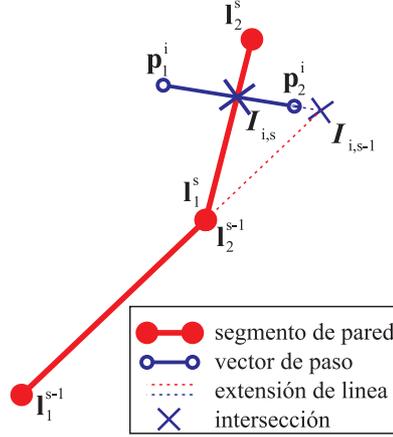


Figura 5.16: Ejemplo de detección de intersecciones entre segmentos de líneas. Los puntos $I_{i,s}$ y $I_{i,s-1}$ marcan las posibles intersecciones entre el paso p^i y los segmentos de paredes l^s y l^{s-1} , respectivamente. Si $I_{i,s}$ se encuentra en el segmento definido por cada par de puntos, los valores de los coeficientes $\gamma_{i,s}$ y $\lambda_{i,s}$ de (5.18) están comprendidos entre 0 y 1. Las líneas punteadas representan la extensión de los segmentos de línea a las posibles intersecciones.

Se propone verificar todas intersecciones con paredes utilizando operaciones de matrices. Para facilitar el acceso a las partículas de una habitación específica, se agregará un estado adicional $\mathbf{X}_6 = g$, siguiendo el esquema de Woodman [55], el cual especificará en que habitación se encuentra la partícula. El nuevo vector de estados para la partícula i , será

$$\mathbf{X}^{(i)} = [r_x^{(i)} \quad r_y^{(i)} \quad r_z^{(i)} \quad \theta^{(i)} \quad \delta\dot{\theta}^{(i)} \quad g^{(i)}]^T. \quad (5.21)$$

Si se desea evaluar el grupo de partículas en la habitación g_0 , se define el subconjunto de N_v partículas $V = \{v_1, \dots, v_{N_v}\}$, tal que $\mathbf{X}_6^{(v_p)} = g_0$ (se encuentran en la habitación), con $p = 1, \dots, N_v$. Para representar las diferencias $(\mathbf{p}_2^i - \mathbf{p}_1^i)_x$ y $(\mathbf{p}_2^i - \mathbf{p}_1^i)_y$ como vectores fila con los elementos de V , se agruparán como

$$\Delta P_x = [r_x^{v_1}(j+1) - r_x^{v_1}(j) \quad \dots \quad r_x^{v_{N_v}}(j+1) - r_x^{v_{N_v}}(j)], \quad (5.22)$$

$$\Delta P_y = [r_y^{v_1}(j+1) - r_y^{v_1}(j) \quad \dots \quad r_y^{v_{N_v}}(j+1) - r_y^{v_{N_v}}(j)], \quad (5.23)$$

cada una de tamaño $1 \times N_v$. El conjunto de los segmentos que definen una habitación g_0 es $S_g = \{s_1, \dots, s_{N_g}\}$, con los que de manera similar a los desplazamientos, se pueden construir arreglos asociados a las diferencias $(\mathbf{l}_1^s - \mathbf{l}_2^s)_x$ y $(\mathbf{l}_1^s - \mathbf{l}_2^s)_y$, que escritos como vectores columnas son:

$$\Delta L_x = [(\mathbf{l}_1^{s_1} - \mathbf{l}_2^{s_1})_x \quad \dots \quad (\mathbf{l}_1^{s_{N_g}} - \mathbf{l}_2^{s_{N_g}})_x]^T, \quad (5.24)$$

$$\Delta L_y = [(\mathbf{l}_1^{s_1} - \mathbf{l}_2^{s_1})_y \quad \dots \quad (\mathbf{l}_1^{s_{N_g}} - \mathbf{l}_2^{s_{N_g}})_y]^T, \quad (5.25)$$

respectivamente, cada uno de tamaño $N_g \times 1$.

Para acelerar las operaciones se predefinirán versiones extendidas (superíndice e) de los

vectores fila y columna como:

$$\Delta P_x^e = \left[\begin{array}{c} \Delta P_x \\ \vdots \\ \Delta P_x \end{array} \right] \left. \vphantom{\begin{array}{c} \Delta P_x \\ \vdots \\ \Delta P_x \end{array}} \right\} N_g \text{ veces}, \quad (5.26)$$

$$\Delta P_y^e = \left[\begin{array}{c} \Delta P_y \\ \vdots \\ \Delta P_y \end{array} \right] \left. \vphantom{\begin{array}{c} \Delta P_y \\ \vdots \\ \Delta P_y \end{array}} \right\} N_g \text{ veces}, \quad (5.27)$$

$$\Delta L_x^e = \underbrace{[\Delta L_x \quad \dots \quad \Delta L_x]}_{N_v \text{ veces}}, \quad (5.28)$$

$$\Delta L_y^e = \underbrace{[\Delta L_y \quad \dots \quad \Delta L_y]}_{N_v \text{ veces}}, \quad (5.29)$$

cada uno de dimensiones $N_g \times N_v$. Por último se definen las matrices LP_x y LP_y , de diferencias cruzadas, como:

$$LP_x = \begin{bmatrix} (\mathbf{l}_1^{s_1} - \mathbf{p}_1^{v_1})_x & \dots & (\mathbf{l}_1^{s_{N_g}} - \mathbf{p}_1^{v_{N_v}})_x \\ \vdots & \ddots & \vdots \\ (\mathbf{l}_1^{s_{N_g}} - \mathbf{p}_1^{v_1})_x & \dots & (\mathbf{l}_1^{s_{N_g}} - \mathbf{p}_1^{v_{N_v}})_x \end{bmatrix}, \quad (5.30)$$

$$LP_y = \begin{bmatrix} (\mathbf{l}_1^{s_1} - \mathbf{p}_1^{v_1})_y & \dots & (\mathbf{l}_1^{s_1} - \mathbf{p}_1^{v_{N_v}})_y \\ \vdots & \ddots & \vdots \\ (\mathbf{l}_1^{s_{N_g}} - \mathbf{p}_1^{v_1})_y & \dots & (\mathbf{l}_1^{s_{N_g}} - \mathbf{p}_1^{v_{N_v}})_y \end{bmatrix} \quad (5.31)$$

Utilizando estas matrices los coeficientes pueden ser calculados como:

$$\Gamma = \frac{\Delta L_y^e \cdot LP_x - \Delta L_x^e \cdot LP_y}{\Delta L_y^e \cdot \Delta P_x^e - \Delta L_x^e \cdot \Delta P_y^e}, \quad (5.32)$$

$$\Lambda = \frac{\Delta P_x^e \cdot LP_y - \Delta P_y^e \cdot LP_x}{\Delta L_y^e \cdot \Delta P_x^e - \Delta L_x^e \cdot \Delta P_y^e}, \quad (5.33)$$

donde la división y la multiplicación son realizados elemento por elemento (operadores \cdot y \cdot en MATLAB). Por último las intersecciones pueden ser detectadas usando la siguiente operación lógica:

$$\text{Cross} = (\Gamma > 0 \text{ AND } \Gamma < 1) \text{ AND } (\Lambda > 0 \text{ AND } \Lambda < 1), \quad (5.34)$$

donde el elemento $\text{Cross}_{s,v}$ es verdadero si el segmento s y el paso de la partícula v se interceptan, o falso si no se interceptaron. Adicionalmente los valores de la columna v de Γ se pueden utilizar para conocer en que orden fueron interceptados los segmentos de la habitación por una misma partícula. Si se desea conocer la primera intersección es necesario buscar el menor valor de la columna v , tal que $\text{Cross}_{s,v} = \text{TRUE}$. Este tipo de operaciones están optimizadas para MATLAB, pero si se desea utilizar otro lenguaje de programación se pueden utilizar múltiples librerías de operaciones de matrices, lo que permitiría acelerar el proceso de detección de intersecciones.

5.2.2. Grupos de partículas y estructura del mapa

Utilizando operaciones vectoriales como las propuestas en la sección anterior se puede utilizar map matching en edificios simples o pequeños. Sin embargo a medida de que se utiliza en edificios más grandes o el área a estudiar es mayor, el tiempo de cómputo aumenta y se hace

no escalable. Para hacer escalable el algoritmo, Woodman [55] propuso evaluar los cruces solo con las paredes cercanas a cada partícula, en partículas aquellas de la misma habitación o en caso de cruzar puertas las habitaciones conectadas. Este tipo de algoritmo evaluando las paredes de cada partícula es ineficiente en MATLAB, por lo que en esta tesis se propone agrupar las partículas de acuerdo a la habitación y ejecutar las comparaciones de una manera vectorizada. Para ello, se propone agrupar las paredes de un edificio en una estructura de datos tipo árbol para un rápido acceso a las paredes de un edificio. En esta sección se explicará la estructura de datos propuesta y el algoritmo para detectar los cruces con paredes y obtener la habitación de las partículas de manera vectorizada.

Si se dispone de un grupo de partículas en una habitación, éstas solo podrán mantenerse en la habitación, interceptar las paredes de la habitación o pasar a las habitaciones contiguas, en el primer caso se mantienen las partículas en la misma habitación, en el segundo se descartarán las partículas, pero en el último será necesario evaluar las paredes o cruces a nuevas habitaciones de la segunda habitación. Debido a que las partículas pueden estar distribuidas en cualquier posición/orientación dentro de la habitación, es necesario evaluar cada uno de los posibles escenarios y obtener los subgrupos de partículas que se mantienen en la habitación, chocan con paredes y van a cada una de las posibles habitaciones conectadas. Una vez en la habitación conectada se repite el proceso. Esta forma de evaluar posibles escenarios requiere una estructura jerárquica (RoomStructure), basada en un arreglo de habitaciones como la observada en la figura 5.17. Cada habitación debe incluir por lo menos un número de habitación, un arreglo con los segmentos de la habitación (segments), un arreglo de conexiones (connections) de cada uno de los segmentos, y una sub habitación (subRoom) similar al elemento habitación, pero con un conjunto limitado de elementos definido por los segmentos y habitaciones alcanzables desde la habitación original en un paso. Esta estructura de datos se construye como un árbol de datos redundante donde las ramas principales son cada una de las habitaciones del edificio y las ramas secundarias de éstas son copias reducidas de las habitaciones principales pero solo con los elementos al alcance desde la habitación de la rama principal.

El arreglo de segmentos de la habitación es un conjunto de vectores de segmentos de línea l^s , cada uno escrito como una concatenación de 2 puntos l_1^s y l_2^s y donde la unión de los segmentos de la habitación definen un polígono cerrado. Los segmentos son clasificados como no cruzables (paredes u obstrucciones) o cruzables (puertas o segmentos que dividen dos habitaciones o zonas) y por cada segmento habrá un elemento en el arreglo de conexiones que indicara si el elemento es no cruzable (valor 0) o cruzable (indicando el número de habitación a la que conecta). Por cada segmento cruzable se define un elemento subRoom como se observa en la figura 5.17, pero solo se incluirán los segmentos de línea que puedan cruzarse al dar un paso (con una distancia máxima predefinida) desde la habitación original y sin encontrar otro segmento previamente. Se ha observado que la distancia típica de un paso (distancia entre dos apoyos consecutivos del mismo pie) es alrededor 1.2 m, por lo que si se asumen dos pasos largos con un fallo de detección de apoyo en el medio, la distancia máxima se aproxima a 3 m.

Para obtener los elementos al alcance desde una habitación se realiza una simulación previa en la que se trazan múltiples pasos con orientación aleatoria desde los segmentos cruzables de una habitación y con una longitud equivalente a la distancia máxima. Los segmentos a incluir en el elemento subRoom serán aquellos correspondientes a los primeros cruces de estos pasos y si se encuentra un segmento cruzable se agregará un nuevo elemento subRoom en el subRoom actual indicando los segmentos alcanzables desde la habitación original. Debido a que el alcance máximo está limitado a 3 m hemos observado que en el CAR solo se pueden alcanzar 2 habitaciones más luego de salir de una, por lo que el árbol utilizado solo tendrá 3 niveles (1 RoomStructure y 2 subRoom), sin embargo si alguna estructura lo requiere el árbol puede ser expandido más.

Con esta estructura definida solo queda recorrer cada posible habitación y posible cruce con cada grupo de partículas, según el siguiente pseudocódigo:

```

newUsedRooms=void;

FOR room1= all the roomsWithParticles
  subset1=particles with ( $X_6==\text{room1}$ );
  selectedRoom1=RoomStructure(room1);
  segments1=selectedRoom1.segments;
  connections1=selectedRoom1.connections;
  crossings1=EvaluateCrossings(subset1,segments1);
  IF at least a particle did not cross a segment
    newUsedRooms  $\leftarrow$  room1;
  ENDIF
  particlesToKill=particles crossing a wall;
  set  $X_6$  of particlesToKill to 0;
  FOR room2=possible connections in connections1
    subset2=particles that crossed to room2
    selectedRoom2=selectedRoom1.subRoom(room2);
    segments2=selectedRoom2.segments;
    connections2=selectedRoom2.connections;
    crossings2=EvaluateCrossings(subset2,segments2);
    IF at least a particle did not cross a new segment
      newUsedRooms  $\leftarrow$  room2;
      set  $X_6$  of particles not crossing to room2
    ENDIF
    particlesToKill=particles crossing a wall;
    set  $X_6$  of particlesToKill to 0;
    FOR room3=possible connections in connections2
      subset3=particles that crossed to room3
      selectedRoom3=selectedRoom2.subRoom(room3);
      segments3=selectedRoom3.segments;
      connections3=selectedRoom3.connections;
      crossings3=EvaluateCrossings(subset3,segments3);
      IF at least a particle did not cross a segment
        newUsedRooms  $\leftarrow$  room3;
        set  $X_6$  of particles not crossing to room3
      ENDIF
      particlesToKill=particles crossing a wall;
      set  $X_6$  of particlesToKill to 0;
    ENDFOR
  ENDFOR
ENDFOR

roomsWithParticles=newUsedRooms;
set weight of particles with ( $X_6==0$ ) to 0;

```

El código presentado está preparado para manejar cruces de hasta 3 habitaciones en un solo paso, pero si la arquitectura del edificio lo requiere (lo cual es muy poco probable en la práctica habitual), se puede modificar para albergar más niveles.

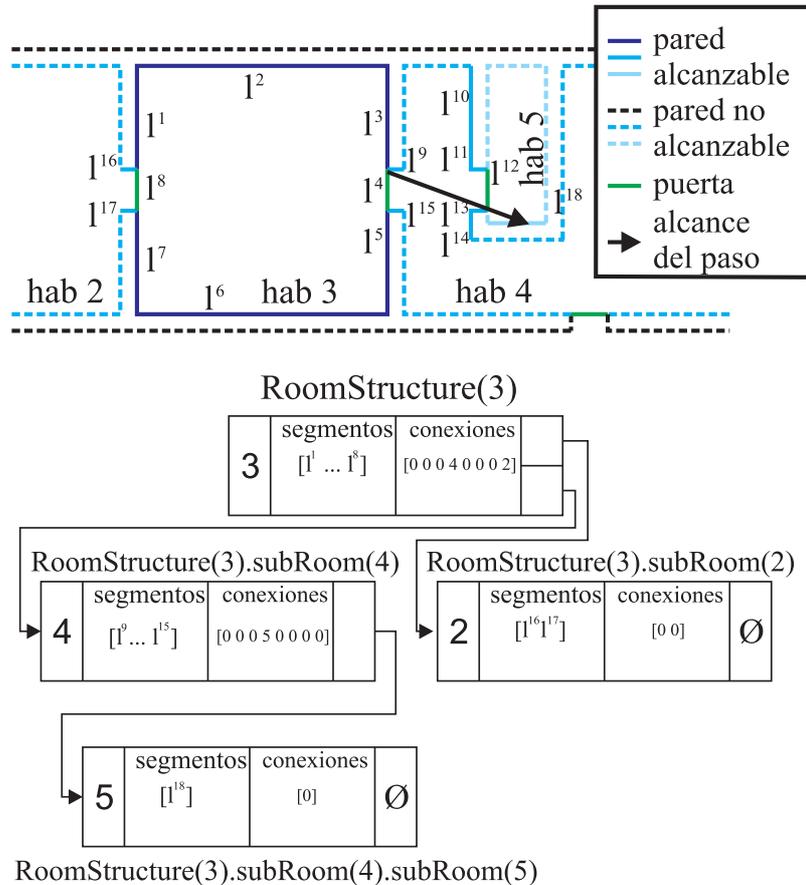


Figura 5.17: Ejemplo del estructura del mapa utilizado y árbol de datos para representar las paredes de la habitación 3 y sus conexiones.

5.2.3. Pruebas realizadas

En la presente sección se evaluarán diferentes aspectos del algoritmo de map matching. Las pruebas se realizaron en el edificio A del Centro de Automática y Robótica, un edificio sin simetrías estructurales significativas y con oficinas de diferentes tamaños como puede ser observado en la figura 5.18. El edificio tiene un área aproximada de $66 \text{ m} \times 42,5 \text{ m}$. Para las pruebas se utilizó una IMU MTi de XSens colocada en el pie derecho de la persona a localizar, con esta se registraron 100 muestras por segundo de las aceleraciones y velocidades angulares.

Se proponen tres experimentos. En el primero se buscará comprobar el correcto funcionamiento del algoritmo de map matching, localizando una persona únicamente con PDR y el mapa, pero sin conocer la posición u orientación inicial. En segundo experimento se buscará observar el efecto del bias del giróscopo sobre la estimación, específicamente en recorridos largos sin muchas correcciones. Por último, se buscará comparar los tiempos de cómputo del algoritmo con otras implementaciones.

5.2.3.1. Autolocalización con PDR y mapas

Para probar el posicionamiento utilizando únicamente Map matching con el modelo de movimiento de PDR se propuso realizar el recorrido mostrado en la figura 5.18, que consta de 2

vueltas en contra de las agujas del reloj iniciada en la sala de entrada, recorriendo los pasillos principales del edificio, entrando en algunas oficinas y volviendo a la posición inicial. Debido a que la estimación no conoce la posición ni orientación inicial, las partículas del filtro fueron distribuidas aleatoriamente en toda el área de estudio y con una orientación inicial uniformemente distribuida entre $-\pi$ y π radianes.

Debido a la manera en que se aplica la corrección de los mapas, penalizando las partículas que cruzan paredes, cualquier partícula que logre salir del edificio, no encontrará paredes que la eliminen, por lo que serán recompensadas con cada remuestreo, mientras que las partículas dentro del edificio, serán cada vez menos. Para evitar estas hipótesis que consumirán una parte significativa de los cálculos necesarios se pueden aplicar múltiples técnicas, pero debido a que en este experimento solamente se quiere comprobar el correcto funcionamiento del algoritmo, se agregará una región equivalente a una pared invisible que delimitará el edificio.

Como se observa en la figura 5.18, para la trayectoria descrita, el algoritmo es capaz de estimar la posición de la persona luego de 100 pasos (150 s), aún sin conocer la posición o orientación inicial. El número de pasos necesarios para obtener la posición correcta variará de acuerdo a la simetría del edificio y lo característico que sea la trayectoria (trayectorias más distintivas serán identificadas antes), sin embargo, como se mencionó previamente, en este experimento solo se buscará verificar el correcto funcionamiento del algoritmo.

Map matching permite estimar la posición real, sin la necesidad de medidas externas absolutas, por lo que puede utilizarse en situaciones donde no se puede desplegar infraestructura, pero se conoce el mapa de la zona a estudiar. Como se observa en la figura 5.19, el algoritmo tiene niveles de error inferiores al metro comparado con utilizar medidas RSS de balizas RFID que tiene niveles de error entre 1 y 2 metros. Sin embargo la utilización de map matching tiene el inconveniente de que requiere un mayor tiempo de convergencia por lo que se recomienda acelerar el proceso utilizando otras medidas.

5.2.3.2. Efecto del bias de la velocidad angular en la estimación en Map matching

Como se ha comentado previamente, el bias en la velocidad angular de una estimación tiene un efecto a largo plazo, que medidas constantes como el RSS de señales RFID pueden hacer no perceptible, sin embargo, medidas como map matching aprovechan en mejor medida el tener una mejor estimación del bias debido a que dependen en gran medida del modelo de movimiento. En general, el efecto del bias en la velocidad angular se ve apantallado cuando la persona recorre pasillos estrechos, pues estos generan correcciones constantes de la deriva, pero en espacios exteriores o áreas amplias donde el usuario pasa mucho tiempo sin correcciones de las paredes (museos, naves, etc.), es necesaria una correcta estimación del crecimiento del error de orientación y por ende del bias de la velocidad angular.

