



INSTITUTO POLITÉCNICO NACIONAL

**CENTRO DE INVESTIGACIÓN EN CIENCIA
APLICADA Y TECNOLOGÍA AVANZADA**

UNIDAD QUERÉTARO

POSGRADO EN TECNOLOGÍA AVANZADA

**Reconstrucción tridimensional de ductos a partir de análisis
de imágenes**

TESIS

**QUE PARA OBTENER EL GRADO DE
DOCTOR EN TECNOLOGÍA AVANZADA**

PRESENTA

M.I Silvia Eugenia Cano Rodríguez

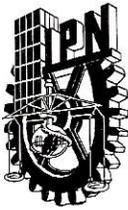
DIRECTORES DE TESIS

Dr. José Joel González Barbosa

Dr. Juan Bautista Hurtado Ramos



Santiago de Querétaro Qro. Julio del 2018



INSTITUTO POLITÉCNICO NACIONAL SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

ACTA DE REGISTRO DE TEMA DE TESIS Y DESIGNACIÓN DE DIRECTORES DE TESIS

México, D.F. a 22 de Agosto del 2018

El Colegio de Profesores de Estudios de Posgrado e Investigación de CICATA-Qro en su sesión ordinaria No. 140509 celebrada el día 9 del mes de mayo conoció la solicitud presentada por el(la) alumno(a):

Cano
Apellido paterno

Rodríguez
Apellido materno

Silvia Eugenia
Nombre (s)

Con registro:

A	1	4	0	6	7	2
---	---	---	---	---	---	---

Aspirante de: Doctor en tecnología Avanzada

1.- Se designa al aspirante el tema de tesis titulado:
Reconstrucción tridimensional de ductos a partir de análisis de imágenes

De manera general el tema abarcará los siguientes aspectos:
Desarrollo de un sistema de visión y fusión de sensores
Caracterización del sistema de posicionamiento
Cálculo del error de la posición calculada por imágenes

2.- Se designan como Directores de Tesis a los Profesores:
Dr. José Joel González Barbosa y Dr. Juan Bautista Hurtado Ramos

3.- El trabajo de investigación base para el desarrollo de la tesina será elaborado por el alumno en:
CICATA-Qro.

que cuenta con los recursos e infraestructura necesarios.

4.- El interesado deberá asistir a los seminarios desarrollados en el área de adscripción del trabajo desde la fecha en que se suscribe la presente hasta la aceptación de la tesis por la Comisión Revisora correspondiente:

Directores de Tesis

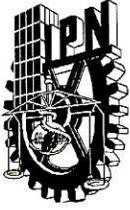
Dr. José Joel González Barbosa

Dr. Juan Bautista Hurtado Ramos

Aspirante
M.I Silvia Eugenia Cano Rodríguez

Presidente del Colegio
Dr. Alejandro Alfredo Lozano Guzmán

INSTITUTO POLITÉCNICO NACIONAL
CENTRO DE INVESTIGACIÓN EN
CIENCIA APLICADA
Y TECNOLOGÍA AVANZADA
UNIDAD QUERÉTARO
DIRECCIÓN



INSTITUTO POLITÉCNICO NACIONAL

SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

ACTA DE REVISIÓN DE TESIS

En la Ciudad de Querétaro siendo las 12 horas del día 27 del mes de Agosto del 2018 se reunieron los miembros de la Comisión Revisora de la Tesis, designada por el Colegio de Profesores de Estudios de Posgrado e Investigación de CICATA-Qro para examinar la tesis titulada:

Reconstrucción tridimensional de ductos a partir de análisis de imágenes

Presentada por el alumno:

Cano
Apellido paterno

Rodríguez

Silvia Eugenia

Apellido materno

Nombre(s)

Con registro:

A	1	4	0	6	7	2
---	---	---	---	---	---	---

aspirante de:

Doctor en tecnología avanzada

Después de intercambiar opiniones los miembros de la Comisión manifestaron **APROBAR LA TESIS**, en virtud de que satisface los requisitos señalados por las disposiciones reglamentarias vigentes.