Para evaluar el efecto de incluir el bias de la velocidad angular entre los estados, se propone utilizar un recorrido con un tramo fuera del edificio, donde la estimación dependerá únicamente de PDR y la estimación del error que propone el filtro de partículas. Esta trayectoria puede ser observada en la figura 5.20, donde la persona a ubicar inicia su recorrido en una oficina del edificio y luego de un corto trayecto que permite estimar su posición, sale al área exterior (donde la estimación depende exclusivamente de PDR) y recorre aproximadamente 120 m para entrar en el lado opuesto del edificio, el trayecto es repetido 3 veces.

Se puede observar que en un principio ambas nubes de partículas se comportan de manera similar, pero a medida que la persona se desplaza la nube que estima el bias crece ligeramente más que la que no. Al reentrar al edificio una gran parte de las partículas es eliminada debido al

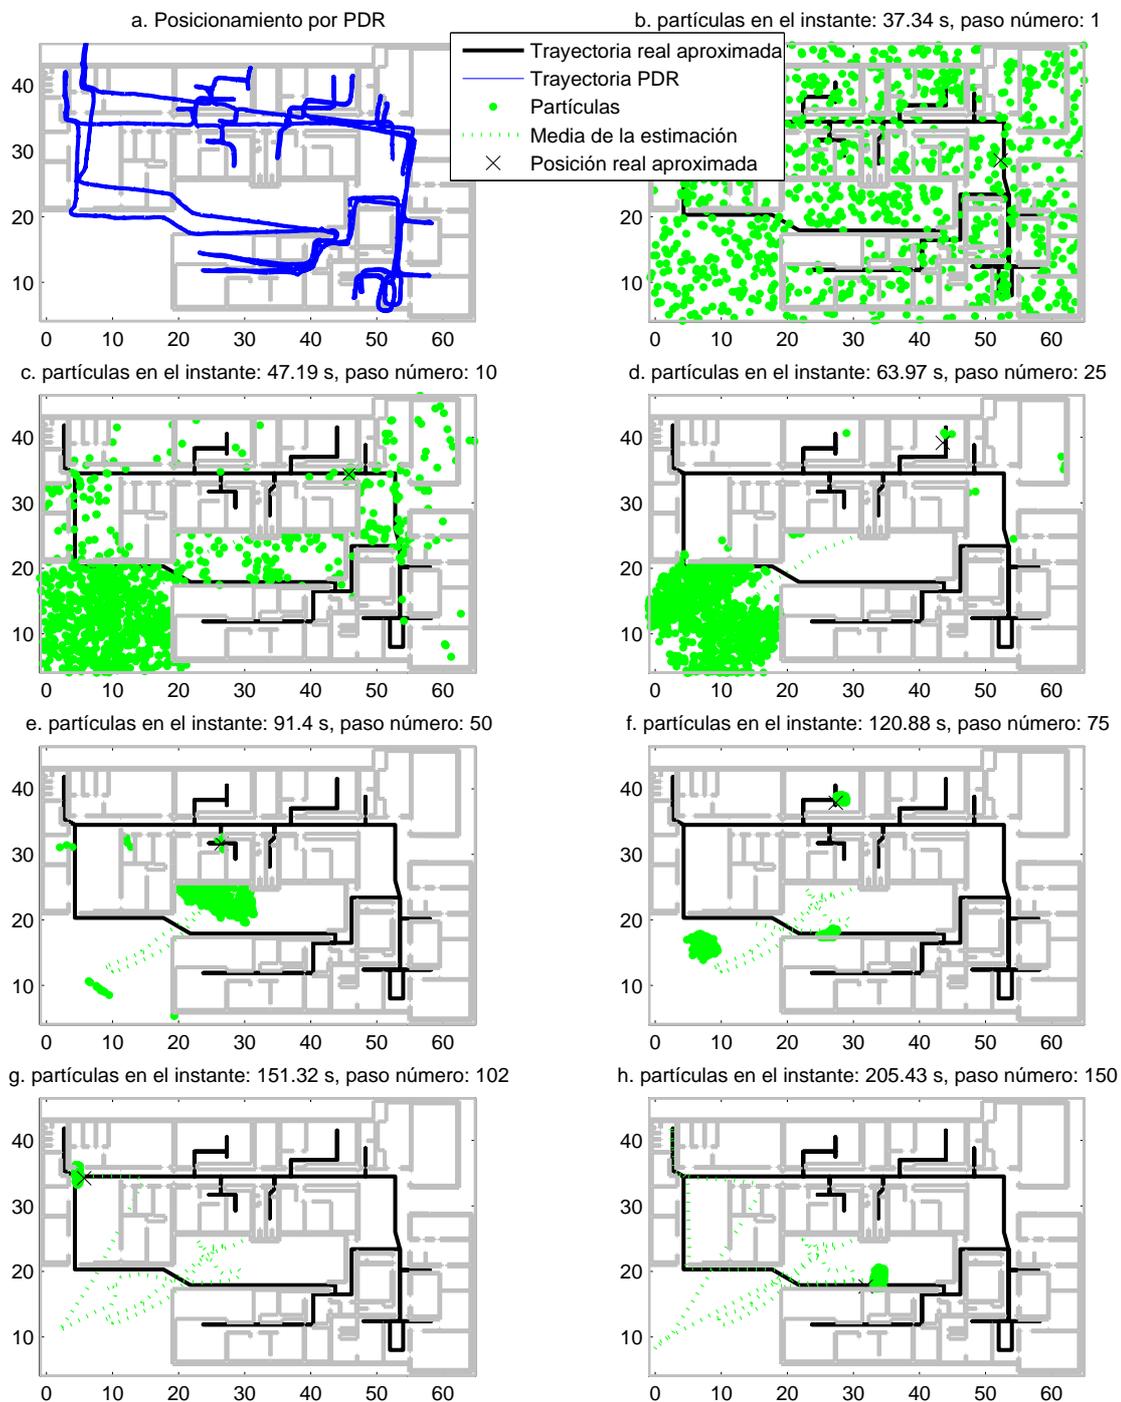


Figura 5.18: Estimación de la posición utilizando PDR con y sin Map matching, con 100 000 partículas, y sin posición o orientación inicial. Ejes en metros. Para facilitar la visualización solo 1 000 partículas son mostradas.

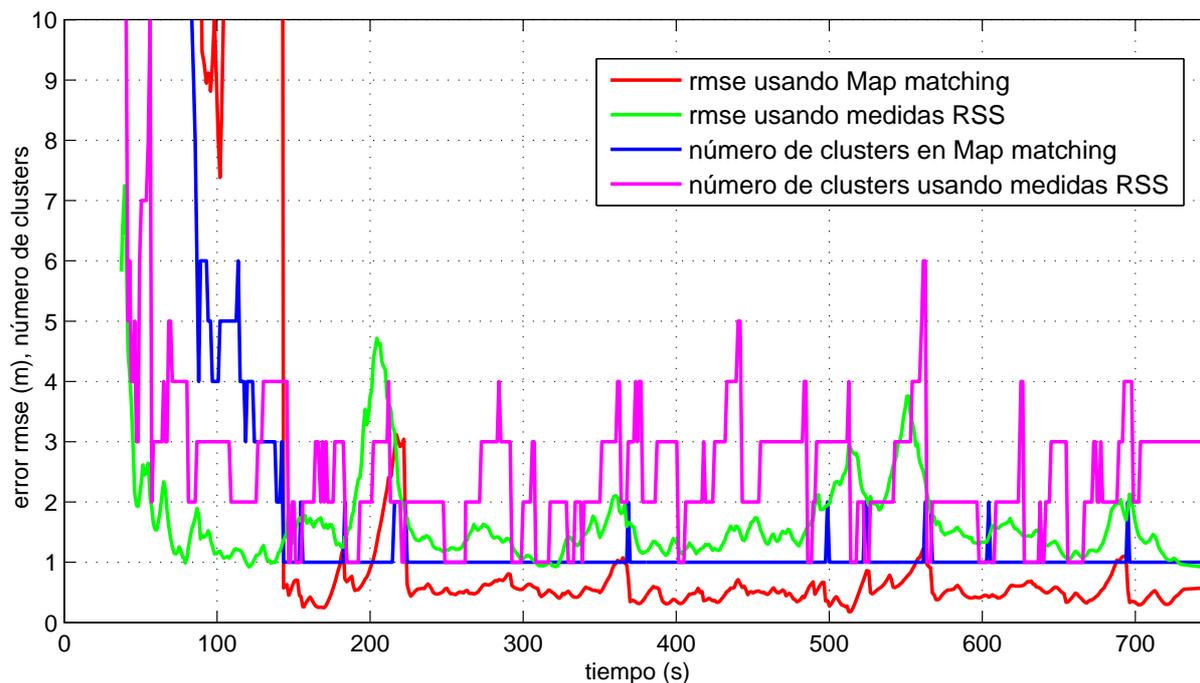


Figura 5.19: Raíz del error cuadrático medio (rmse) y número de clusters (o grupos de partículas) al utilizar medidas RSS de balizas RFID o utilizar map matching.

cruce con las paredes de la entrada posterior y lo estrecho de la puerta de entrada. Debido a la mayor dispersión de la nube en la estimación con bias, un mayor número de partículas sobrevive, además de que éstas serán principalmente aquellas partículas con un bias que desvía la nube en el sentido correcto. El modelo sin bias tendrá sus partículas más concentradas, por lo que al desviarse más de lo esperado solo sobrevivirán las partículas de la parte más externa de la nube, por lo que la probabilidad de que sobrevivan las partículas será menor y se necesitará propagar un mayor número de partículas para que sobrevivan un número significativo de éstas.

Al repetir el trayecto externo, el modelo con bias ya ha aproximado el comportamiento de la deriva, por lo que corrige el desplazamiento de la nube y centra las partículas en un punto más cercano a la posición real. En cambio el modelo sin bias repite la propagación con deriva, lo que hace que presente mayores niveles de error y podría no reentrar en la posición correcta o necesitar un mayor número de partículas para evitar que todas sean eliminadas o tomen otros caminos. Se puede observar que al modelar el bias de la velocidad angular, el modelo de movimiento de las partículas se adapta mejor al movimiento de la persona y aproxima correctamente el nivel de error esperado de la propagación, evitando tener que aumentar el número de partículas y por ende el tiempo de cómputo.

5.2.3.3. Tiempo de cómputo y número de partículas

Un aspecto importante a tomar en cuenta al utilizar filtros de partículas, es el tiempo de cómputo que requieren para ejecutar la estimación. Para analizarla se propone la observación de los tiempos de ejecución de un conjunto de datos específico y en MATLAB. En este experimento se utilizó una ordenador de escritorio con un procesador Intel Core 2 (2.83 GHz) con Windows 7. Aunque el procesador utilizado tiene varios núcleos, las funciones implementadas utilizan

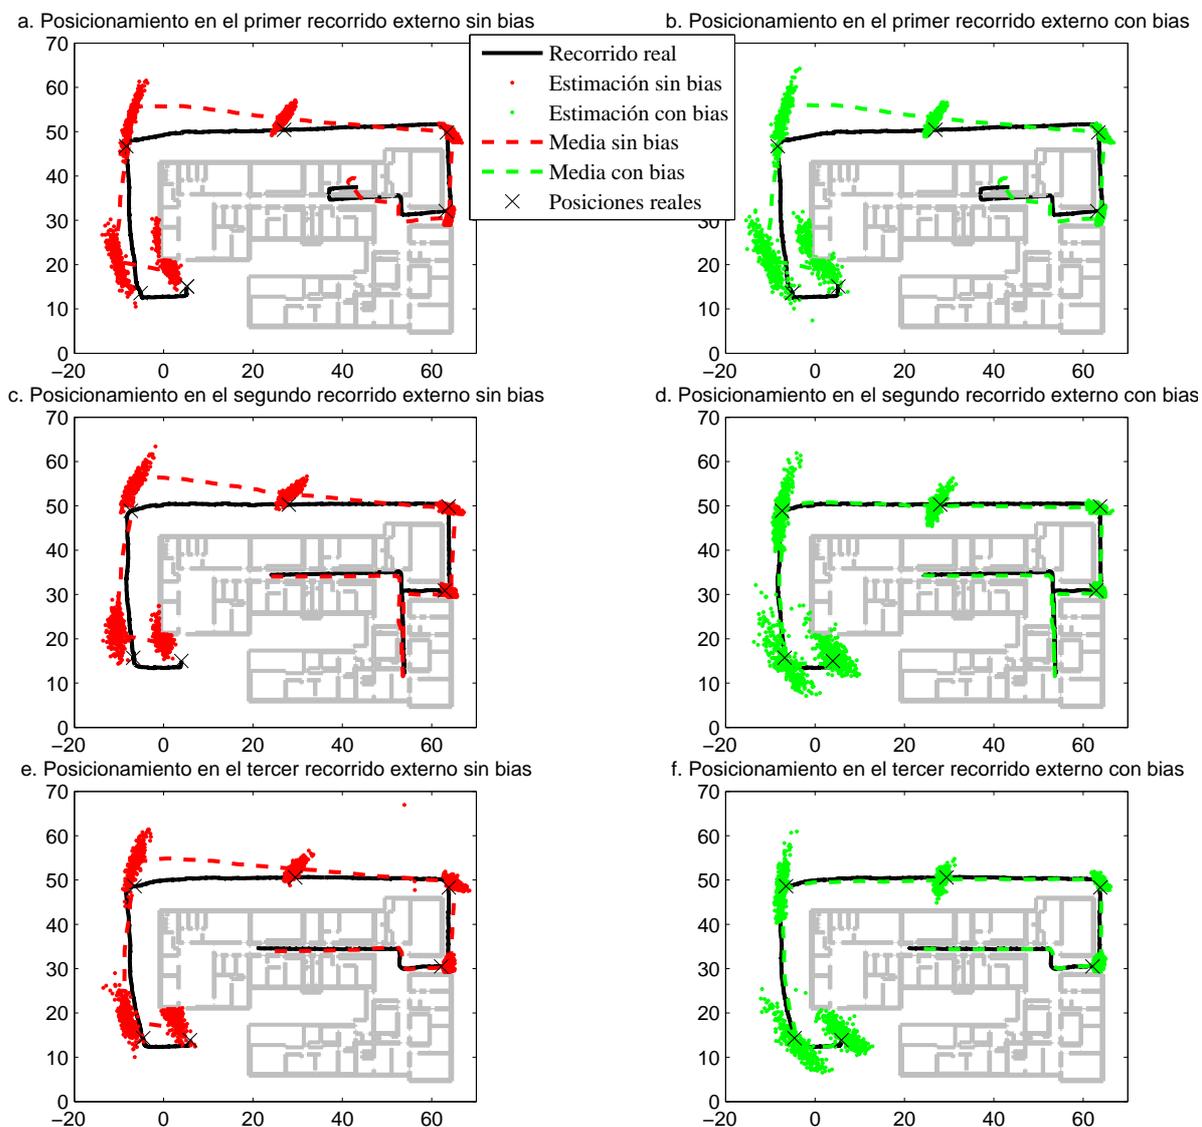


Figura 5.20: Evolución de las nubes de partículas en diferentes puntos del recorrido, comparando la propagación con (derecha, verde) o sin (izquierda, rojo) estimación del bias en la velocidad angular. El filtro utiliza 100 000 partículas, pero para facilitar la observación solo 300 partículas aleatoriamente elegidas son mostradas. a. y b. Primer trayecto externo donde se aprecia el efecto del bias en el recorrido. c. y d., e. y f. Segundo y tercer trayecto externo donde se observa que la estimación con bias es capaz de corregir la deriva, mientras que sin ella se desvía del camino real.

únicamente uno de ellos a la vez.

A lo largo de esta tesis se han detallado algoritmos desarrollados por otros autores y se han propuesto sucesivas mejoras al algoritmo. Para analizar los tiempos asumiremos que el número de partículas es N_p , el número de paredes del edificio es N_e , el número de paredes de una habitación es N_h que se asume mucho menor que N_e y N_r es promedio del número de señales RSS recibidas. Este trabajo se centrará en los siguientes algoritmos:

rMM: Map matching basado en habitaciones [55], en el que se evalúan solo los segmentos de la habitación donde se encuentra la partícula. La implementación no fue vectorizada debido a que la habitación de cada partícula puede ser distinta. Se espera que la ejecución en MATLAB sea lenta debido a la manera en que este sistema maneja las iteraciones (en [55] se utilizó Java para acelerar la ejecución, pero en esta aplicación necesitamos utilizar MATLAB). Se utilizó un número fijo de partículas y la complejidad del algoritmo con respecto al número de operaciones es $O(N_p * N_h)$.

mMM: Map matching con operaciones de matrices, detectando los cruces de las partículas con todas las paredes del edificio utilizando las operaciones vectorizadas (5.32) a (5.34). La complejidad del algoritmo con respecto al número de operaciones es $O(N_p * N_e)$.

eMM: Map Matching eficiente, evaluando solo los segmentos de la habitación de las partículas, pero agrupadas de acuerdo a la habitación, utilizando la estructura de datos de la figura 5.17 y utilizando las operaciones vectorizadas (5.32) a (5.34). La complejidad del algoritmo con respecto al número de operaciones es $O(N_p * N_h)$.

RSS: Se usan medidas RSS para modificar los pesos de las partículas de acuerdo a la probabilidad de la medida en la fase de corrección como se propone en [135]. La complejidad del algoritmo con respecto al número de operaciones es $O(N_p * N_r)$.

El algoritmo fue probado en la señal utilizada en la figura 5.18, con 24 balizas RFID activas distribuidas en todo el edificio. La tabla 5.1 muestra los tiempos de ejecución de cada uno de los algoritmos previos, donde se puede corroborar que el uso de operaciones matriciales baja significativamente el tiempo necesario para el uso de Map matching, comparado con versiones no vectorizadas. Al agrupar las partículas de acuerdo a la habitación en que se encuentra, se disminuye aún más el tiempo de cómputo, esto es debido a la disminución del número de operaciones a realizar (solo se estudian los choques con paredes cercanas) y la forma eficiente en que se implementan (mediante operaciones vectorizadas). Al agrupar las partículas, el proceso se hace más eficiente, especialmente cuando todas las partículas colapsan a una sola nube de pequeñas dimensiones, donde solo será necesario analizar pocas habitaciones y todas (o casi todas) las operaciones serán realizadas como bloque, lo que es muy eficiente en lenguajes como MATLAB o utilizando librerías de manejo de matrices (usualmente muy optimizadas) en cualquier otro lenguaje de programación.

Como se puede observar el uso de operaciones matriciales y el agrupar las partículas de acuerdo a su habitación permite acelerar la detección de los choques con paredes y permite ejecutar el Map matching de manera eficiente en MATLAB. Extrapolando los tiempos obtenidos, sería posible ejecutar hasta 300 000 partículas simultáneamente en el límite de tiempo real (en un procesador de 2.83 GHz), equivalente a las 274 000 partículas que permite ejecutar el algoritmo en [55] en un procesador de 2.6 GHz usando Java en Linux. Adicionalmente, debido al uso de operaciones matriciales, el algoritmo puede potencialmente implementarse en procesadores paralelos, incrementando la eficiencia del método. Se puede notar que los tiempos con el super-

Algoritmo \ partículas	100 000	10 000	1 000
rMM	26 226,26 <i>s</i>	3 034,76 ¹ <i>s</i>	no converge
mMM	3 400,57 <i>s</i>	343,76 ¹ <i>s</i>	no converge
eMM	246,73 <i>s</i>	35,64 ¹ <i>s</i>	no converge
RSS	239,45 <i>s</i>	28,36 <i>s</i>	14,33 <i>s</i>

Tabla 5.1: Tiempo de procesamiento de una señal de 732,34 *s* utilizando los algoritmos de Map matching en la literatura y las mejoras propuestas en este trabajo. Se evalúan diferentes números de partículas.

índice¹ de la tabla 5.1 están cerca de la deprivación de las partículas por lo que este número no se recomienda

5.3. Medidas externas y Map matching

El Map matching permite obtener la posición de una persona con un nivel de error relativamente bajo (dependerá de las características del mapa), pero, sin información adicional, requiere un número de partículas que crece con el área a estudiar, lo que no es escalable. Adicionalmente, requiere que la persona recorra una distancia significativa para poder converger y estimar su posición (si la simetría del edificio lo permite). Por el contrario, la utilización de medidas externas (RSS, TDOA, AOA, RTT, etc.) permiten obtener una posición con un tiempo de cómputo finito sin importar la escala, pero debido a que las señales RF se ven alteradas por el entorno, suelen presentar errores de posicionamiento mucho mayores que en el caso del map matching. En la presente sección se propone estudiar las ventajas de incluir medidas externas en el map matching.

5.3.1. Inicialización de las partículas

Previamente se han utilizado las medidas externas como correcciones a los pesos de las partículas. Al inicializar la estimación, estas observaciones pueden ser utilizadas para actualizar los pesos de partículas uniformemente distribuidas en un edificio usando la ecuación 4.43. Luego de la actualización, la estimación detectará una degeneración de la distribución y forzará el remuestreo de las partículas.

A pesar de que se lograría que la estimación converja, el número de partículas necesarias todavía es dependiente del área a estudiar y se desperdicia mucho poder de cómputo en áreas no necesarias, por lo que se propone utilizar la o las medidas iniciales para establecer la distribución inicial. Dependiendo de las medidas disponibles se busca conseguir una distribución de las partículas tal que:

$$h(X^{(i)}) = z + \eta_z = z^{(i)}, \quad (5.35)$$

donde z es la medida o medidas a utilizar y η_z es su error, lo que generará un grupo de "partículas" $z^{(i)}$ que muestrean los posibles valores de la medida. Debido a que la mayoría de las observaciones no describen todos los estados de $X^{(i)}$, es necesario utilizar variables aleatorias para establecer las relaciones faltantes.

La medida utilizada con más frecuencia es la de distancia d (RTT, TOA, RSS, etc.) a una baliza en una posición conocida r_b . La posición de la partícula en el plano horizontal se puede

¹El número de partículas utilizadas está cerca del mínimo requerido, lo que puede causar deprivación de las partículas en ocasiones

obtener utilizando:

$$\begin{bmatrix} r_x^{(i)} \\ r_y^{(i)} \end{bmatrix} = r_b + \begin{bmatrix} d^{(i)} \cos(\theta^{(i)}) \\ d^{(i)} \sin(\theta^{(i)}) \end{bmatrix}, \quad (5.36)$$

donde $d^{(i)}$ es la distancia de la partícula i de acuerdo a $z^{(i)}$ y la función de observación $h(X^{(i)})$, $\theta^{(i)}$ es el ángulo de incidencia, uniformemente distribuido entre 0 y 2π .

Si se dispone de medidas de diferencias de distancia $\Delta d_{j,k}$ entre las balizas j y k , es necesario definir aleatoriamente una de las distancias a las balizas ($d_j^{(i)}$ o $d_k^{(i)}$) y resolver el sistema de ecuaciones:

$$\|\mathbf{r} - \mathbf{r}_{b_j}\| - d_k^{(i)} = \Delta d_{j,k}^{(i)}, \quad (5.37)$$

$$\|\mathbf{r} - \mathbf{r}_{b_k}\| = d_k^{(i)}, \quad (5.38)$$

tomando en cuenta de elegir la distancia $d_k^{(i)}$ tal que se encuentre entre 0 y d_{MAX} (distancia máxima del sensor), y se cumplan las desigualdades triangulares

$$d_k^{(i)} + d_j^{(i)} \geq \|\mathbf{r}_{b_j} - \mathbf{r}_{b_k}\|, \quad (5.39)$$

$$d_k^{(i)} + \|\mathbf{r}_{b_j} - \mathbf{r}_{b_k}\| \geq d_j^{(i)}, \quad (5.40)$$

$$d_j^{(i)} + \|\mathbf{r}_{b_j} - \mathbf{r}_{b_k}\| \geq d_k^{(i)}, \quad (5.41)$$

$$(5.42)$$

donde $d_j^{(i)} = \|d_k^{(i)} + \Delta d_{j,k}^{(i)}\|$, para que la ecuación tenga soluciones reales.

Las medidas de ángulo de incidencia θ desde una baliza con una posición conocida r_b (asumiremos que θ está medido en el sistema de referencia global) generarían partículas de acuerdo a (5.36), pero en este caso $d^{(i)}$ sería una variable aleatoria uniformemente distribuida entre 0 y d_{MAX} , y $\theta^{(i)}$ será la muestra de la medida.

Si se dispone de un posicionamiento absoluto en \mathbf{r}_z , o un conjunto de medidas que producen una solución única, la posición de las partículas se puede establecer centrada en ese punto y con una desviación estándar de acuerdo a la precisión reportada. La distribución de la orientación de la partícula $\psi^{(i)}$ puede ser obtenida de medidas de orientación como el campo magnético, o con una distribución uniforme entre 0 y 2π . Cualquier otro estado es muestreado de acuerdo a su distribución esperada.

Esta distribución inicial permite ajustar el número de partículas de acuerdo al nivel de ruido esperado, conservando el cómputo en las zonas de interés y acelerando la convergencia.

5.3.2. Pruebas realizadas

Para probar el efecto de utilizar map matching inicializando las partículas de acuerdo a las medidas externas recibidas se propone realizar un experimento en el edificio A del Centro de Automática y Robótica, como se presentó en [141]. Todas las paredes del edificio fueron registradas y se definió una “pared” externa adicional para limitar las hipótesis a recorridos dentro del rectángulo que delimita el edificio. Para la prueba se realizará un movimiento sencillo en forma de L que puede ser ubicado en más de una posición debido a la simetría del edificio y se contará con 24 balizas RFID de las utilizadas en la sección 5.1.3, modelo M100 de RfCode, transmitiendo un identificador una vez por segundo en la banda de 433 MHz. La persona a localizar llevaba una IMU MTi de XSens en el empeine del pie derecho, registrando las aceleraciones y giros a

Algoritmo \ error	Promedio	Desviación estándar
RSS	1.12 m	0.63 m
Map matching, mejor hipótesis	1.97 m	3.92 m
Map matching y RSS	0.51 m	0.42 m

Tabla 5.2: Media y desviación estándar del error al usar Map matching y/o medidas externas de RSS para localización de una persona en la trayectoria mostrada en la figura 5.21.

100 muestras por segundo, y un lector de balizas RFID modelo M220 de RFCODE a nivel de la cintura. Todas las señales fueron registradas y sincronizadas en un teléfono Samsung S4.

Para la estimación se utilizará un filtro de partículas estimando la posición, orientación y habitación de la partícula. La distribución inicial de las partículas será estimada utilizando las medidas RSS recibidas antes del primer paso, su orientación será uniformemente distribuida entre 0 y 2π , y la habitación dependerá de las posiciones de las partículas.

Debido a la trayectoria realizada, si se utiliza solo map matching y no se dispone de información acerca de la orientación, habrían dos posibles hipótesis para la ubicación de la persona como se puede observar en la figura 5.21. En la figura, la línea negra describe la trayectoria real seguida por la persona, mientras que la línea azul claro muestra otra posible trayectoria que sería encontrada con el algoritmo. Sin embargo, si no se delimita el área del map matching, cualquier trayectoria en el exterior del edificio sería posible y no tendrían actualizaciones por choques con paredes, lo que le disminuiría el número de partículas dentro del edificio pues la probabilidad de encontrar una pared es mayor.

Para una primera estimación se utilizan 100 000 partículas. En ella se puede observar que si se define la posición inicial de las partículas de acuerdo a las medidas iniciales, se descarta la segunda hipótesis posible y se concentra el cómputo en la posición real de la persona. La figura 5.21 muestra la evolución de la estimación y cómo al cabo de unos pocos pasos las partículas están concentradas alrededor de la posición real, evitando múltiples hipótesis debido a las medidas RSS y descartando trayectorias imposibles gracias al map matching.

Para estudiar la evolución del número de hipótesis se utilizó un algoritmo de clustering para agrupar conjuntos de partículas con características similares (posición y orientación). Como se observa en la figura 5.22, si no se utilizan medidas externas, la estimación tarda alrededor de 80 pasos en descartar todas las trayectorias no posibles, aun así hay 2 posibles trayectorias que podrían seguir esa forma (si no se toman en cuenta las trayectorias fuera del área del edificio) que serían teóricamente imposibles de distinguir a menos que se use más información. Si se utilizan las medidas externas, puede observarse que la estimación rápidamente converge a la posición real al cabo de tan solo 12 pasos.

Al utilizar ambas medidas se logra bajar el nivel de error significativamente como puede ser observado en los errores reportados en la tabla 5.2 (error promedio de $0,51\text{ m}$) y en la CDF (línea roja) de la figura 5.23 (menos de $0,75\text{ m}$ de error durante 90% del recorrido). En comparación, sin utilizar medidas RSS se generan al menos 2 hipótesis (luego de 80 pasos) de las cuales una tendría un nivel de error comparable con el caso anterior, pero no sería posible identificar la correcta, y debido a la tardanza en converger cerca de 15% de los puntos tienen más de $2,5\text{ m}$ de error, esto genera que el error medio (rmse) sea de $1,97\text{ m}$. Al utilizar solo medidas RSS se puede localizar a la persona rápidamente y sin múltiples hipótesis, pero las partículas estarán más dispersas (menos de $1,9\text{ m}$ de error en 90% de los puntos y un error medio de $1,12\text{ m}$).

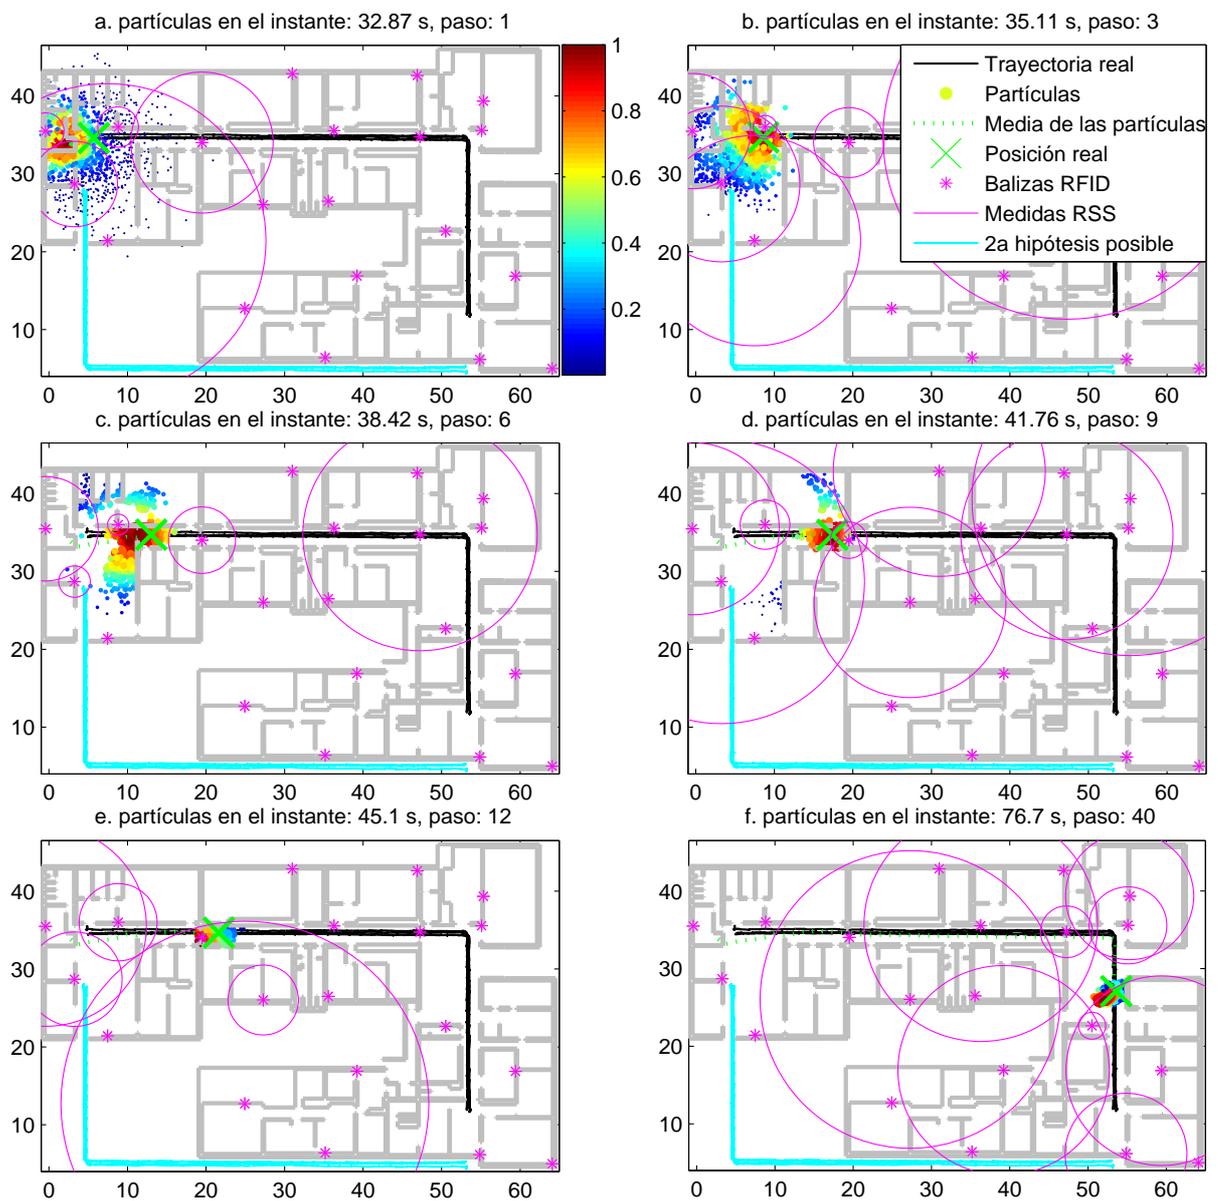


Figura 5.21: Evolución de las nubes de partículas en diferentes puntos del recorrido al utilizar map matching y medidas de potencia de 24 balizas RFID. El filtro utiliza 100 000 partículas, pero para facilitar la observación solo 1000 partículas aleatoriamente elegidas son mostradas.

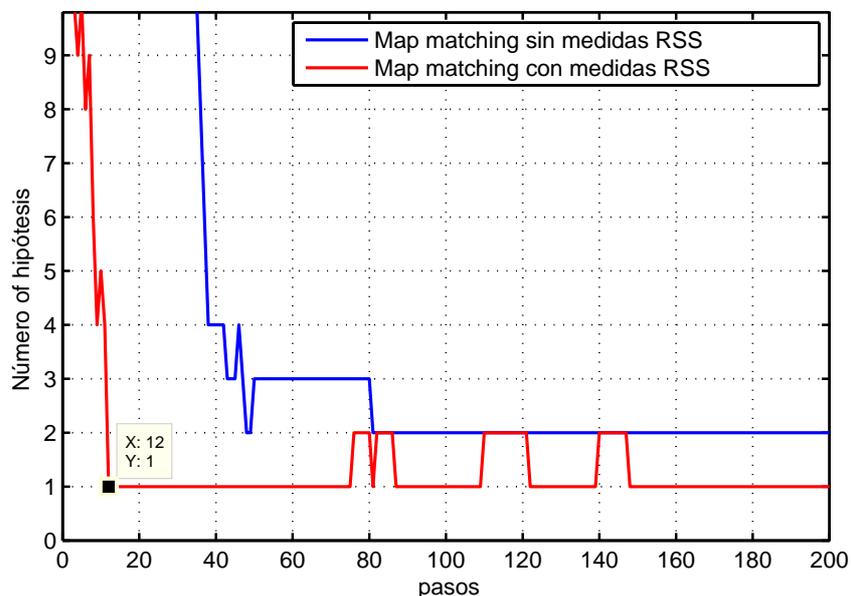


Figura 5.22: Evolución del número de hipótesis usando map matching con y sin medidas externas de RSS. El número de hipótesis es obtenido usando algoritmos de clustering.

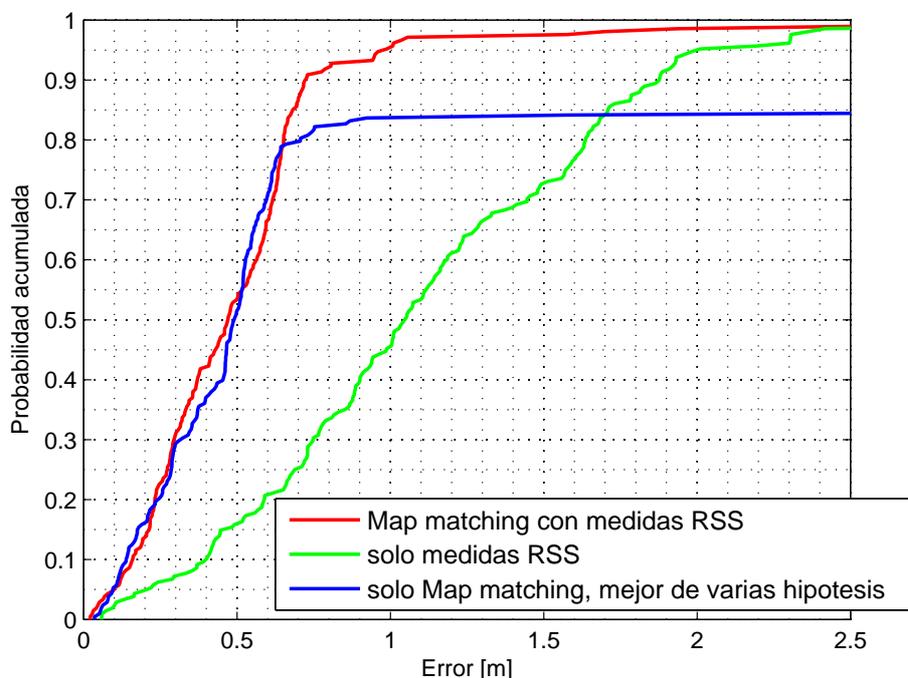


Figura 5.23: Funciones de distribución acumulada (CDF) del error de posicionamiento obtenidas con un filtro de partículas usando PDR con map matching y/o medidas RSS. Para el caso solo map matching, se selecciona artificialmente la hipótesis real para minimizar este error, de lo contrario generaría errores sobre los 30 m, sin embargo en un caso real estas hipótesis no podrían ser distinguidas sin información adicional.

5.3.3. Tiempo de cómputo y número de partículas necesarias

Otra de las ventajas de inicializar las partículas de acuerdo a las medidas iniciales es que debido a que la densidad de probabilidad no está tan distribuida, el número de partículas necesarias disminuiría y por ende el tiempo necesario para su ejecución. En la presente sección se propone evaluar el número de partículas necesarias y su efecto en el tiempo de cómputo (directamente proporcional al número de partículas).

Para analizar el tiempo requerido en cada caso se realizó un experimento similar al propuesto en la sección 5.2.3.3. Utilizando MATLAB, se ejecutó cada algoritmo utilizando un ordenador con un procesador Intel Core 2 (MATLAB solo utiliza uno de los núcleos que trabajan a 2.83 GHz) en Windows 7. La versión de MATLAB disponible para el experimento solo utiliza un núcleo para las operaciones de las partículas, sin embargo, se espera que los tiempos disminuyan si se utilizan mejores librerías de procesamiento en paralelo.

En este experimento se utilizaron las medidas tomadas para las pruebas de la sección 5.2.3.1, en la que se recorre durante 732,34 s el edificio A del Centro de Automática y Robótica, entrando en diferentes oficinas y volviendo al punto de inicio después de 2 vueltas. El edificio cuenta con cerca de 100 balizas RFID modelo M100 de RFCODE, transmitiendo un código identificador una vez por segundo en la banda de 433 MHz, de las que solo 24 etiquetas uniformemente distribuidas en el área son utilizadas. Al igual que en casos anteriores, la persona a localizar llevaba una IMU MTi de XSens en el empeine del pie derecho, registrando las aceleraciones y giros a 100 muestras por segundo, y un lector de balizas RFID modelo M220 de RFCODE a nivel de la cintura. Todas las señales fueron registradas y sincronizadas en un teléfono Samsung S4.

Se estudiarán tres métodos, el caso de solo utilizar medidas RSS (equivalente al algoritmo RSS de la tabla 5.1), el caso de solo utilizar Map Matching (equivalente al algoritmo eMM de la tabla 5.1) y utilizando ambas medidas simultáneamente. Al igual que en el caso anterior, las partículas estiman la posición, orientación y habitación, con una distribución inicial de posición uniforme en el caso solo Map matching, y de acuerdo a las medidas RFID iniciales en los casos que se utiliza RSS. La orientación está uniformemente distribuida entre 0 y 2π y la habitación es obtenida de la posición de la partícula.