LA COMISIÓN REVISORA

Directores de tesis

Dr. José Joel González Barbosa

Dr. Juan Bautista Hurtado Ramos

Dr. Francisco Javier Ornelas Rodríguez

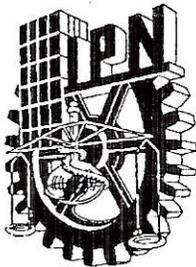
Dr. Antonio Hernández Zavala

Dr. Octavio Icasio Hernández

PRESIDENTE DEL COLEGIO DE PROFESORES

Dr. Alejandro Alfredo Lozano Guzmán





INSTITUTO POLITÉCNICO NACIONAL
SECRETARÍA DE INVESTIGACIÓN Y POSGRADO

CARTA CESION DE DERECHOS

En la Ciudad de Querétaro, Qro., el día 5 del mes de Septiembre del año 2018, el (la) que suscribe C. Silvia Eugenia Cano Rodríguez alumno (a) del Programa de Doctorado en Tecnología Avanzada, con número de registro A140672, adscrito a CICATA. unidad Querétaro, manifiesta que es autor (a) intelectual del presente trabajo de Tesis bajo la dirección del (de la, de los) Dr. José Joel González Barbosa y Dr. Juan Bautista Hurtado Ramos y cede los derechos del trabajo titulado Reconstrucción tridimensional de ductos a partir de análisis de imágenes, al Instituto Politécnico Nacional para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, gráficas o datos del trabajo sin el permiso expreso del autor y/o director del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección CICATA-IPN, Cerro Blanco No 141 Colinas del Cimatarío C.P 76090 Querétaro, Qro. Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.

Silvia Eugenia Cano Rodríguez

Agradecimientos

Agradezco a las instituciones que me han dado el apoyo académico y económico para realizar este proyecto.

- Al Instituto Politécnico Nacional y al Centro de Investigación en Ciencia Aplicada y Tecnología Avanzada.



- Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo económico otorgado para la realización de este proyecto de investigación.



Resumen

Reconstrucción tridimensional de ductos a partir de análisis de imágenes

El presente trabajo propone un sistema de posicionamiento con gran utilidad en diferentes tipos de aplicaciones industriales, como la industria metal mecánica, la industria aeronáutica, la militar y la medicina, que requieren constantemente de la medición de dimensiones internas de la pieza bajo inspección.

En esta tesis se plantea la idea de desarrollar un sistema de posicionamiento del interior de objetos que está conformado por un sistema de visión, un sensor magnético y un odómetro, la posición del sistema está dada por los datos provenientes de los sensores que recopilan la información de forma independiente. Se presenta una solución al problema de la estimación de la posición utilizando métodos probabilísticos, se modelan los datos de los sensores mediante distribuciones de probabilidad, para combinar la información de los diferentes sensores y disminuir los errores de posicionamiento se implementan técnicas de fusión de datos, posteriormente se procesan los datos y se realiza una estimación de la posición del sistema mediante diferentes técnicas como el Filtro de Kalman (FK) y el Filtro de Partículas (FP) en la que la posición debe ser lo más acertada y con la menor incertidumbre posible. Nuestros esfuerzos van dirigidos en obtener la posición del sistema de medición en la que pueda tomar una decisión de localización de la cámara y obtener una mejora en la precisión de la posición del sistema.

El trabajo es parte de un proyecto anterior, a partir de un sistema de medición desarrollado en el laboratorio de análisis de imágenes de CICATA Querétaro, por [1] su diseño es la base de nuestro sistema, y consiste en una proyección de luz adaptada a un fibroscopio para implementar algoritmos para estimar la posición del sistema con una incertidumbre caracterizada.

El trabajo se ha desarrollado en diferentes etapas. En la primer etapa de nuestro trabajo se construye el diseño del sistema de medición con la integración de sensores de desplazamiento lineales, se realiza una descripción de los sensores y se explican los pasos para la adquisición de los datos para cada sensor. Modelamos el sistema matemáticamente con la finalidad de obtener información del movimiento del sistema en cada posición. Posteriormente mientras el sistema se va desplazando y capturando imágenes en una posición específica, obtenemos una imagen correspondiente a las dimensiones métricas (mm) de la posición que se mide y con los datos de desplazamiento obtenidos de los sensores, encontrar la posición en la imagen y

recuperar el desplazamiento del sistema. La última etapa del trabajo consiste en la realización de algoritmos de estimación del posicionamiento del sistema con la finalidad de disminuir el error entre el desplazamiento medido con un sistema de referencia en un punto determinado y el desplazamiento medido por nuestro sistema en ese mismo punto.