La tabla 5.3 muestra los tiempos de cómputo de los algoritmos descritos. Se observa que al incluir las medidas externas y map matching, el tiempo de cómputo aumenta (como es de esperar), pero el punto en el que el algoritmo se acerca a la deprivación de las partículas (marcado con el superíndice²) disminuye comparado con el caso de solo map matching, lo que permitiría obtener un nivel de error menor (como se observó en la sección anterior), con menos partículas.

Algoritmo \ partículas	100.000	10.000	1.000
RSS	239.45 s	28.36 s	14.33 s
Map Matching	246.73 s	35,64 ² s	no converge
Map Matching y RSS	446.49 s	52.59 s	19,45 ² s

Tabla 5.3: Tiempo de procesamiento de una señal de 732,34 s utilizando los algoritmos de Map matching y/o medidas externas de RSS, y evaluando diferentes números de partículas.

²El número de partículas utilizadas está cerca del mínimo requerido, lo que puede causar deprivación de las partículas en ocasiones

5.4. Conclusiones

En el presente capítulo se han tratado las formas de introducir diferentes medidas externas a la estimación con el filtro de dos niveles, con el objetivo de limitar el crecimiento del error. Se han introducido 2 tipos de medidas, sensores externos y restricciones de movimientos, las primeras permiten integrar en la estimación cualquier señal asociada a puntos conocidos (TOA, TDOA, RSS, AOA, etc.), mientras que la segunda utiliza entre otros el mapa del edificio para corregir la deriva de la estimación. Inicialmente se trata cada medida independientemente y por último se muestran las ventajas de su utilización conjunta.

Cualquier sistema basado en sensores inerciales permite obtener un estimado del desplazamiento de una persona, pero debido al carácter integrativo del proceso, utilizando PDR, este acumulará errores en la orientación que crecen linealmente con el tiempo, y en la posición que crecen linealmente con la distancia total recorrida. Para evitar la deriva de estos sistemas se utilizaron las señales RF disponibles, aprovechando los sistemas de comunicación inalámbrico instalados en la mayoría de los edificios. Para analizar el impacto de incluir dichas medidas en la estimación, se estudió la cota de Cramér Rao donde se pudo comprobar que el modelo de movimiento de PDR tiene un error que crece con el tiempo, pero si se utiliza para propagar estimaciones con medidas RSS de sistemas RF, permite disminuir el error cuadrático medio de alrededor de 4 m (solo posicionamiento RSS) a menos de 0,5 m (fusión PDR-RSS). Estos hallazgos se comprobaron realizando un análisis de Monte Carlo con señales sintéticas con ruido aleatorio controlado.

Para probar el sistema con señales reales se propuso utilizar las medidas de potencia de la señal y tiempo de vuelo de balizas WiFi y ZigBee. A diferencia de otras implementaciones, en el presente trabajo se utilizó un modelo de atenuación de la señal con respecto a la distancia previamente calibrado y extrapolable a otros ambientes de oficina sin necesidad de realizar medidas exhaustivas. El sistema es más robusto ante cambios en mobiliarios, puertas, etc., y permite obtener errores inferiores a 1,75 m en más del 90 % de las muestras.

De manera similar se probó la inclusión de sistemas especializados en posicionamiento como el sistema de posicionamiento por UWB de Ubisense, y se analizó el efecto de tener un sistema muy preciso en una pequeña parte del recorrido (UWB de Ubisense) y uno poco preciso pero con una mejor cobertura (RSS a tags RFID). Se pudo comprobar que se obtiene un menor nivel de error utilizando el sistema con mayor cobertura que el más preciso pero confinado, pero si se utilizan ambos, este último permite una mejor estimación inicial, lo que disminuye significativamente el nivel de error del sistema desde las primeras medidas.

También se analizó el efecto de variar el número de tags RFID utilizados y se pudo comprobar que a medida que se aumenta el número de dispositivos utilizados, mejora la estimación. Sin embargo, una vez superados los 34 emisores (en un área de $3\,000\text{ m}^2 \approx 15 \times 25\text{ m}^2 + 40 \times 65\text{ m}^2$) no se aprecia mejoría significativa, lo que permite definir una densidad mínima de tags de aproximadamente 1 tag por cada 90 m^2 , para obtener los mejores resultados posibles con esta tecnología.

Otra fuente de información que puede ser utilizada para localizar a una persona es el mapa, ésta permite delimitar el crecimiento de la deriva, restringiendo el paso de la persona a los pasillos y oficinas del edificio. Hay múltiples técnicas para utilizar la información del mapa en la estimación, pero la única que no modifica el patrón de caminado es el método propuesto en [54, 55, 66], que elimina las estimaciones que atraviesan paredes. En particular este trabajo se basó en la implementación de [55] que optimiza el algoritmo utilizando solo las paredes de la habitación en la que se encuentra la partícula y por ende haciendo al algoritmo escalable con el número de paredes.

Para optimizar el algoritmo en MATLAB se propuso hacer uso de operaciones de matrices y se describió una vectorización del algoritmo que permite acelerar significativamente las operaciones. Para utilizar la vectorización en el algoritmo de [55] que utiliza solo las paredes de la habitación de la partícula, se propuso, agrupar las partículas de una misma habitación para utilizar las operaciones como bloques, y representar el mapa del edificio con un esquema de árbol de datos que permite acceder rápidamente a las paredes de una habitación y las paredes alcanzables si ésta cruza a otra habitación por puertas, pasillos, etc.

El algoritmo fue probado en un recorrido en el Edificio A del Centro de Automática y Robótica, donde se pudo observar que éste es capaz de obtener la posición absoluta de una persona utilizando únicamente PDR y el mapa del edificio (si el recorrido es no simétrico). El tiempo necesario para la localización de la persona dependerá del recorrido realizado, para la prueba realizada fue de aproximadamente 150 segundos, en el paso 100 y una vez alcanzado este punto, la estimación se mantuvo con un error cuadrático medio de aproximadamente 0,5 *m*, mientras que la localización utilizando medidas RSS de tags RFID y PDR tiene un error cuadrático medio de aproximadamente 1,5 *m*, pero un tiempo de convergencia mucho menor (cerca de 70 segundos, paso 30).

Para comprobar el efecto del modelado del bias en el filtro de partículas se propuso observar el efecto que éste tenía sobre la estimación con diferentes medidas externas. Al utilizar medidas de la potencia de la señal con frecuentes muestras (1 medida por segundo) se observó que el error de la estimación no se diferenciaba significativamente del modelo sin bias. Sin embargo, al estudiar el efecto en un recorrido con tramos con pocas correcciones (trayectoria externa al edificio o en galerías, naves, etc.) se pudo observar que la presencia del bias ayudaba a estimar en mejor medida el error esperado en la posición, evitando la deprivación de las partículas y ayudando a estimar este error no observable a nivel de PDR y por ende corrigiendo su efecto.

Al observar el tiempo requerido para ejecutar las diferentes implementaciones de map matching y su dependencia en el número de partículas, se pudo constatar que el algoritmo de map matching eficiente propuesto (operaciones matriciales y verificación de solo las paredes alcanzables desde la habitación de la partícula) tiene una complejidad similar a la inclusión de medidas RSS, pero requiere de un número mayor de partículas para converger (este número depende del área a localizar). También se puede notar que el algoritmo en forma matricial pero utilizando todas las paredes del edificio es significativamente más lento y no es escalable si se trata de ubicar a la persona en áreas más grandes. La implementación propuesta por [55] permite tener un número de operaciones escalable con el edificio, pero debido a la implementación en MATLAB esta es unas 100 veces más lenta que la implementación eficiente propuesta.

La utilización de Map Matching permite reducir las nubes de partículas a áreas relativamente pequeñas (un error de 0,5 *m* en el experimento propuesto, pero variará de acuerdo al edificio y la trayectoria) pero requiriendo un trayectoria relativamente larga para converger, y dependiendo de la simetría del edificio podrían generarse más de una hipótesis, y sin información adicional sería imposible identificar la correcta. Adicionalmente, el número de partículas necesarias para inicializar el sistema crece proporcionalmente al área a estudiar, ralentizando el algoritmo si el edificio es muy grande. La forma más fácil de prevenir estos problemas es utilizar medidas externas, que permiten inicializar las partículas en áreas específicas, minimizar el número de partículas necesarias y eliminar hipótesis simétricas.

Las medidas externas suelen ser utilizadas como correcciones a las partículas, pero para inicializarlas basta con generar distribuciones que sigan las medidas iniciales observadas. Este método solo requiere un número de partículas proporcional al área de cobertura del sensor y las concentraría en los puntos de interés. Luego de la inicialización, las medidas externas modifican los pesos de las partículas de acuerdo a las señales recibidas, lo que permite eliminar las falsas

hipótesis más rápidamente.

Al observar los efectos de cada una de estas medidas (Map matching y medidas externas) podemos notar que el efecto simultáneo mejora significativamente la estimación. En el experimento realizado usando PDR con map matching y medidas RSS de balizas RFID, se logró un error de posicionamiento cercano a $0,5 m$, menos de la mitad que utilizando PDR con medidas RSS y casi la cuarta parte que utilizando PDR con map matching. Adicionalmente se logró una convergencia mucho más rápida y gracias a que el número de partículas requerido es menor, el tiempo de procesamiento es inferior.

En el presente capítulo se pudo observar el efecto de complementar las medidas inerciales obtenidas del PDR con medidas absolutas como son medidas RF (RSS, RTT, TDAO, AOA, etc.) y la información contenida en el mapa del edificio (Map matching). Se pudo constatar que cada una es capaz de localizar a una persona de manera absoluta, pero su utilización conjunta permite obtener los mejores resultados. En el caso de las medidas externas RF, la utilización de la información inercial de PDR permite disminuir significativamente el nivel de error de los sistemas RF y el filtro de partículas permite la utilización de medidas sin necesidad de su linealización. La información del mapa permite colocar un recorrido en un edificio si la simetría de éste lo permite, pero al utilizar el mapa y las medidas de los sensores RF se logra disminuir el nivel de error, el tiempo de cómputo, el tiempo de convergencia y el número de partículas necesarias.

Parte III

Conclusiones

Capítulo 6

Conclusiones y aportaciones

A continuación se resumen las principales conclusiones y aportaciones obtenidas en la Tesis, organizadas de acuerdo al esquema de la figura 6.1. En el esquema se observan los objetivos inicialmente planteados (Obj. 1.X, Obj. 2.X y Obj. 3.X), cubiertos en los capítulos 3, 4 y 5 respectivamente, y sobre los cuales se presentarán en la siguiente sección 6.1 las conclusiones obtenidas para cada objetivo específico. Seguidamente, la sección 6.2 muestra las diferentes aportaciones de acuerdo a los trabajos presentados, mientras que la sección 6.3 enumera los trabajos en revistas, patentes, conferencias y estancias de investigación. Por último, la sección 6.4 propone posibles temas de investigación para continuar el trabajo propuesto en esta tesis.

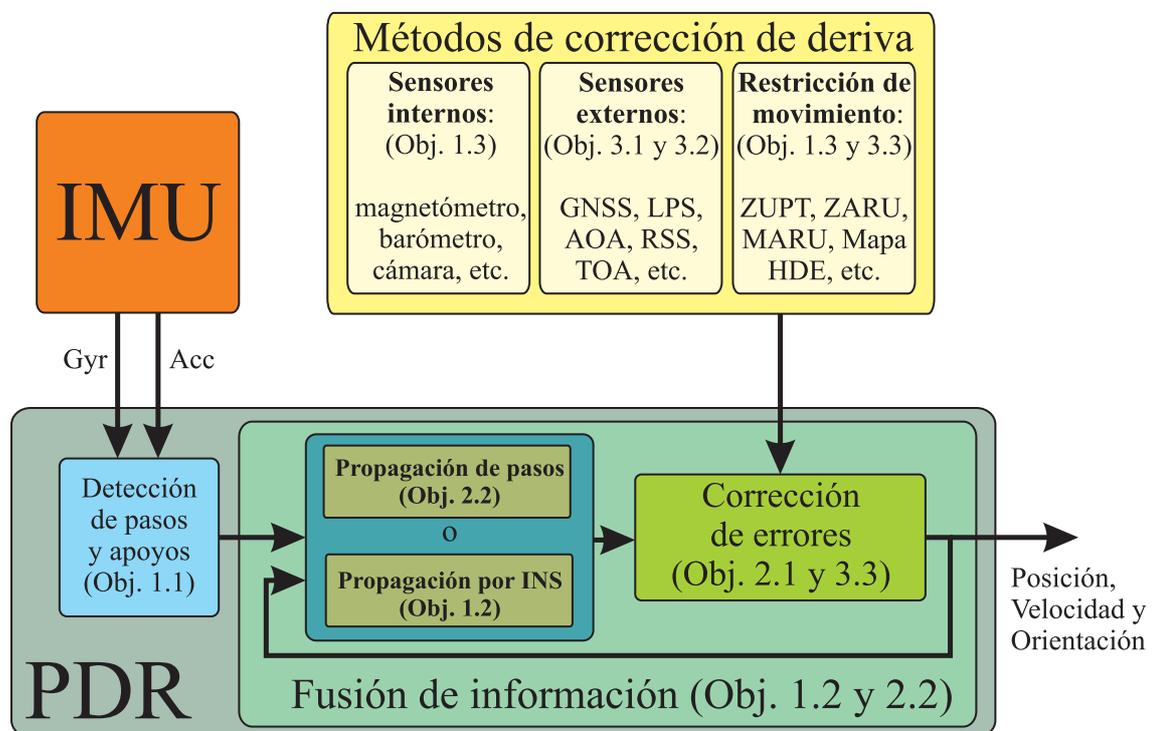


Figura 6.1: Esquema general de algoritmos de posicionamiento por sensores inerciales.

6.1. Conclusiones específicas por objetivos

Luego de analizar los resultados obtenidos en este trabajo de tesis, se pudieron concluir diferentes ideas respecto a la localización de personas en ambientes interiores mediante sensores inerciales y su fusión con otras tecnologías. A continuación se presentan las conclusiones de acuerdo a los objetivos específicos originalmente planteados:

6.1.1. Estudio y mejoras en los algoritmos de posicionamiento por sensores inerciales (Objetivo 1)

El primer objetivo planteado trata el estudio del algoritmo PDR, utilizando navegación inercial con una IMU en el pie de la persona. Los sensores inerciales permiten conocer el posicionamiento relativo de una persona con un nivel de error muy bajo, pero para ello, es necesario identificar las fases de apoyo de la persona, propagar los estados de la estimación inercial y los errores asociados, e implementar correcciones que permitan minimizar el crecimiento del error. Estos puntos fueron tratados en el capítulo 3 y se presentan a continuación.

Objetivo 1.1: Estudiar los métodos de detección de las fases del paso y proponer mejoras a los algoritmos actualmente utilizados.

Para localizar a una persona utilizando sensores inerciales en el pie es necesario identificar las fases de apoyo para poder corregir la deriva de la integración inercial. Las características de la fase de apoyo pueden cambiar por múltiples razones (diferentes personas, suelos, zapatos, etc.) pero es necesario definir un algoritmo que sea capaz de adaptarse a esas variaciones para garantizar su reconocimiento durante el caminado. Comúnmente se utilizan límites en los módulos de las aceleraciones y velocidades angulares para detectar dicha fase, pero en el capítulo se logró una mejor detección utilizando un filtro de mediana con un retardo sobre la señal anterior.

Una vez identificado un instante en que el pie se encuentra en apoyo se pueden aplicar las correcciones asociadas, pero se ha observado que los puntos iniciales y finales de dicha fase pueden tener velocidades no nulas que afectarían la corrección. En la presente tesis se propuso variar la certeza del apoyo de acuerdo a que tan cerca se encuentre el punto del centro temporal de apoyo y modificar la covarianza de acuerdo a esta. Este ajuste de la covarianza de la medida es particularmente útil en medidas como las rotaciones magnéticas pues permite enfocar el efecto de las medidas en la parte central del apoyo (donde el campo magnético es más constante) y minimizarlo al inicio y fin de dicha fase (donde el campo magnético puede variar), mejorando el efecto de la medida.

Objetivo 1.2: Estudiar el filtro estimador utilizado (EKF) y evaluar la posibilidad de utilizar filtros mejor adaptados a las no linealidades del sistema.

El filtro extendido de Kalman es una de las herramientas de estimación más utilizadas actualmente, pero debido a que es una linealización para poder tratar sistemas no lineales (la mayoría) se ha observado que tiende a presentar un sesgo o bias. En este trabajo se propuso la utilización de un filtro alternativo con un requerimiento de cómputo ligeramente superior, el filtro de Kalman Unscented, que mide la propagación del sistema y las observaciones mediante una serie de puntos cercanos a la media y distribuidos de acuerdo a la desviación estándar de los estados.

La utilización de este filtro permite una mejor propagación de los estados, en particular la orientación, lo que repercute significativamente en la estimación de la posición. Adicionalmente, permite extraer más información de las diferentes observaciones utilizadas e introducir fácilmente medidas no lineales que requerirían la obtención de los gradientes en el EKF.

Objetivo 1.3: Estudiar las medidas de campo magnético en interiores y la posibilidad de ser utilizadas para proveer información de la orientación.

Una de las mayores fuentes de error en la estimación de la posición con sensores inerciales es el incremento del error de la guiñada, este es usualmente corregido en exteriores observando el campo magnético, pero en interiores el campo suele presentar perturbaciones que no permiten su directa utilización. En esta tesis se propuso el Magnetic Angular Rate Update (MARU) que utiliza observaciones de las variaciones o rotaciones del campo magnético durante las fases de apoyo para observar las velocidades angulares. Estos campos magnéticos aunque puedan estar perturbados por el ambiente, se mantendrán constantes mientras el pie se mantenga en la fase de apoyo, por lo que pueden ser utilizados para medir la velocidad angular perpendicular a éste, pero no la orientación absoluta.

El MARU permite estimar el bias en del giróscopo, un estado no completamente observable previamente, al comparar la rotación observada en el campo magnético con las velocidades angulares observadas. Esta medición de las rotaciones del campo magnético permiten disminuir el orden de crecimiento del error de orientación, pasando de un error que crece linealmente con el tiempo a uno que crece con la raíz del tiempo (random walk). Se propuso utilizar el MARU de 2 formas, en un EKF y en un UKF, y se observó que ambas disminuyen el nivel de error de orientación, siendo la implementación del MARU en el UKF, el método que provee la estimación con el menor nivel de error.

Debido a la necesidad de que el pie se encuentre en la fase de apoyo para que se pueda asumir el campo magnético constante, la medida se ve afectada por pequeños cambios en éste al inicio y fin de la fase de apoyo. Para solucionarlo, se estudió la utilización de la variación de la covarianza de la medida de acuerdo a la certeza del apoyo, logrando potenciar el efecto de la medida en la region central del apoyo y disminuyendo su efecto en los límites del apoyo. Este tipo de medidas suaves disminuyeron el error de orientación y por ende el de posición.

6.1.2. Estudio del esquema de fusión de información para mejorar la utilización de medidas externas (Objetivo 2).

El segundo objetivo planteado busca mejorar el esquema de fusión para poder incorporar de manera más eficiente medidas externas, ya sean de múltiples sistemas de posicionamiento absoluto, o medidas independientes que se desean fusionar. Los algoritmos para unir múltiples estimaciones fueron discutidos en el capítulo 4 y a continuación se presentan las conclusiones obtenidas de acuerdo a los objetivos específicos planteados.

Objetivo 2.1: Estudiar la unificación de múltiples sistemas de posicionamiento mediante la utilización de una relación de distancia máxima entre ellos.

Para fusionar las estimaciones de sistemas de posicionamiento en varias partes del cuerpo se suele requerir una distancia relativa entre ellos para poder relacionar las estimaciones. Si se dispone de un sistema PDR en el pie y otro sensor de posicionamiento en el cuerpo no es posible medir a tiempo real la distancia entre ellos, por lo que se propuso estimar con un EKF asumiendo una distancia máxima entre las posiciones y en la etapa de corrección modificar la media y la covarianza para que se adapten al límite de distancia establecido, una técnica conocida como filtro de límites (constrain filter).

Se presentó una versión del filtro de límites que utiliza una rejilla de puntos en el espacio de estados para evaluar el efecto del límite en la evolución de la pdf, pero debido al número de

estados, esta rejilla requeriría demasiados puntos para ser lo suficientemente precisa. Se modificó linealmente el espacio de estados para limitar el efecto a un número reducido de estados y simplificar el problema, logrando establecer el límite de distancia solo en un espacio transformado de 3 estados, independiente del resto de los estados.

Se pudo comprobar que mediante esta fusión se logró disminuir el error de posicionamiento significativamente sin conocer la posición relativa entre los sistemas de posicionamiento, tanto en simulaciones de Monte Carlo, como en pruebas con un sistema PDR en el pie y un sistema de posicionamiento UWB en la cabeza.

Objetivo 2.2: Fusión de información mediante la utilización de un filtro de partículas con actualizaciones basadas en la información de PDR y correcciones basadas en medidas externa.

Entre las estrategias actuales para manejar las no linealidades de las medidas y propagaciones en localización, está la utilización de estimaciones a 2 etapas propuesta por múltiples autores. En la primera etapa de la estimación utilizan PDR con la IMU en el pie (implementado en un EKF) para extraer los desplazamientos y una segunda etapa implementa un filtro de partículas para incluir las medidas externas.

Al estudiar la evolución de la cota inferior de Cramér-Rao de esta estimación se observó que en ausencia de medidas externas el crecimiento del error era inferior al esperado. Debido a esto, se propuso la modificación del esquema para adaptar el error de propagación de los pasos a sus características y modelar el bias de la velocidad angular en el eje vertical.

Al incluir el bias de la velocidad angular en el eje vertical, el crecimiento del nivel de error se aproxima en mejor medida al error cuadrático medio esperado con medidas reales, lo que mejorará las estimación cuando se depende de PDR por mucho tiempo. Utilizando este esquema se pueden utilizar un conjunto mayor de medidas sin la necesidad de linealizarlas o aproximarlas, por ende ofreciendo una máxima flexibilidad.

6.1.3. Inclusión de medidas externas en el algoritmo de posicionamiento basado en filtro de partículas (Objetivo 3)

El tercer objetivo planteado busca estudiar los métodos de corrección de la deriva, ya que como se ha discutido previamente las estimaciones basadas únicamente en sensores inerciales divergen con el tiempo por lo que necesitan de medidas externas para limitar el crecimiento del error. En ambientes interiores es común encontrar señales RF (WiFi, Bluetooth, RFID, etc.), por lo que se suelen utilizar las características de las señales (TDoA, ToA, AoA, RSS, etc.) para relacionar las posiciones de éstos con la posición de la persona a ubicar.

Adicionalmente, si se dispone del mapa del edificio, es posible ubicar a la persona y corregir su posición en base al recorrido tomado (si el recorrido es único). Este objetivo fue tratado en el capítulo 5 y a continuación se agruparán las conclusiones al estudiar los efectos de estas medidas externas sobre el posicionamiento.

Objetivo 3.1: Inclusión de medidas de potencia de la señal y tiempo de vuelo.

Para conocer el efecto teórico de la inclusión de información de distancia a balizas conocidas se estudió la cota inferior de Cramér-Rao y se comparó con el error cuadrático medio obtenido de un experimento de Monte Carlo. Se pudo observar que las medidas de distancia no solo limitaban

el crecimiento del error como era esperado, sino que generaban un nivel de error inferior (cercano a $0,5\text{ m}$ en nuestro experimento) a solo utilizar medidas externas (con un nivel de error de cerca de $4,0\text{ m}$) al agrupar más medidas bajo la misma estimación.

Al analizar el crecimiento del error con y sin estimación del bias en el PDR, se observó que al agregar las medidas externas continuas, el bias no tiene un efecto significativo pues su efecto se corrige constantemente. El efecto del bias se observará cuando no hayan medidas externas por suficiente tiempo.

Para comprobar el efecto del esquema de fusión en señales reales, se utilizó el algoritmo para fusionar PDR con mediciones de tiempo de vuelo y potencia de la señal a puntos de acceso WiFi. La fusión de las medidas externas permitió una estimación más robusta, disminuyendo el error de más de 5 m (90% del tiempo) al utilizar solo las señales RF, a menos de $1,75\text{ m}$ (90% del tiempo) con el algoritmo fusionado. Adicionalmente se observó que al utilizar el modelo de error del paso adaptativo, se disminuyó el error entre un 10% y un 20%, comparado con un modelo de error constante en el paso.

Objetivo 3.2: Inclusión de medidas de diferencias de tiempos de vuelo y ángulo de incidencia.

Para analizar el efecto de diferentes sistemas de posicionamiento absoluto sobre la estimación, se estudió la fusión de PDR con 2 sistemas de posicionamiento, uno preciso, pero con poca área de cobertura y otro menos preciso, pero con una cobertura mucho mayor. Se observó que se podía obtener un menor error de posicionamiento utilizando el sistema de mayor cobertura, pues para trayectorias largas, la estimación dependería mucho del PDR sin correcciones.

Al variar el número de balizas a utilizar se comprobó que se logra mejorar la precisión del sistema al aumentar los emisores usados. Sin embargo, pasado cierta densidad (1 baliza cada 90 m^2 en el edificio estudiado) la precisión no mejora significativamente, pero aumenta el cómputo necesario, por lo que esta se podría considerar una densidad ideal.

Los sistemas de posicionamiento más precisos tienen la ventaja de que permiten concentrar las estimaciones de la posición, pero son fácilmente afectados por los valores atípicos que podrían generar una degeneración de las partículas en la estimación. Para evitarlo se debe implementar un detector de valores atípicos robusto aunque disminuya el número de medidas disponibles.

Objetivo 3.3: Inclusión de la información del mapa en la estimación bajo una estructura de cómputo óptima.

Las trayectorias de una persona en un edificio son delimitadas por su estructura, por lo que conociendo el recorrido de manera relativa, se puede limitar las posibles posiciones a aquellas que siguen la estructura del mapa. Luego de estudiar los diferentes métodos para utilizar la información del mapa, se implementó un método basado en la eliminación de las hipótesis que pasan por paredes propuesto por Woodman et.al [55]. El algoritmo minimiza el número de detecciones de cruces evaluando únicamente las paredes de la habitación en la que se encuentra la partícula.

Para optimizar el método, en esta tesis se vectorizaron las operaciones a realizar, de modo que en ambientes de desarrollo como MATLAB las operaciones fuesen eficientes. Adicionalmente se minimizó el número de paredes a comparar al pasar a nuevas habitaciones, utilizando solo las paredes alcanzables desde el borde entre ellas, y se definió un modelo estructurado del edificio que incluye las habitaciones, las paredes y las puertas (segmentos cruzables que definen el cambio

de habitación).

Para comprobar el funcionamiento del método se evaluó el posicionamiento de un recorrido utilizando solo PDR y el mapa del edificio. Se pudo comprobar que con tan solo esta información es posible la localización de la persona, pero dependerá de cuan única es la trayectoria. El tiempo requerido para la localización dependerá de la trayectoria, pero en general suelen ser necesarios por lo menos varias decenas de pasos para generar una trayectoria única, y una vez convergida la estimación, el error de ésta dependerá del tamaño de los pasillos y puertas.

En general si la estimación se encuentra dentro de un edificio, y por ende se corrige constantemente, esta no requiere una estimación del bias de la velocidad angular, pero si la persona se encuentra en áreas exteriores, o salones amplios sin correcciones continuas, la estimación del bias podría ayudar a ajustar correctamente el crecimiento del error.

El método vectorizado utilizando todas las paredes del edificio no es escalable, pues la complejidad crece con el área a estudiar, mientras que el método por habitaciones es escalable, pero no ejecutable a tiempo real en MATLAB (debido a la implementación de iteraciones por partícula). Al combinar ambos métodos, se puede generar un algoritmo escalable e implementable en MATLAB.

En la mayoría de los casos la convergencia del método es lenta y requiere un número significativo de partículas, por lo que se propuso la utilización de medidas absolutas para inicializar y corregir la estimación. Al inicializar la pdf de acuerdo a las medidas absolutas, se reduce el número partículas necesarias (limitado de acuerdo a la distribución de las medidas iniciales), y al corregir la estimación con las medidas externas se evitan las simetrías estructurales, disminuyendo el número de partículas necesarias (y por ende el tiempo de cómputo) y reduciendo significativamente el error de la estimación.

6.2. Principales aportaciones

El presente trabajo de investigación ha generado novedosas aportaciones para la localización de personas en ambientes interiores mediante sensores inerciales y su fusión con otras tecnologías, estas han supuesto un avance en el estado de la técnica y prueba de ello son las numerosas publicaciones. A continuación se resumen y asocian de manera cronológica con los trabajos publicados:

1. Se **estudió el caminado de las personas y la detección del apoyo** para desarrollar **una señal sintética que emula a un peatón con una IMU en el pie**. La señal fue utilizada para mejorar la estimación inercial y el algoritmo de detección de pasos, y permite realizar análisis de Monte Carlo sobre la evolución del error en las estimaciones. Este trabajo fue presentado en la conferencia IPIN 2011 [19].
2. Luego de estudiar el esquema de estimación inercial y correcciones del PDR mediante un EKF, se propuso la **utilización de un UKF para mejorar la propagación no lineal de los estados y mejorar el efecto de las correcciones**. Además, debido a la no observabilidad de la orientación en ambientes con perturbaciones magnéticas se propuso la **utilización de los cambios en el campo magnético** observado debido a rotaciones de la IMU para medir los cambios de orientación y por ende el bias del giróscopo, una medida acuñada como **Magnetic Angular Rate Update (MARU)**. Esta propuesta fue presentada en la conferencia PLANS 2012 [28] y patentado en conjunto con el DLR [115].
3. Buscando mejoras en el algoritmo de fusión de información para incorporar información de

la posición absoluta de sensores en diferentes partes del cuerpo, **se propuso la utilización de un límite en la distancia máxima entre ellos para corregir la evolución de la estimación**. Esta técnica conocida como **Constrain filter** fue aplicada para asociar una estimación PDR en el pie con una estimación inercial de una IMU en la cabeza, con correcciones de un sistema UWB. Este sistema fue presentado en la conferencia IPIN 2012 [142].

4. Para lograr mejorar el esquema de fusión de información PDR con medidas externas, se utilizó un **esquema de dos niveles**. En un nivel se implementa PDR con una IMU en el pie, basado en un EKF con una alta tasa de muestreo para extraer el movimiento relativo de la persona. En el siguiente nivel se utilizan los desplazamientos para propagar las estimaciones de un filtro de partículas corregido de acuerdo a las medidas externas observadas, medidas RSS y RTT de balizas WiFi y Zigbee. **La propagación de las partículas de acuerdo a los pasos fue mejorada, adaptando el modelo del error de acuerdo a las características de los pasos**. Este trabajo fue publicado en la revista Sensors and Actuators A: Physical en 2013 [143].
5. Se estudió **el efecto de utilizar 2 diferentes medidas externas en la estimación a 2 niveles** previamente propuesta. Se estudió **un sistema UWB** con un error bajo pero con poca cobertura y **medidas RSS de balizas RFID** con un error mayor pero cobertura en toda el área de estudio. Se pudieron constatar los efectos de cada medida sobre la estimación y se observó que se obtiene una mejor estimación utilizando medidas externas con mayor cobertura que con medidas externas más precisas pero en un área confinada. Por último **se propuso un algoritmo de detección de outliers** para las medidas precisas y **se evaluó la densidad óptima de balizas** para obtener un correcto posicionamiento. Los hallazgos fueron presentados en la conferencia IPIN 2013 [135].
6. Se propuso **un esquema para integrar la información de mapa (map matching) en la estimación PDR** mediante el filtro de 2 niveles utilizando la verificación de cruce por paredes de las partículas. Para poder acelerar el cómputo en plataformas como MATLAB se propuso una vectorización de las operaciones utilizadas y se minimizaron las verificaciones de cruces utilizando solo las paredes relevantes (de la habitación o alcanzables desde puertas) lo que permitió la escalabilidad del algoritmo. También **se mejoró el modelo de propagación de las partículas** al incluir la estimación del bias de la velocidad angular y **se estudió el efecto de la utilización simultánea del mapa y medidas externas**. Este trabajo fue publicado en la sección especial “Indoor Localization, Tracking, and Mapping With Heterogeneous Technologies” de la revista IEEE Transactions on Vehicular Technology 2015 [141].

6.3. Publicaciones

A continuación se presentan los diferentes trabajos publicados producto de la tesis en revistas internacionales, patentes, congresos internacionales y estancias de investigación. Adicionalmente se citan los trabajos del grupo de investigación en los que se colaboró como coautor.

6.3.1. Revistas Internacionales

- [143] F. Zampella, A. Bahillo, J. Prieto, A.R. Jiménez, and F. Seco, “Pedestrian Navigation fusing Inertial and RSS/TOF measurements with Adaptive Movement/Measurement Mo-

dels: Experimental Evaluation and Theoretical Limits”, in *Sensors and Actuators A: Physical*, Vol. 203, pp-249-260, Diciembre 2013.

- [141] F. Zampella, A.R. Jiménez, and F. Seco, “Indoor Positioning using efficient Map Matching, RSS measurements and an improved motion model”, in *IEEE Transactions on Vehicular Technology*, Vol 64, no 4, pp-1304-1317, Abril 2015

6.3.2. Patentes

- [115] M. Khider, P. Robertson, F. Zampella, A. Jiménez, “Method for estimating the position and orientation using an inertial measurement unit fixed to a moving pedestrian”, WO 2013/160268 A1. Abril 2013

6.3.3. Conferencias Internacionales

- [19] F. Zampella, F. Seco, J.C. Prieto, and J. Guevara, “Simulation of foot-mounted IMU signals for the evaluation of PDR algorithms”. in *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp 1-7, Sept 2011,
- [28] F. Zampella, M. Khider, P. Robertson, A. R. Jiménez, “Unscented Kalman filter and Magnetic Angular Rate Update (MARU) for an improved Pedestrian Dead-Reckoning”, in *Position Location and Navigation Symposium (PLANS), IEEE/ION*, pp. 129-139, Abril 2012.
- [142] F. Zampella, A. De Angelis, I. Skog, D. Zachariah, A. R. Jiménez, “A constraint approach for UWB and PDR fusion”, in *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1-9, Nov. 2012.
- [135] F. Zampella, A.R. Jiménez, and F. Seco, “Robust Indoor positioning fusing PDR and RF technologies: The RFID and UWB case”, in *Proceedings of the 4th International Position and Indoor Navigation Conference (IPIN)*, pp-686-695, Nov 2013

6.3.4. Estancias de investigación Internacionales

El desarrollo de este trabajo de tesis ha permitido multiples colaboraciones internacionales, destacando dos estancias de investigación internacionales:

1. De Junio a Septiembre de 2011: en el Institute of communications and navigation del German Aerospace Center (DLR), Oberpfaffenhofen, Alemania. Esta estancia fue clave en el desarrollo de la estimación por filtro de Kalman Unscented y las medidas de rotación magnética (MARU), permitiendo la publicación de un paper [28] y una patente [115].
2. De Febrero a Agosto de 2012: en el Signal Processing Lab del Royal Institute of Technology (KTH), Estocolmo, Suecia. Esta estancia permitió una profundización en temas de estimación Bayesiana que dieron como fruto la publicación de un paper [142].

6.3.5. Otras Publicaciones como coautor

El autor de la tesis colaboró en los siguientes trabajos:

- [144] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Localización inercial de personas con detección de rampas”. in *Seminario Anual de Automática, Electrónica Industrial e Instrumentación (SAAEI)*, pp 807-812, 2011,
- [145] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Ramp Detection with a Foot-Mounted IMU for a Drift-Free Pedestrian Position Estimation”, in *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp 1-4, Sept 2011,
- [60] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Improved Heuristic Drift Elimination (iHDE) for Pedestrian Navigation in Complex Buildings”, in *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp 1-8, Sept 2011,
- [75] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “PDR with a Foot-Mounted IMU and Ramp Detection”, in *Sensors*, Vol 11, No 10, pp 9393-9410, 2011
- [146] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Indoor Localization and Tracking of Persons using an Inertial Measurement Unit (IMU) and the Signal Strength (RSS) from RFID Tags”, in *Evaluating Ambient Assisted Living Systems through Competitive Benchmarking*, 2012, Winning team in the Localization track,
- [61] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Improved heuristic drift elimination with magnetically-aided dominant directions (MiHDE) for pedestrian navigation in complex buildings”, in *Journal of Location Based Services*, Volume 6, Issue 3, pp 186-210, 2012,
- [147] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Indoor Localization of Persons in AAL scenarios using an Inertial Measurement Unit (IMU) and the Signal Strength (SS) from RFID Tags”, in *Communications in Computer and Information Science*, Springer, pp 32-51, 2013,
- [148] A.R. Jiménez, F. Zampella and F. Seco, “Light-Matching: a new Signal of Opportunity for Pedestrian Indoor Navigation”, in *Proceedings of the 4th International Position and Indoor Navigation Conference (IPIN)*, pp 777-786, 2013
- [149] F. Seco, A.R. Jiménez and F. Zampella, “Joint Estimation of Indoor Position and Orientation from RF Signal Strength Measurements”, in *Proceedings of the 4th International Position and Indoor Navigation Conference (IPIN)*, pp 78-85, 2013
- [92] A.R. Jiménez, F. Zampella and F. Seco, “Improving Inertial Pedestrian Dead-Reckoning by Detecting Unmodified Switched-on Lamps in Buildings”, in *Sensors*, Vol 14, No 1, pp 731-769, 2014
- [150] A.R. Jiménez, F. Zampella and F. Seco, “Método de localización en espacios interiores basado en detección y emparejamiento de puntos de luz”, Patente WO2015/059330 A1. 2015
- [151] E. Muñoz Diaz, F. de Ponte Müller, A. R. Jiménez and F. Zampella, “Evaluation of AHRS algorithms for inertial personal localization in industrial environments” in *IEEE International Conference on Industrial Technology (ICIT)*, Sevilla, pp. 3412-3417, 2015.
- [152] F. Seco, A. R. Jiménez and F. Zampella, “Fine-grained acoustic positioning with compensation of CDMA interference,” in *IEEE International Conference on Industrial Technology (ICIT)*, pp. 3418-3423, Sevilla, 2015.

6.4. Trabajos futuros

Este trabajo se ha centrado en el desarrollo de mejoras a los sistemas de posicionamiento en ambientes interiores. A pesar de las mejoras propuestas, existen aún diversas áreas de trabajo para mejorar el estado actual del arte que se podrían considerar una continuación de esta tesis. Entre los trabajos futuros que vemos interesante abordar, están los siguientes:

- Identificación de las perturbaciones magnéticas observando las diferencias entre las rotaciones del campo magnético y las mediciones de las velocidades angulares mientras la persona se desplaza, para obtener información de la orientación del campo magnético, y por ende mejorar la orientación en estimaciones PDR sin la IMU en el pie o para poder mapear las perturbaciones magnéticas del entorno.
- Desarrollo de un esquema automatizado y estandarizado para obtener el contexto para posicionamiento en interiores. La información del área de estudio puede incluir: mapa del edificio, balizas RF disponibles y sus modelos de propagación, fingerprints, luces, otros usuarios, etc.
- Utilizar medidas de múltiples usuarios suministradas de forma automática (crowdsourcing) para autocalibrar la red de sensores y emisores utilizadas para localizar o evaluar el estado de los dispositivos.
- Adaptar el esquema de posicionamiento a dos niveles para utilizar PDR basado en medidas inerciales de un teléfono móvil. Al no haber correcciones de velocidad nula (ZUPT) la estimación tiene un mayor nivel de error, y necesita utilizar el campo magnético y la observación de la gravedad para disminuir la deriva. Debido a la popularización de los teléfonos móviles, un sistema de posicionamiento PDR con un bajo nivel de error podría ser acogido rápidamente, por lo que es un área de investigación de mucho impacto e importancia.

Capítulo 7

Conclusions and innovations

This chapter resumes the main conclusions and ideas proposed in this thesis, organized according to the scheme in the figure 7.1. The diagram shows the initial objectives defined for this work (Obj. 1.X, Obj. 2.X and Obj. 3.X), covered in chapters 3, 4 and 5, and presented in section 7.1 grouped according to the objectives. Following, section 7.2 shows the innovations presented according to the published works and section 7.3 lists the articles, patents, conference papers and research visits product of this thesis. A final section 7.4 proposes possible areas of research to continue the work laid by this research. For a general overview of each chapter in English you can refer to the extended abstract in English.