Abstract

Three dimensional reconstruction of pipelines from image processing

We introduce an Active Light Positioning System for internal 3D scanning of industrial pieces that has great use in different types of industries like metal-mechanic, aeronautics, military and medicine, which constantly require internal measurement of pieces under inspection.

This thesis proposes the use of a measurement system capable of reading the position of the active light to determine the depth in the interior of objects. The system is formed by a vision system, a magnetic sensor and an odometer, the measurement position of the system is given data coming from several sensor which collect the information in a independent way. A solution to the problem of position estimation is presented using probabilistic methods. First we determined the sensor model with probability distributions, in order to combine the information of different sensors and minimize positioning errors, sensor data fusion techniques are implemented, data are processed and a position estimation are calculated with different techniques such as Kalman filter and Particle filter, getting a optimal estimation with fewer uncertainty. Our efforts are aimed to obtain a position of a measurement system in which you can take a decision on where the camera is located and obtain an improvement in the accuracy of the position of the system.

The work is part of a previous project, from a measurement system developed in the laboratory of analysis of images of CICATA Queretaro, by [1] his system design is the base of our system, and consists on a light Projection adapted to a fibroscope to implement algorithms to estimate the system position with a characterized uncertainty.

The project is developed in different stages: In the first stage of our work the design of the measurement system is built with the integration of linear displacement sensors, a description of the sensors is made and the steps for the acquisition of the data for each sensor are explained. We can model the system mathematically obtaining position information of the system. While the system is moving and capturing images in a specific position, we obtain an image corresponding to the geometric dimensions (mm) of the position and with data obtained from

sensors, we can find the position of the system. Finally, we will work on implement algorithms to estimate the position of the system in order to minimize the error between the displacement measured with a reference system at a certain point and the displacement measured by our system at the same point.

Índice general

Agradecimientos	I
	página
Resumen	I
Abstract	III
Índice general	V
Índice de figuras	VIII
Índice de cuadros	XI
1. Introducción	1
1.1. Introducción	2
1.2. Justificación	3
1.3. Objetivos	3
1.4. Descripción del trabajo	4
1.5. Estructura de la Tesis	4
2. Estado del arte	5
2.1. Estado del arte	6
2.1.1. Sistemas de visión aplicados a la industria	7
2.2. Sistemas endoscópicos	12
2.2.1. Sistemas monoculares con endoscopios	12
2.2.2. Sistemas de visión estéreo con endoscopios	15
2.2.3. Sistemas endoscópicos con sensores	18
2.2.4. Aplicación de sistemas endoscópicos en la industria	19
2.2.5. Estimación de la profundidad	21

3. Sensores de desplazamiento	23
3.1. Introducción	24
3.2. Sensor magnético	24
3.3. Sensor odométrico	27
3.4. Sistema de visión	30
3.4.1. Modelo para el sistema de visión	32
3.4.2. Estimación de la posición	34
3.5. Descripción del sistema de posicionamiento	37
4. Metodología Experimental	41
4.1. Estimación de la profundidad	42
4.2. Modelo de la medición	43
4.2.1. Modelos probabilísticos	44
4.3. Estimación de parámetros	45
4.3.1. Interpolación lineal y el algoritmo de Máxima Expectación (EM)	45
4.3.2. Formulación del algoritmo	48
4.4. Fusión de sensores	49
4.5. Modelo de mezcla de distribuciones	50
4.6. Solución al problema de estimación	52
4.7. Modelo del sistema	53
4.8. Filtro de Kalman (FK)	55
4.9. Filtro de Partículas (FP)	57
4.9.1. Filtro de Partículas aplicado al modelo del sistema	60
5. Resultados Experimentales	63
5.1. Adquisición de datos	64
5.2. Modelo de la medición	67
5.3. Fusión de datos	68
5.4. Filtro de Kalman	70
5.5. Filtro de Partículas	73
5.6. Comparación de los filtros	75
Conclusiones y Trabajo Futuro	80
Bibliografía	82