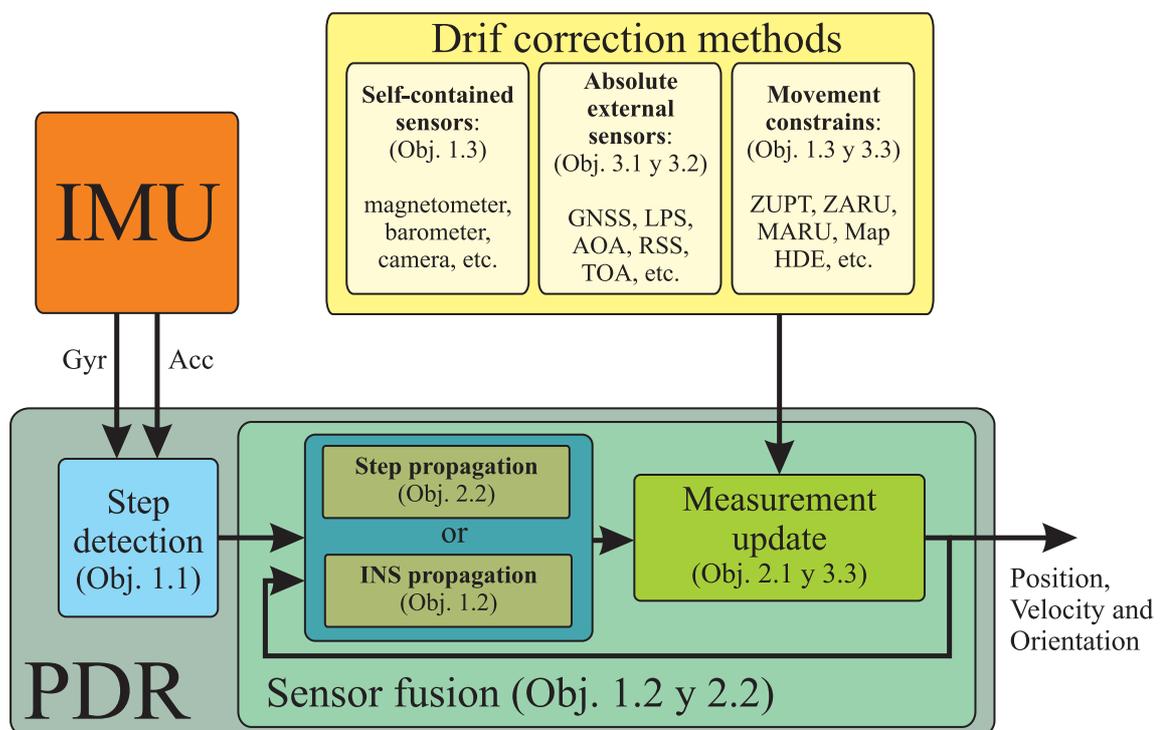


Figura 7.1: Specific objectives defined in each of the blocks of the positioning system scheme.

7.1. Objective specific conclusions

This thesis has treated different aspects of the positioning of pedestrians in indoor environments using inertial sensors and other technologies, and this sections groups all the improvements and conclusions according to the specific objectives initially defined:

7.1.1. Study and propose improvements to the positioning using body-fixed inertial sensors and self-contained measurements (Objective 1)

The first objective refers to the study of the foot-mounted PDR algorithm, using inertial navigation to estimate the position of the foot of a person. The inertial sensor provides a relative positioning with a significantly low error, but requires the identification of the stance phases of the walk pattern, the propagation of the states of the inertial estimation and the associated errors, and the implementation of corrections to minimize the error growth. This points were treated in chapter 3 and their conclusions are presented next:

Objective 1.1: Study the Step detection algorithms and propose possible improvements to the state of the art techniques.

The first step to locate a person using foot-mounted PDR is to identify the stance phase to correct the drift in the inertial estimation. The characteristics of this phase can change for multiple reasons (different persons, floors, shoes, etc.), but it is necessary to define a robust algorithm that adapts to the changes to guaranty its recognition in any case. The most common approach is to set limits to the norm of the accelerations and turn rates to detect the phase, but in this chapter it was shown that a better detection can be achieved using a median filter of a delayed window of magnitude based thresholds.

Once the foot is detected to be in a stance phase, it is possible to apply several corrections, but it was observed that the initial and final instants of the phase can present non zero velocities that introduce a drift in the estimation. This thesis proposes to adapt the certainty of the measurement according to how close it is to the temporal center of the stance and modify the covariance of the measurement accordingly. This modulation of the measurement's covariance was shown to be particularly effective when observing magnetic rotations due to the fact that focuses the effect of the measurement in the central part of the stance (where the magnetic field is closer to constant) and lower the impact of it in the initial and final instants (where the magnetic field might change), improving the effect of the measurement.

Objective 1.2: Study the Sensor fusion filter used (EKF) and evaluate other possible alternatives to improve the handling of non linear characteristics.

The Extended Kalman filter is the most commonly used estimation filter to date, but due to the fact that relies in a linear approximation to treat non linear problems (most real systems are non linear), it tends to generate a drift or bias in the estimated value. This thesis proposed the use of an alternative filter, with a slightly higher computation requirement, the Unscented Kalman filter (UKF or sigma-point Kalman filter), that measures the state propagation and the effect of the observations using a set of sigma points centered in the estimated mean and distributed according to the standard deviation of the states.

The use of the UKF provides a better propagation of the states, mainly the attitude states, and therefore improves the estimation of the position. Additionally it obtains more information from the used observations and simplifies the introduction of non linear measurements that would require the estimation of a gradient for the EKF.

Objective 1.3: Study the magnetic field in indoor environments and possible measures to provide information on the orientation.

The main source of errors in the estimation of the position with inertial sensors is the drift in the yaw, this effect is usually corrected in outdoor environments observing the earth magnetic field, but in indoor environments this field tends to be affected by the metallic structures in the area and may introduce errors in the estimation. This thesis proposed the use of the Magnetic Angular Rate Update (MARU) that measures the rotation of the inertial unit observing the rotation of the magnetic field. As previously discussed, this field might present a perturbation that changes with the position, but this perturbation will remain constant during the stance phase, and therefore it can be used to measure the turn rates perpendicular to the field, but not to measure the absolute orientation.

The MARU provides information to correct the bias in the gyroscope, previously a non completely observable state, by comparing the observed rotation in the magnetic field with the measured turn rates. This measurement of the rotation of the magnetic field reduces the error growth order of the orientation from linearly dependant with time, to proportional to the squared root of the time (as a random walk). The MARU was proposed in 2 schemes, in a EKF estimation and in a UKF estimation, and it was observed that in both cases the orientation error level is reduced, but the UKF achieved the lowest error level.

The measurement requires the IMU to be static to assume a constant magnetic field, and therefore it is affected by the initial and final movements of the stance phase. The effect of the MARU can be improved varying the covariance of the measurement according to the certainty of the stance, enforcing the measurement in the central region of the stance phase and reducing the effect near the edges of it. This type of “soft” measurement diminish even more the orientation error and improves the position estimation.

7.1.2. Study the sensor fusion scheme to improve the use of external measurements (Objective 2).

The second objective focus on improving the sensor fusion scheme to use the information from external measurements, deal with multiple independent positioning systems, or to use independent measurements. The algorithms to fuse multiple estimations was covered in chapter 4, and the main conclusion according to the specific objective were:

Objective 2.1: Study the fusion of different positioning systems using the fact that the distance between them is limited.

The common way to fuse the estimations from several positioning systems in different parts of the body is to use the relative distance between them. However, when using a foot-mounted PDR unit and other positioning sensors in the upper body it is not possible to measure the relative distance in real time. It is possible to relate the information assuming a maximum distance between the estimations that modifies the mean and covariance of the joint estimation in a filter like the EKF, a technique known as constrain filtering.

The chapter presented a version of the constrain filter that uses a grid of points in the joint space to evaluate the effect of the limit in the evolution of the pdf, but due to the number of states, the grid requires too many points to obtain the desired precision. If the state space is modified to limit the effect of the limit to a reduced number of states, the problem can be simplified and the number of states for the grid minimized to 3, independent of the number of

joint states.

It was shown that the fusion scheme was able to reduce the positioning error without knowing the relative position between the estimation, both in Monte Carlo experiments, and fusing foot-mounted PDR signals with an UWB positioning system in the head of a person.

Objective 2.2: Sensor fusion using a particle filter propagated with the steps obtained from PDR and updates from absolute measurement.

Several authors have proposed the use of a 2 level estimation algorithm to handle the non linearities of the observations and propagation in indoor positioning with PDR, this thesis extended that scheme to include as many measurements as possible. The first level of the estimation uses foot-mounted PDR (using an EKF) to extract the displacements between stances of the pedestrian, while a second level uses a particle filter to include external (usually highly non linear) measurements.

This thesis studied the Cramér-Rao lower bound of the estimation and it was observed that in the absence of external measurements the error growth order was lower than the expected, that can cause an underestimation of the error level in those cases. This work proposed a modification of the scheme to adapt the step propagation error to the characteristics of the stride and to model the bias in the turn rate in the vertical turn rate (non observable with only PDR).

The inclusion of the bias adjusted the error to an order growth similar to the expected root mean squared error with real measurements, and therefore improves the propagation when it depends on PDR for long periods without external measurements. The 2 level scheme allows the use of a wider range of measurements without having to linearize or approximate them.

7.1.3. Inclusion of external measurements in the positioning algorithm based on a particle filter. (Objective 3)

The third proposed objective focus in the study of the drift correction methods, due to the fact that as previously discussed, the error of a purely inertial estimation will grow with time, and therefore they need external measurements to contain it. In indoor environments it is common to have RF signals available (WiFi, Bluetooth, RFID, etc.), therefore this thesis was centered in the use of the characteristics of those signals (TDoA, ToA, AoA, RSS, etc.) to relate the position of the beacons with the position of the pedestrian.

Finally, if the map of the building is available, it is possible to locate a person and correct his position based on the path taken (if the path is unique enough). These objectives were treated in chapter 5 and the conclusions grouped accordingly are presented next:

Objective 3.1: Inclusion of measurement from the received signal strength and time of flight in the estimation.

This thesis studied the Cramér-Rao Lower Bound to know the theoretical effect of the inclusion of distance measurements in a 2 level estimation with PDR, comparing it with the root mean squared error of a Monte Carlo experiment. It was observed that the use of external measurements not only limited the drift of the estimation, but generated a lower error (close to 0,5 *m* in our experiment) than using only external measurements (in our case 4,0 *m*) due to using the information from several non correlated measurements.

It was observed that the inclusion of the turn rate bias state in the estimation was not as significant in the presence of constant external measurements, however the effect remains necessary when the estimation doesn't observe absolute measurements for a significant time.

As a way to test the effect of the sensor fusion scheme with real signals, the algorithm was used to fuse PDR with round trip time and received signal strength measurements to WiFi access points in known positions. The use of external measurements created a robust estimation, reducing the error from around 5 m (90% of the time) using only the RF signals, to less than 1,75 m (90% of the time) in the fused algorithm. Finally, it was observed that the adaptive step propagation model reduced the error between 10% and 20%, when compared to a constant error model.

Objective 3.2: Inclusion of time difference of arrival and angle of arrival measurements.

The effect of the use of different absolute measurements on the estimation was analysed fusing the PDR estimation with 2 positioning systems, the first with a low error level, but in a confined area, and the second with a higher error but with a wider coverage. It was observed that the wider coverage of the second measurement was more important to the estimation than the lower error rate of the first measurement, mainly due to the fact that the first relies in uncorrected PDR for a significant part of the time.

The density of beacons was also studied varying the number of active beacons, showing that an increase in the density reduces the error level. However, if the density was higher than a certain threshold (1 beacon per 90 m² in our case) the precision remains approximately similar, but the necessary computing power continues to grow, therefore that point can be defined as an ideal density.

A positioning system with a significantly lower error level allows the estimation to concentrate the pdf in a smaller region, but are easily affected by any outlier in the measurements that could cause a degeneration in the particle distribution. As a way to avoid those cases it is necessary to implement a robust outlier detectors, even if it reduces the number of valid measurements.

Objective 3.3: Include map information in the estimation using an efficient implementation.

The paths of a pedestrian in a building are limited by its structure, therefore by knowing the relative path of a person it is feasible to limit the possible positions to those that follows the structure of the map. After studying the different methods to use the information on the map, this thesis implemented an algorithm based on the elimination of hypotheses that went through walls as proposed by Woodman et.al [55]. The algorithm minimizes the number of cross detections evaluating only the walls of the room that the particle is in.

To optimize the method, in this thesis the operations were vectorized to be used in a development environment like MATLAB efficiently. Additionally, the number of cross detections after passing to a new room was reduced using only the reachable walls from the border between rooms, and defining a structured model of the building including rooms, walls and doors.

The algorithm was tested positioning a person using only PDR and the map of the building. It was shown that this information was enough to generate an absolute positioning of the person, but depends on the uniqueness of the trajectory. The time required to converge to a correct position depends on the trajectory (and the building), but in general several tenths of steps are

required to generate a non symmetrical path, and once the estimation converged, the error level will vary according to the size of the doors and hallways.

Generally if the estimation is done inside of a building, the algorithm corrects the path constantly and it is not necessary to include the turn rate bias among the estimation states, but if the pedestrian passes through outdoor areas or wide rooms without many corrections, the bias estimation might help to correctly estimate the error growth.

The vectorized method using all the walls of the building is not scalable due to the fact that the number of operations for one particle grows with the coverage area. The room based algorithm can not be implemented in MATLAB (due to the slow iterations in this platform), but combining both methods the algorithm becomes scalable and can be implemented in MATLAB.

In most cases, the algorithm requires a significant amount of time/steps and particles to converge, therefore this thesis proposed the use of absolute information to initialize and correct the estimation. By initializing the pdf with the external measurements the number of particles is reduced (limited according to the initial absolute measurements) and the structural symmetries are discarded, reducing the computing time and the estimation error.

7.2. Main innovations

This work has generated several innovations to the state the art in indoor positioning using Pedestrian Dead Reckoning and sensor fusion, producing several publications in journals, patents and conferences. This section presents in a chronological order the innovations according to the presented papers:

1. After **studying the walk pattern of a person and the step detection algorithms in PDR** we proposed a **synthetic signal to emulate the IMU signals from the foot of a pedestrian**. The signal was used to improve the inertial estimation and the step detection algorithm, and allowed us to make Monte Carlo experiments on the evolution of the error in the estimation. This work was presented in the IPIN conference in 2011 [19].
2. Following the study of the inertial estimation and corrections in PDR using an EKF, we proposed **the use of the UKF to improve the non linear propagation and to improve the corrections**. Additionally, due to the non observability of the heading in indoor environments with magnetic perturbations, we proposed **the observation of the changes in the magnetic field in the body frame to measure the rotation of the IMU and therefore the bias in the gyroscope**, a correction named **Magnetic Angular Rate Update (MARU)**. This research was presented in the PLANS conference in 2012 [28] and jointly patented with the German Aerospace Center (DLR) [115].
3. As a way to improve the sensor fusion algorithm to incorporate position information from sensors in different parts of the body, **we proposed the use of a limit (constrain) in the distance between the sensors to correct the joint estimation**. This tool known as **Constrain filter** was used to associate the PDR estimation (in the foot) with an inertial estimation of an IMU in the head of a person with UWB corrections. The system was presented in the IPIN conference in 2012 [142].
4. The sensor fusion scheme to include absolute positioning/measurements in a PDR estimation was improved using a **two level filter**. In the first level footmounted PDR is implemented based on an EKF with zero velocity updates at a high sampling rate, to extract the relative movements of a person (the strides). The next level in the filter uses

the strides to propagate a particle filter corrected according to the observed RSS and RTT measurements from WiFi and ZigBee beacons. **The propagation of the particles was improved adapting the error model according to the characteristics of the step.** This work was published in the *Sensors and Actuators A: Physical* Journal in 2013 [143].

5. **The effect of 2 different external measurements in the two level estimation was analysed.** We studied the use of an **UWB positioning system** with a low error but limited coverage and **RSS measurements from RFID beacons** with a higher error but complete coverage. It was observed that the estimation error was lower using the external measurements with full coverage than the more precise system with a limited coverage. Finally we **proposed an outlier detection algorithm** for the high precision measurements and **optimized the density of the beacons** to obtain a correct positioning in that area. This innovations were presented in the IPIN conference in 2013 [135].
6. We proposed **a scheme to integrate the information of the map in the PDR estimation** using the 2 level filter, based on the detection of wall crossings of the hypothesis in the particle filter. The operations were optimized to be used in research tools like MATLAB using a vectorization, and the number of detections were minimized tracking the room of the particle and checking only the walls in that room (or reachable walls). This improvements limited the number of operations per particle regardless of the area of the map and made the algorithm scalable. It also **improved the propagation model of the particles with the inclusion of the bias in the turn rate and studied the effect of the simultaneous use of the map and external measurements.** This work was published in the especial section “Indoor Localization, Tracking, and Mapping With Heterogeneous Technologies” from the *IEEE Transactions on Vehicular Technology* Journal in 2015 [141].

7.3. Published work

This section presents the different documents published as a result of the research in this thesis in international Journals, patents, international congresses and research visits. It also list the work carried out as part of the research group in which I collaborated as a coauthor.

7.3.1. International Journals

- [143] F. Zampella, A. Bahillo, J. Prieto, A.R. Jiménez, and F. Seco, “Pedestrian Navigation fusing Inertial and RSS/TOF measurements with Adaptive Movement/Measurement Models: Experimental Evaluation and Theoretical Limits”, in *Sensors and Actuators A: Physical*, Vol. 203, pp-249-260, Diciembre 2013.
- [141] F. Zampella, A.R. Jiménez, and F. Seco, “Indoor Positioning using efficient Map Matching, RSS measurements and an improved motion model”, in *IEEE Transactions on Vehicular Technology*, Vol 64, no 4, pp-1304-1317, Abril 2015

7.3.2. Patents

- [115] M. Khider, P. Robertson, F. Zampella, A. Jiménez, “Method for estimating the position and orientation using an inertial measurement unit fixed to a moving pedestrian”, WO 2013/160268 A1. Abril 2013

7.3.3. International conferences

- [19] F. Zampella, F. Seco, J.C. Prieto, and J. Guevara, “Simulation of foot-mounted IMU signals for the evaluation of PDR algorithms”. in *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp 1-7, Sept 2011,
- [28] F. Zampella, M. Khider, P. Robertson, A. R. Jiménez, “Unscented Kalman filter and Magnetic Angular Rate Update (MARU) for an improved Pedestrian Dead-Reckoning”, in *Position Location and Navigation Symposium (PLANS), IEEE/ION*, pp. 129-139, Abril 2012.
- [142] F. Zampella, A. De Angelis, I. Skog, D. Zachariah, A. R. Jiménez, “A constraint approach for UWB and PDR fusion”, in *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp. 1-9, Nov. 2012.
- [135] F. Zampella, A.R. Jiménez, and F. Seco, “Robust Indoor positioning fusing PDR and RF technologies: The RFID and UWB case”, in *Proceedings of the 4th International Position and Indoor Navigation Conference (IPIN)*, pp-686-695, Nov 2013

7.3.4. International research visits

The work for this thesis also allowed several international collaborations, highlighting these two international research visits:

1. From June to September 2011: in the “Institute of communications and navigation” of the German Aerospace Center (DLR), Oberpfaffenhofen, Germany. This visit was the key in the development of the estimation using an Unscented Kalman filter and the Magnetic Angular Rate Update (MARU), producing a conference paper [28] and a patent [115].
2. From February to August 2012: in the “Signal Processing Lab” of the Royal Institute of Technology (KTH), Stockholm, Sweden. This visit allowed me to obtain a deeper understanding of Bayesian estimation that produced a paper in sensor fusion [142].

7.3.5. Other publications as coauthor

The author of this thesis collaborated in this works:

- [144] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Localización inercial de personas con detección de rampas”. in *Seminario Anual de Automática, Electrónica Industrial e Instrumentación (SAAEI)*, pp 807-812, 2011,
- [145] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Ramp Detection with a Foot-Mounted IMU for a Drift-Free Pedestrian Position Estimation”, in *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp 1-4, Sept 2011,
- [60] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Improved Heuristic Drift Elimination (iHDE) for Pedestrian Navigation in Complex Buildings”, in *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, pp 1-8, Sept 2011,
- [75] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “PDR with a Foot-Mounted IMU and Ramp Detection”, in *Sensors*, Vol 11, No 10, pp 9393-9410, 2011

- [146] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Indoor Localization and Tracking of Persons using an Inertial Measurement Unit (IMU) and the Signal Strength (RSS) from RFID Tags”, in *Evaluating Ambient Assisted Living Systems through Competitive Benchmarking*, 2012, Winning team in the Localization track,
- [61] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Improved heuristic drift elimination with magnetically-aided dominant directions (MiHDE) for pedestrian navigation in complex buildings”, in *Journal of Location Based Services*, Volume 6, Issue 3, pp 186-210, 2012,
- [147] A.R. Jiménez, F. Seco, F. Zampella, C.Prieto and J. Guevara, “Indoor Localization of Persons in AAL scenarios using an Inertial Measurement Unit (IMU) and the Signal Strength (SS) from RFID Tags”, in *Communications in Computer and Information Science*, Springer, pp 32-51, 2013,
- [148] A.R. Jiménez, F. Zampella and F. Seco, “Light-Matching: a new Signal of Opportunity for Pedestrian Indoor Navigation”, in *Proceedings of the 4th International Position and Indoor Navigation Conference (IPIN)*, pp 777-786, 2013
- [149] F. Seco, A.R. Jiménez and F. Zampella, “Joint Estimation of Indoor Position and Orientation from RF Signal Strength Measurements”, in *Proceedings of the 4th International Position and Indoor Navigation Conference (IPIN)*, pp 78-85, 2013
- [92] A.R. Jiménez, F. Zampella and F. Seco, “Improving Inertial Pedestrian Dead-Reckoning by Detecting Unmodified Switched-on Lamps in Buildings”, in *Sensors*, Vol 14, No 1, pp 731-769, 2014
- [150] A.R. Jiménez, F. Zampella and F. Seco, “Método de localización en espacios interiores basado en detección y emparejamiento de puntos de luz”, Patente WO2015/059330 A1. 2015
- [151] E. Muñoz Diaz, F. de Ponte Müller, A. R. Jiménez and F. Zampella, “Evaluation of AHRS algorithms for inertial personal localization in industrial environments” in *IEEE International Conference on Industrial Technology (ICIT)*, Sevilla, pp. 3412-3417, 2015.
- [152] F. Seco, A. R. Jiménez and F. Zampella, “Fine-grained acoustic positioning with compensation of CDMA interference,” in *IEEE International Conference on Industrial Technology (ICIT)*, pp. 3418-3423, Sevilla, 2015.

7.4. Future research subjects

This research has focused on the improvements to the indoor positioning systems and following the analysis of the current state of the art, these areas for future research are proposed:

- Identify the magnetic perturbations observing the differences in the rotation of the observed magnetic field and the measured turn rates while the person is walking, as a way to obtain information on the orientation of the magnetic field and improve PDR estimation with non foot-mounted IMUs, or to be able to map the magnetic disturbances in the environment.
- Develop a system to automatically obtain the context for indoor positioning. This area information could include: the map of the building, the RF beacons in the area and their propagation models, fingerprints, lights, other users, etc.

- Use the information automatically gathered from multiple users (crowdsourcing) to calibrate the sensor and beacon networks used to locate a person, or to monitor their state.
- Adapt the two levels positioning scheme to use PDR based in inertial measurements from a mobile phone. This is a challenging escenario mainly due to the lack of a zero velocity phase to limit the drift and relies in other methods like step counting, magnetic navigation and measuring the gravity to reduce the drift. Due to the popularization of the mobile devices (smartphones, tablets, etc.) there is a significant interest in the development of a system able to provide good positioning indoor and it would be immediately adopted by the current manufacturers and developers.

Capítulo 8

Bibliografía

Bibliografía

- [1] D. Lowe, "Object recognition from local scale-invariant features," in *Computer Vision, 1999. The Proceedings of the Seventh IEEE International Conference on*, vol. 2, 1999, pp. 1150–1157 vol.2.
- [2] H. Bay, A. Ess, T. Tuytelaars, and L. Van Gool, "Speeded-Up Robust Features (SURF)," *Computer Vision and Image Understanding*, vol. 110, no. 3, pp. 346–359, June 2008. [Online]. Available: <http://dx.doi.org/10.1016/j.cviu.2007.09.014>
- [3] S. Rajagopal, "Personal dead reckoning system with shoe mounted inertial sensors," Master's thesis, Royal Institute of Technology, Oct 2008. [Online]. Available: https://eeweb01.ee.kth.se/upload/publications/reports/2008/XR-EE-SB_2008_013.pdf
- [4] T. Logsdon, *Understanding the Navstar: GPS, GIS, IVHS*, ser. Electrical Engineering. Springer, 1995. [Online]. Available: <http://books.google.es/books?id=dc7v1uGkwfMC>
- [5] N. Bowditch, N. Imagery, and M. Agency, *The American Practical Navigator - Bowditch*, ser. Pub. (United States. National Imagery and Mapping Agency). Midpoint Trade Books Incorporated, 2002. [Online]. Available: http://books.google.es/books?id=pXjHDnIE_ygC
- [6] D. Titterton and J. Weston, *Strapdown Inertial Navigation Technology*, 2nd ed. The American Institute of Aeronautics and Astronautics, 2004.
- [7] W. Branch, E. Brook-Williams, and A. Weems System of Navigation, *A Short History of Navigation*. Weems system of navigation, 1942. [Online]. Available: <http://books.google.es/books?id=SsVEAAAAIAAJ>
- [8] O. Woodman, "Introduction to Inertial Navigation," Cambridge, p. 37, Jan. 2007.
- [9] S. Nasiri, M. Lim, and M. Housholder, "A critical review of the market status and industry challenges of producing consumer grade mems gyroscopes," Invensense, Tech. Rep., 2010.
- [10] N. Yazdi, F. Ayazi, and K. Najafi, "Micromachined inertial sensors," *Proceedings of the IEEE*, vol. 86, no. 8, pp. 1640–1659, 1998. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=704269>
- [11] D. Gebre-Egziabher, "Design and performance analysis of a low-cost aided dead reckoning navigator," Ph.D. dissertation, Stanford University, 2004.
- [12] S. Nassar, "Improving the Inertial Navigation System (INS) Error Model for INS and INS / DGPS Applications," Ph.D. dissertation, Department of Geomatics Engineering, University of Calgary, 2003.
- [13] M. Keshner, "1/f noise," *Proceedings of the IEEE*, vol. 70, pp. 212–218, 1982. [Online]. Available: <http://ieeexplore.ieee.org/iel5/5/31311/01456550.pdf?arnumber=1456550>

- [14] M. El-Diasty, a. El-Rabbany, and S. Pagiatakis, "Temperature variation effects on stochastic characteristics for low-cost MEMS-based inertial sensor error," *Measurement Science and Technology*, vol. 18, no. 11, pp. 3321–3328, Nov. 2007.
- [15] "IEEE Standard Specification Format Guide and Test Procedure for Single-axis Interferometric Fiber Optic Gyros, IEEE Std 952-1997 (R2008)," 1997.
- [16] A. Chatfield, *Fundamentals of High Accuracy Inertial Navigation*. AIAA, American Institute of of Aeronautics and Astronautics, 1997.
- [17] R. Rogers, *Applied Mathematics in Integrated Navigation Systems*. AIAA Education Series. Washington, DC., 2003.
- [18] A. R. Jiménez, F. Seco, J. C. Prieto, and J. Guevara, "Indoor pedestrian navigation using an INS/EKF framework for yaw drift reduction and a foot-mounted IMU," in *Positioning Navigation and Communication (WPNC), 2010 7th Workshop on*, 3 2010, pp. 135–143.
- [19] F. Zampella, A. R. Jiménez, F. Seco, J. C. Prieto, and J. Guevara, "Simulation of foot-mounted IMU signals for the evaluation of PDR algorithms," in *Indoor Positioning and Indoor Navigation (IPIN), International Conference on*, sept. 2011, pp. 1–7.
- [20] E. M. Foxlin, "Pedestrian tracking with shoe-mounted inertial sensors," *Computer Graphics and Applications, IEEE*, vol. 25, no. 6, pp. 38–46, Nov.-Dec. 2005.
- [21] V. Renaudin, V. Demeule, and M. Ortiz, "Adaptative pedestrian displacement estimation with a smartphone," in *Proceedings of the Indoor Positioning and Indoor Navigation*, October 2013, pp. 916–924.
- [22] I. Skog, P. Handel, J. Nilsson, and J. Rantakokko, "Zero-velocity detection - an algorithm evaluation," *Biomedical Engineering, IEEE Transactions on*, vol. 57, no. 11, pp. 2657–2666, nov. 2010.
- [23] R. Stirling, "Development of a Pedestrian Navigation System Using Shoe Mounted Sensors," Master's thesis, University of Alberta, 2004.
- [24] L. Ojeda and J. Borenstein, "Non-GPS navigation with the personal dead-reckoning system," in *SPIE Defense and Security Conference, Unmanned Systems Technology IX, Orlando, Florida*. Spie, 2007, pp. 65 610C–65 610C–11. [Online]. Available: <http://link.aip.org/link/PSISDG/v6561/i1/p65610C/s1&Agg=doi>
- [25] F. Seco, A. R. Jiménez, J. C. Prieto, J. Roa, and K. Koutsou, "A survey of mathematical methods for indoor localization," in *WISP 2009 - 6th IEEE International Symposium on Intelligent Signal Processing*, Budapest, 2009, pp. 9–14. [Online]. Available: <http://www.car.upm-csic.es/lopsi/static/publications.htm>
- [26] V. Renaudin, M. Afzal, and G, "New method for magnetometers based orientation estimation," in *Position Location And Navigation Symposium*, 2010, p. 9. [Online]. Available: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5507301
- [27] M. H. Afzal, "Use of earth's magnetic field for pedestrian navigation," Ph.D. dissertation, University of Calgary, July 2011.
- [28] F. Zampella, M. Khider, P. Robertson, and A. R. Jiménez, "Unscented Kalman filter and Magnetic Angular Rate Update (MARU) for an improved Pedestrian Dead-Reckoning," in *Position Location and Navigation Symposium (PLANS), IEEE/ION*, april 2012, pp. 129–139.

- [29] A. R. Jiménez, F. Seco, J. C. Prieto, and J. Guevara, “Accurate Pedestrian Indoor Navigation by Tightly Coupling Foot-Mounted IMU and RFID Measurements,” *Instrumentation and Measurement, IEEE Transactions on*, vol. 61, no. 1, pp. 178–189, jan. 2012.
- [30] S. J. Julier and J. K. Uhlmann, “A new extension of the kalman filter to nonlinear systems,” in *Proc. of AeroSense: The 11th Int. Symp. on Aerospace/Defence Sensing, Simulation and Controls*, 1997, pp. 182–193.
- [31] E. Wan and R. Van Der Merwe, “The unscented kalman filter for nonlinear estimation,” in *Adaptive Systems for Signal Processing, Communications, and Control Symposium. AS-SPCC*, 2000, pp. 153–158.
- [32] F. Zampella, “Localización de personas mediante sensores inerciales usando el filtro de Kalman Unscented,” Master’s thesis, Universidad de Alcalá, 2012.
- [33] S. S. Haykin, *Kalman filtering and neural networks*. Wiley, 2001.
- [34] D. Zachariah, I. Skog, M. Jansson, and P. Händel, “Bayesian estimation with distance bounds,” in *IEEE Signal Processing Letters (Accepted for publication)*, 2012.
- [35] D. Zachariah and M. Jansson, “Fusing visual tags and inertial information for indoor navigation,” in *Position Location and Navigation Symposium (PLANS)*, 2012.
- [36] G. Panahandeh, D. Zachariah, and M. Jansson, “Exploiting ground plane constraints for visual-inertial navigation,” in *Position Location and Navigation Symposium (PLANS), IEEE/ION*, april 2012, pp. 527–534.
- [37] A. S. Paul and E. A. Wan, “RSSI-Based Indoor Localization and Tracking Using Sigma-Point Kalman Smoothers,” *IEEE Journal of Selected Topics in Signal Processing*, vol. 3, no. 5, pp. 860–873, Oct. 2009. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5290385>
- [38] S. Thrun, W. Burgard, and D. Fox, *Probabilistic Robotics*, ser. Intelligent Robotics and Autonomous Agents. MIT Press, 2005. [Online]. Available: http://books.google.es/books?id=k_yOQgAACAAJ
- [39] M. Arulampalam, S. Maskell, N. Gordon, and T. Clapp, “A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking,” *Signal Processing, IEEE Transactions on*, vol. 50, no. 2, pp. 174–188, feb 2002.
- [40] F. Daum and J. Huang, “Curse of dimensionality and particle filters,” in *Aerospace Conference. Proceedings. IEEE*, vol. 4, 2003, pp. 1979–1993.
- [41] A. Doucet, S. Godsill, and C. Andrieu, “On sequential monte carlo sampling methods for bayesian filtering,” *Statistics and Computing*, vol. 10, no. 3, pp. 197–208, 2000. [Online]. Available: <http://dx.doi.org/10.1023/A%3A1008935410038>
- [42] G. Kitagawa, “Monte carlo filter and smoother for non-gaussian nonlinear state space models,” *Journal of Computational and Graphical Statistics*, vol. 5, no. 1, pp. pp. 1–25, 1996. [Online]. Available: <http://www.jstor.org/stable/1390750>
- [43] M. J. Veth, “Tutorial on nonlinear estimation techniques for aided navigation systems,” in *Position Location and Navigation Symposium (PLANS)*, 2012.

- [44] P. Robertson, M. Angermann, and B. Krach, "Simultaneous localization and mapping for pedestrians using only footmounted inertial sensors," in *In Proc. UbiComp, ACM*, 2009, pp. 93–96.
- [45] S. Kaiser, M. Khider, and P. Robertson, "A maps-based angular pdf for navigation systems in indoor and outdoor environments," in *Indoor Positioning and Indoor Navigation (IPIN), International Conference on*, sept. 2011, pp. 1–7.
- [46] L. Bruno and P. Robertson, "Wislam: Improving footslam with wifi," in *Indoor Positioning and Indoor Navigation (IPIN), International Conference on*, sept. 2011, pp. 1–10.
- [47] A. R. Jiménez, F. Seco, J. C. Prieto, and J. Guevara, "A comparison of Pedestrian Dead-Reckoning algorithms using a low-cost MEMS IMU," in *IEEE International Symposium on Intelligent Signal Processing*. Ieee, Aug. 2009, pp. 37–42. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5286542>
- [48] H. Weinberg, "Using the ADXL202 in Pedometer and Personal Navigation Applications," pp. 1–8, 2002.
- [49] D. Alvarez, R. Gonzalez, A. Lopez, and J. Alvarez, "Comparison of step length estimators from wearable accelerometer devices," in *Engineering in Medicine and Biology Society EMBS. 28th Annual International Conference of the IEEE*, Aug 2006, pp. 5964–5967.
- [50] S. H. Shin, C. G. Park, J. W. Kim, H. S. Hong, and J. M. Lee, "Adaptive Step Length Estimation Algorithm Using Low-Cost MEMS Inertial Sensors," *IEEE Sensors Applications Symposium*, no. February, pp. 1–5, Feb. 2007.
- [51] S. Moafipoor, D. A. Grejner-Brzezinska, C. Toth, and C. Rizos, "Quality Assurance/Quality Control Analysis of Dead Reckoning Parameters in a Personal Navigator," in *Location Based Services and TeleCartography II*, vol. 2. Springer, 2009, pp. 333–351. [Online]. Available: <http://www.springerlink.com/index/P6LN357058707281.pdf>
- [52] P. Tomé, F. Bonzou, B. Merminod, and K. Aminian, "Improving pedestrian dynamics modelling using fuzzy logic," *Position Location And Navigation Symposium*, pp. 1–7, 2010.
- [53] H. Niedermeier, G. Ameres, T. Pany, and B. Eissfeller, "First results from supporting long coherent CDMA correlations by a MEMS INS and a Pedestrian Navigation System for HS-GNSS applications," *2009 6th Workshop on Positioning, Navigation and Communication*, vol. 2009, pp. 5–13, Mar. 2009. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4907797>
- [54] S. Beauregard, Widyawan, and M. Klepal, "Indoor pdr performance enhancement using minimal map information and particle filters," in *2008 IEEE/ION Position, Location and Navigation Symposium*, May 2008, pp. 141–147.
- [55] O. Woodman and R. Harle, "Pedestrian localisation for indoor environments," *Proceedings of the 10th international conference on Ubiquitous computing - UbiComp*, p. 114, 2008. [Online]. Available: <http://portal.acm.org/citation.cfm?doid=1409635.1409651>
- [56] B. Krach and P. Robertson, "Cascaded estimation architecture for integration of foot-mounted inertial sensors," in *Position, Location and Navigation Symposium*, 2008, pp. 112–119. [Online]. Available: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4570047
- [57] R. Feliz, E. Zalama, and J. García-Bermejo, "Pedestrian tracking using inertial sensors," *Journal of Physical Agents*, vol. 3, no. 1, pp. 35–43, 2009. [Online]. Available: <http://www.doaj.org/doaj?func=abstract&id=490284>

- [58] J. Borenstein, L. Ojeda, and S. Kwanmuang, “Heuristic Reduction of Gyro Drift for Personnel Tracking Systems,” *Journal of Navigation*, vol. 62, no. 1, p. 41, Dec. 2008. [Online]. Available: http://www.journals.cambridge.org/abstract_S0373463308005043
- [59] J. Borenstein and L. Ojeda, “Heuristic Drift Elimination for Personnel Tracking Systems,” *Journal of Navigation*, vol. 63, no. 04, pp. 591–606, Sept. 2010. [Online]. Available: http://www.journals.cambridge.org/abstract_S0373463310000184
- [60] A. R. Jiménez, F. Seco, F. Zampella, J. Prieto, and J. Guevara, “Improved Heuristic Drift Elimination (iHDE) for pedestrian navigation in complex buildings,” in *Indoor Positioning and Indoor Navigation (IPIN), International Conference on*, Sept 2011, pp. 1–8.
- [61] A. R. Jiménez, F. Seco, F. Zampella, J. C. Prieto, and J. Guevara, “Improved heuristic drift elimination with magnetically-aided dominant directions (MiHDE) for pedestrian navigation in complex buildings,” *Journal of Location Based Services*, vol. 6, no. 3, pp. 186–210, 2012. [Online]. Available: <http://www.tandfonline.com/doi/abs/10.1080/17489725.2012.687779>
- [62] M. Quddus, W. Ochieng, and R. Noland, “Current map-matching algorithms for transport applications: State-of-the art and future research directions,” *Transportation Research Part C: Emerging Technologies*, vol. 15, no. 5, pp. 312–328, Oct. 2007. [Online]. Available: <http://linkinghub.elsevier.com/retrieve/pii/S0968090X07000265>
- [63] M. Attia, A. Moussa, X. Zhao, and N. El-Sheimy, “Assisting personal positioning in indoor environments using map matching,” *Archives of Photogrammetry, Cartography and Remote Sensing*, vol. 22, pp. 39–49, 2011.
- [64] M. Attia, A. Moussa, and N. El-Sheimy, “Map aided pedestrian dead reckoning using buildings information for indoor navigation applications,” *Positioning*, vol. 04, no. 03, pp. 227–239, 2013.
- [65] I. Spassov, “Algorithms for Map-Aided Autonomous Indoor Pedestrian Positioning and Navigation,” Ph.D. dissertation, EPFL-ÉCOLE POLYTECHNIQUE FÉDÉRALE DE LAUSANNE, 2007.
- [66] B. Krach and P. Robertson, “Integration of foot-mounted inertial sensors into a Bayesian location estimation framework,” *5th Workshop on Positioning, Navigation and Communication*, pp. 55–61, 3 2008. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4510357>
- [67] C. Ascher, C. Kessler, R. Weis, and G. Trommer, “Multi-floor map matching in indoor environments for mobile platforms,” in *Proceedings of the International Conference on Indoor Positioning and Indoor Navigation, IPIN*, Sydney, NSW, 2012, pp. 1–8.
- [68] K. V. Laerhoven and O. Cakmakci, “What shall we teach our pants?” in *4th Int. Symp. on Wearable Computers.*, 2000, pp. 77–83. [Online]. Available: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=888468
- [69] F. Korbinian, M. J. Vera-Nadales, P. Robertson, and M. Angermann, “Reliable Real-Time Recognition of Motion Related Human Activities Using MEMS Inertial Sensors,” in *ION GNSS*, 2010, p. 14.
- [70] M. J. Vera-Nadales, “Recognition of Human Motion related activities from sensors,” Ph.D. dissertation, University of Malaga, 2010.

- [71] G. Shi, Y. Zou, Y. Jin, X. Cui, and W. J. Li, "Towards HMM based human motion recognition using MEMS inertial sensors," in *IEEE International Conference on Robotics and Biomimetics*, Feb 2008, pp. 1762–1766.
- [72] K. Altun, B. Barshan, and O. Tuncel, "Comparative study on classifying human activities with miniature inertial and magnetic sensors," *Pattern Recognition*, vol. 43, no. 10, pp. 3605–3620, Oct. 2010. [Online]. Available: <http://linkinghub.elsevier.com/retrieve/pii/S0031320310001950>
- [73] D. Gusenbauer, C. Isert, and J. Krösche, "Self-Contained Indoor Positioning on Off-The-Shelf Mobile Devices," in *International Conference on Indoor Positioning and Indoor Navigation*, no. September, 2010, pp. 15–17.
- [74] M. Kouroggi, T. Ishikawa, and T. Kurata, "A method of pedestrian dead reckoning using action recognition," in *Position Location And Navigation Symposium*, 2010. [Online]. Available: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5507239
- [75] A. R. Jiménez, F. Seco, F. Zampella, J. C. Prieto, and J. Guevara, "PDR with a Foot-Mounted IMU and Ramp Detection," *Sensors*, vol. 10, pp. 9393–9410, 2011. [Online]. Available: <http://www.mdpi.com/1424-8220/11/10/9393>
- [76] M. Hardegger, D. Roggen, S. Mazilu, and G. Troster, "ActionSLAM: Using location-related actions as landmarks in pedestrian SLAM," in *Indoor Positioning and Indoor Navigation (IPIN), International Conference on*, Nov 2012, pp. 1–10.
- [77] *A Quick Derivation relating altitude to air pressure*, Portland State Aerospace Society Std., 2004, portland State Aerospace Society.
- [78] K. Sagawa, H. Inooka, and Y. Satoh, "Non-restricted measurement of walking distance," *Systems, Man, and cybernetics*, pp. 1847–1852, 2000. [Online]. Available: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=886378
- [79] Honeywell, "Precision Indoor Personnel Location and Tracking for Emergency Responders," in *Worcester Polytechnic Institute*, 2009, p. 20.
- [80] T. Pany, J. Winkel, B. Riedl, M. Restle, T. Wörz, R. Schweikert, H. Niedermeier, G. Amers, B. Eissfeller, and S. Lagrasta, "Performance of a Partially Coherent Ultra-Tightly Coupled GNSS/INS Pedestrian Navigation System Enabling Coherent Integration Times of Several Seconds to Track GNSS Signals Down to 1.5 dBHz." in *22st International Technical Meeting of the Satellite Division of The Institute of Navigation ION GNSS*, 2009, p. 16. [Online]. Available: <http://navx-rps.com/content/publications/2009/DingposIon2009.pdf>
- [81] G. Retscher, "Location Determination in Indoor Environments for Pedestrian Navigation," *IEEE/ION Position, Location, And Navigation Symposium*, pp. 547–555, 2006. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1650643>
- [82] W. Chai, C. Chen, E. Edwan, J. Zhang, and O. Loffeld, "2d/3d indoor navigation based on multi-sensor assisted pedestrian navigation in wi-fi environments," in *Ubiquitous Positioning, Indoor Navigation, and Location Based Service (UPINLBS)*, Oct 2012, pp. 1–7.
- [83] M. Tanigawa, H. Luinge, L. Schipper, and P. Slycke, "Drift-free dynamic height sensor using MEMS IMU aided by MEMS pressure sensor," *5th Workshop on Positioning, Navigation and Communication*, pp. 191–196, Mar. 2008. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4510374>

- [84] J. Parviainen, J. Kantola, and J. Collin, "Differential barometry in personal navigation," in *Position Location And Navigation Symposium*, 2008, pp. 148–152. [Online]. Available: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4570051
- [85] Q. Ladetto and B. Merminod, "In Step with INS Navigation for the Blind, Tracking Emergency Crews," *GPS World*, vol. 13, no. October, p. 6, 2002.
- [86] Q. Ladetto, J. V. Seeters, S. Sokolowski, Z. Sagan, and B. Merminod, "Digital Magnetic Compass and Gyroscope for Dismounted Soldier Position and Navigation," *Sensors & Electronics Technology Panel, NATO Research and Technology Agency Sensors*, pp. 1–15, 2002.
- [87] M. Angermann, M. Frassl, M. Doniec, B. Julian, and P. Robertson, "Characterization of the indoor magnetic field for applications in localization and mapping," in *Indoor Positioning and Indoor Navigation (IPIN), International Conference on*, Nov 2012, pp. 1–9.
- [88] P. Robertson, M. Frassl, M. Angermann, M. Doniec, B. J. Julian, M. Garcia Puyol, M. Khider, M. Lichtenstern, and L. Bruno, "Simultaneous Localization and Mapping for Pedestrians using Distortions of the Local Magnetic Field Intensity in Large Indoor Environments," in *Proceedings of the 4th Indoor Positioning and Indoor Navigation Conference (IPIN)*, 2013, pp. 929–938.
- [89] J. Rantakokko, J. Rydell, P. Stromback, P. Handel, J. Callmer, D. Tornqvist, F. Gustafsson, M. Jobs, and M. Gruden, "Accurate and reliable soldier and first responder indoor positioning: multisensor systems and cooperative localization," *Wireless Communications, IEEE*, vol. 18, no. 2, pp. 10–18, april 2011.
- [90] J. Rydell and E. Emilsson, "Chameleon: Visual-inertial indoor navigation," in *Position Location and Navigation Symposium (PLANS)*, 2012.
- [91] M. J. Veth, "Fusion of imaging and inertial sensors for navigation," Ph.D. dissertation, AIR FORCE INSTITUTE OF TECHNOLOGY, 2006.
- [92] A. R. Jiménez, F. Zampella, and F. Seco, "Improving Inertial Pedestrian Dead-Reckoning by Detecting Unmodified Switched-on Lamps in Buildings," *Sensors*, vol. 14, pp. 731–769, 2014.
- [93] Z. Zhou, Y. Li, C. Rizos, and Y. Shen, "A robust integration of GPS and MEMS-INS through trajectory-constrained adaptive Kalman filtering," *Cartographica*, 2009.
- [94] H. Qi, "Direct Kalman Filtering Approach for GPS/INS Integration," *IEEE Transactions On Aerospace And Electronic Systems*, vol. 38, no. 2, pp. 687–693, 2002.
- [95] Y. Li, J. Wang, C. Rizos, P. Mumford, and W. Ding, "Low-cost tightly coupled GPS/INS integration based on a nonlinear Kalman filtering design," in *Proceedings of ION National*, 2006, p. 9.
- [96] D. Bernal, P. Closas, E. Calvo, and J. A. Fernandez-Rubio, "Tight GNSS / INS integration as a constrained least-squares problem," in *17th European Signal Processing (EUSIPCO), Glasgow, Scotland, August 24-28, 2009*, pp. 85–89.
- [97] G. Yuan and T. Zhang, "Unscented kalman filtering for ultra-tightly coupled gps/ins integration," in *Mechatronics and Automation, International Conference on (ICMA)*, Aug 2009, pp. 4556–4560.

- [98] V. Renaudin, O. Yalak, P. Tomé, and B. Merminod, "Indoor Navigation of Emergency Agents," *European Journal of Navigation*, vol. 5, no. 3, p. 10, 2007.
- [99] J. Bancroft, G. Lachapelle, M. E. Cannon, and M. G. Petovello, "Twin IMU-HSGPS integration for pedestrian navigation," in *ION GNSS*, 2008, pp. 16–20. [Online]. Available: <http://www.ion-alberta.org/meetings/08.10.03-Bancroft-TwinIMUIntegration.pdf>
- [100] G. Retscher and Q. Fu, "Integration of RFID, GNSS and DR for ubiquitous positioning in pedestrian navigation," *Journal of Global Positioning Systems*, vol. 6, no. 1, pp. 56–64, 2007.
- [101] S. Godha, G. Lachapelle, and M. E. Cannon, "Integrated GPS / INS System for Pedestrian Navigation in a Signal Degraded Environment," in *ION GNSS*, 2006, pp. 26–29.
- [102] L. Fang, P. Antsaklis, L. Montestruque, M. McMickell, M. Lemmon, Y. Sun, H. Fang, I. Koutroulis, M. Haenggi, M. Xie, and X. Xie, "Design of a Wireless Assisted Pedestrian Dead Reckoning System - The NavMote Experience," *IEEE Transactions on Instrumentation and Measurement*, vol. 54, no. 6, pp. 2342–2358, Dec. 2005. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1542534>
- [103] S. House, S. Connell, I. Milligan, D. Austin, T. Hayes, and P. Chiang, "Indoor localization using pedestrian dead reckoning updated with rfid-based fiducials," in *Engineering in Medicine and Biology Society (EMBC), Annual International Conference of the IEEE*, 2011, pp. 7598–7601.
- [104] F. Korbinian, B. Krach, N. Catterall, and P. Robertson, "Development and Evaluation of a Combined WLAN & Inertial Indoor Pedestrian Positioning System," in *4th International Symposium on Location and Context Awareness. ION GNSS*, 2009.
- [105] P. Kemppi, T. Rautiainen, V. Ranki, F. Belloni, and J. Pajunen, "Hybrid positioning system combining angle-based localization, pedestrian dead reckoning and map filtering," in *International Conference on Indoor Positioning and Indoor Navigation*, September 2010, pp. 15–17.
- [106] H. K. Hwang, Z. Aliyazicioglu, M. Grice, and A. Yakovlev, "Direction of arrival estimation using a root-music algorithm," in *Proceedings of the International MultiConference of Engineers and Computer Scientists IMECS*, vol. II, 3 2008.
- [107] D. Inserra, A. Tonello, and N. Moret, "Positioning Based on 2-D Angle of Arrival Estimation," in *Vehicular Technology Conference (VTC Spring), IEEE 73rd*, 5 2011, pp. 1–5.
- [108] V. Renaudin and B. Merminod, "Optimal data fusion for pedestrian navigation based on UWB and MEMS," in *Position Location And Navigation Symposium*, 2008, pp. 341–349. [Online]. Available: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4570054
- [109] Ubisense Ltd., *The Ubisense Precise Real-time Location System - Series 7000 Sensor*, 2011. [Online]. Available: <http://www.ubisense.net/>
- [110] B. Hartmann, N. Link, and G. Trommer, "Indoor 3D position estimation using low-cost inertial sensors and marker-based video-tracking," in *Position Location And Navigation Symposium*, 2010, pp. 319–326. [Online]. Available: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5507248

- [111] S. Y. Seidel and T. S. Rappaport, "914 MHz path loss prediction models for indoor wireless communications in multifloored buildings," *IEEE Trans. on Antennas and Propagation*, vol. 40, no. 2, pp. 207–217, 1992.
- [112] J. Seitz, T. Vaupel, J. Jahn, S. Meyer, J. Boronat, and J. Thielecke, "A hidden markov model for urban navigation based on fingerprinting and pedestrian dead reckoning," in *Information Fusion (FUSION), 13th Conference on*, July 2010, pp. 1–8.
- [113] V. Maximov and O. Tabarovsky, "Survey of Accuracy Improvement Approaches for Tightly Coupled ToA/IMU Personal Indoor Navigation System," in *Proceedings of the 4th Indoor Positioning and Indoor Navigation Conference (IPIN)*, 2013, pp. 31–34.
- [114] A. Bahillo, J. Prieto, S. Mazuelas, R. Lorenzo, P. Fernandez, and E. Abril, "Indoor location based on ieee 802.11 round-trip time measurements with two-step nlos mitigation," *Progress in Electromagnetics Research, PIER B*, vol. 15, pp. 285–306, 2009.
- [115] M. Khider, P. Robertson, F. Zampella, and A. Jimenez, "Method for estimating the position and orientation using an inertial measurement unit fixed to a moving pedestrian," International Patent WO 2013/160 268 A1, 2013.
- [116] M. Angermann, P. Robertson, T. Kemptner, and M. Khider, "A High Precision Reference Data Set for Pedestrian Navigation using Foot-Mounted Inertial Sensors," in *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, no. September, 2010, p. 6. [Online]. Available: <http://www.kn-s.dlr.de/People/Angermann/Welcome/AngermannEtAlIPIN2010.pdf>
- [117] M. Khider, P. Robertson, F. Zampella, and A. Jiménez, "Method for estimating the position and orientation using an inertial measurement unit fixed to a moving pedestrian," International Patent WO 2013/160 286 A1, October 31, 2013.
- [118] D. Simon and T. L. Chia, "Kalman filtering with state equality constraints," *Aerospace and Electronic Systems, IEEE Transactions on*, vol. 38, no. 1, pp. 128–136, jan 2002.
- [119] S. Julier and J. LaViola, "On kalman filtering with nonlinear equality constraints," *Signal Processing, IEEE Transactions on*, vol. 55, no. 6, pp. 2774–2784, june 2007.
- [120] D. Simon, "Kalman filtering with state constraints: a survey of linear and nonlinear algorithms," *Control Theory Applications, IET*, vol. 4, no. 8, pp. 1303–1318, august 2010.
- [121] C. Yang and E. Blasch, "Kalman filtering with nonlinear state constraints," *Aerospace and Electronic Systems, IEEE Transactions on*, vol. 45, no. 1, pp. 70–84, jan. 2009.
- [122] D. Simon and D. L. Simon, "Constrained kalman filtering via density function truncation for turbofan engine health estimation," *Intern. J. Syst. Sci.*, vol. 41, no. 2, pp. 159–171, Feb. 2010. [Online]. Available: <http://dx.doi.org/10.1080/00207720903042970>
- [123] *DRM 4000L Dead Reckoning Module*, Honeywell.
- [124] J.-O. Nilsson, I. Skog, P. Handel, and K. Hari, "Foot-mounted INS for everybody - an open-source embedded implementation," in *Position Location and Navigation Symposium (PLANS), IEEE/ION*, april 2012, pp. 140–145.
- [125] R. Harle, "A Survey of Indoor Inertial Positioning Systems for Pedestrians," *Communications Surveys Tutorials, IEEE*, vol. 15, no. 3, pp. 1281–1293, Third 2013.

- [126] F. Wong, C. K. Carter, and R. Kohn, "Efficient estimation of covariance selection models," *Biometrika*, vol. 90, no. 4, pp. 809–830, 2003.
- [127] L. L. Scharf, *Statistical Signal Processing: Detection, Estimation, and Time Series Analysis*. New York: Addison-Wesley Publishing Co., 1990.
- [128] A. Catovic and Z. Sahinoglu, "The Cramér-Rao Bounds of Hybrid TOA/RSS and TDOA/RSS Location Estimation Schemes," *IEEE Communications Letters*, vol. 8, no. 10, pp. 626–628, Oct 2004.
- [129] J. Prieto, "Estimación adaptativa bayesiana aplicada a la localización de usuarios móviles," Ph.D. dissertation, Universidad de Valladolid, 2012.
- [130] H. L. Van Trees, *Detection, Estimation, and Modulation Theory: Part I*. New York: John Wiley & Sons, 1968.
- [131] N. Bergman, "Recursive Bayesian Estimation. Navigation and Tracking Applications," Ph.D. dissertation, Linköping University, Linköping, Sweden, 1999.
- [132] P. Tichavsky, C. Muravchik, and A. Nehorai, "Posterior Cramér-Rao Bounds for Discrete-Time Nonlinear Filtering," *IEEE Transactions on Signal Processing*, vol. 46, no. 5, pp. 1386–1396, May 1998.
- [133] F. Gustafsson and F. Gunnarsson, "Mobile positioning using wireless networks," *IEEE Signal Processing Magazine*, vol. 22, no. 4, pp. 41–53, July 2005.
- [134] A. Bahillo, S. Mazuelas, R. Lorenzo, P. Fernandez, J. Prieto, R. Duran, and E. Abril, "Hybrid RSS-RTT Localization Scheme for Indoor Wireless Networks," *EURASIP Journal on Advances in Signal Processing*, p. 12, 2010.
- [135] F. Zampella, A. R. Jiménez, and F. Seco, "Robust indoor positioning fusing PDR and RF technologies: the RFID and UWB case," in *Proceedings of the 4th Indoor Positioning and Indoor Navigation Conference (IPIN)*, 2013, pp. 686–695.
- [136] J. Salo, L. Vuokko, H. El-Sallabi, and P. Vainikainen, "An additive model as a physical basis for shadow fading," *Vehicular Technology, IEEE Transactions on*, vol. 56, no. 1, pp. 13–26, Jan. 2007.
- [137] X. Li, "Rss-based location estimation with unknown pathloss model," *IEEE Trans. on Wireless Communications*, vol. 5, no. 12, pp. 3626–3633, 2006.
- [138] S. Mazuelas, A. Bahillo, R. M. Lorenzo, P. Fernandez, F. a. Lago, E. Garcia, J. Blas, and E. J. Abril, "Robust Indoor Positioning Provided by Real-Time RSSI Values in Unmodified WLAN Networks," *IEEE Journal of Selected Topics in Signal Processing*, vol. 3, no. 5, pp. 821–831, Oct. 2009. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5290370>
- [139] R. Goldman, "Intersection of two lines in three-space," in *Graphics Gems*, A. S. Glassner, Ed. San Diego, CA, USA: Academic Press Professional, Inc., 1990, ch. 3D Geometry, pp. 304–. [Online]. Available: <http://dl.acm.org/citation.cfm?id=90767.90838>
- [140] U. Murat Erdem, "Fast line segment intersection," April 2010. [Online]. Available: <http://www.mathworks.com/matlabcentral/fileexchange/27205-fast-line-segment-intersection>

- [141] F. Zampella, A. R. Jiménez, and F. Seco, "Indoor positioning using efficient map matching, rssi measurements and an improved motion model," *IEEE Transactions on Vehicular Technology*, vol. Special Section: Indoor localization, tracking, and mapping with heterogeneous technologies, pp. 1–14, 2015.
- [142] F. Zampella, A. De Angelis, I. Skog, D. Zachariah, and A. R. Jimenez, "A constraint approach for UWB and PDR fusion," in *International Conference on Indoor Positioning and Indoor Navigation (IPIN)*, nov. 2012, pp. 1–9.
- [143] F. Zampella, A. Bahillo, J. Prieto, A. R. Jiménez, and F. Seco, "Pedestrian Navigation fusing Inertial and RSS/TOF measurements with Adaptive Movement/Measurement Models: Experimental Evaluation and Theoretical Limits," *Sensors and Actuators: A*, vol. 203, pp. 249–260, 2013.
- [144] A. R. Jiménez, F. Seco, F. Zampella, J. Prieto, and J. Guevara, "Localización inercial de personas con detección de rampas," in *Seminario Anual de Automática, Electrónica Industrial e Instrumentación (SAAEI)*, 2011, pp. 807–812.
- [145] A. R. Jiménez, F. Seco, F. Zampella, J. C. Prieto, and J. Guevara, "Ramp Detection with a Foot-Mounted IMU for a Drift-Free Pedestrian Position Estimation," in *Indoor Positioning and Indoor Navigation (IPIN), International Conference on*, Sept 2011, pp. 1–4.
- [146] A. R. Jiménez, F. Seco, F. Zampella, J. C. Prieto, and J. Guevara, "Indoor Localization and Tracking of Persons using an Inertial Measurement Unit (IMU) and the Signal Strength (RSS) from RFID Tags," in *Evaluating Ambient Assisted Living Systems through Competitive Benchmarking*, 2012.
- [147] A. R. Jiménez, F. Seco, F. Zampella, and J. C. Prieto, *Indoor Localization of Persons in AAL Scenarios Using an Inertial Measurement Unit (IMU) and the Signal Strength (SS) from RFID Tags*, ser. Communications in Computer and Information Science. Springer Berlin Heidelberg, 2013, vol. 362, pp. 32–51.
- [148] A. R. Jiménez, F. Zampella, and F. Seco, "Light-Matching: a new Signal of Opportunity for Pedestrian Indoor Navigation," in *Proceedings of the 4th Indoor Positioning and Indoor Navigation Conference (IPIN)*, 2013, pp. 686–695.
- [149] F. Seco, A. R. Jiménez, and F. Zampella, "Joint Estimation of Indoor Position and Orientation from RF Signal Strength Measurements," in *Proceedings of the 4th Indoor Positioning and Indoor Navigation Conference (IPIN)*, 2013, pp. 78–85.
- [150] A. R. Jiménez, F. Zampella, and F. Seco, "Método de localización en espacios interiores basado en detección y emparejamiento de puntos de luz," International patent WO2015/059 330 A1, 2015.
- [151] E. Muñoz-Díaz, F. de Ponte Müller, A. R. Jiménez, and F. Zampella, "Evaluation of AHRS algorithms for inertial personal localization in industrial environments," in *IEEE International Conference on Industrial Technology (ICIT)*, 3 2015, pp. 3412–3417.
- [152] F. Seco, A. R. Jiménez, and F. Zampella, "Fine-grained acoustic positioning with compensation of CDMA interference," in *IEEE International Conference on Industrial Technology (ICIT)*, 2015, pp. 78–85.