ANEXOS	99
A. Características de los sensores	100

Índice de figuras

2.1. a) Alineación del robot AACMM y el patrón de medida [24], b) Sistema de referencia del brazo del robot mediante un sistema de visión [29], c) Sistema de escaneo de un robot 6DOF [30]	8
2.2. Sistema de inspección de luz estructurada: a) [33], b) proyección de franjas [35], c) proyección de un patrón de luz circular [34]	9
2.3. Sistemas de visión estéreo: a) Inspección de pastillas de frenado de automóviles [33], b) Inspección de separaciones de ensamblaje [37]	10
2.4. Sistemas de visión estéreo adaptado a un robot [38]	10
2.5. Sistemas de visión para la inspección de tuberías [39]	11
2.6. Sistemas de visión que utiliza un haz de luz circular [40]	11
2.7. Arreglo de cámaras de 7 mm de diámetro [41]	13
2.8. Sistema de inspección sobre mecanismo (ETS) [42]	13
2.9. Sistema de visión de 3.6 mm de diámetro [43]	14
2.10. Esquema del sistema de visión endoscópico de doble canal [44]	14
2.11. Sistema de seguimiento del endoscopio [45]	15
2.12. Robot para la inspección de tuberías [46]	15
2.13. Esquema del sistema de visión de estereo visión [47]	16
2.14. Sistema de visión endoscópico [48]	17
2.15. Esquema del sistema de visión endoscópico [49]	17
2.16. Transformación de coordenadas del sistema de visión endoscópico y el sensor magnético [50]	18
2.17. Endoscopios con sensores inerciales [52],[54]	19
2.18. Endoscopios con sensores inerciales [55],[56]	19
2.19. Esquema del sistema de visión [57]	20
2.20. Esquema del sistema de visión [58]	20
2.21. Sistema de escaneo [59]	21

2.22. Sistema de visión Axial [60]	21
3.1. Circuito de la resistencia móvil	26
3.2. Interior de la banda magnética	26
3.3. Arriba: Controlador bluetooth desarrollado por [1] y abajo escala magnética o soft pot	27
3.4. Encoder optoelectrónico	29
3.5. Sistema de visión	31
3.6. Proyección de puntos en la imagen	32
3.7. Relación entre el movimiento de la cámara y la posición de los puntos en la imagen.	33
3.8. Detección de puntos subpixelicos en la imagen	35
3.9. a) Sistema de medición propuesto, compuesto por un sensor odométrico, sensor magnético y un sistema de visión, b) Diagrama de adquisición de datos de los sensores.	38
3.10. Caracterización de los sensores para el cálculo de la profundidad	40
4.1. Metodología utilizada para el cálculo de la profundidad	42
4.2. Representación de una función densidad de probabilidad	45
4.3. Representación de la estimación del conjunto de datos faltantes a partir del conjunto de valores observados.	46
4.4. Interpolación de densidades de probabilidad	47
4.5. Fusión de datos	50
4.6. Representación de la mezcla de distribuciones. Distribución de probabilidad del sensor óptico (rojo), distribución del sensor odométrico (verde), distribución del sensor magnético (azul) y f-mix representa la mezcla de las distribuciones.	52
4.7. Transición de estados. Las estimaciones consecutivas de la posición del sistema de posicionamiento están indicadas en cada estado, la representación del desplazamiento del sistema predice el siguiente estado a partir de la transición de estado anterior.	54
4.8. Diagrama Filtro de Kalman	55
4.9. Diagrama de flujo del Filtro de Partículas	58
4.10. Etapas del Filtro de Partículas	59
5.1. Posición del sistema de medición para cada sensor	66

5.2.	Desviación estándar σ de los sensores a diferentes posiciones	67
5.3.	Función de probabilidad de los sensores a diferentes posiciones	68
5.4.	Fusión de sensores	69
5.5.	Resultados Filtro de Kalman	71
5.6.	Estimación de estados Filtro de Kalman	71
5.7.	Comparación de la Estimación de estados con el valor real	72
5.8.	Estimación de estados Filtro de Partículas	74
5.9.	Desviaciones de la Mezcla de Gaussianas (GMM), del Filtro de Kalman (FK) y del Filtro de Partículas (FP)	75
5.10.	Estimación de las posiciones de los perfiles del cilindro con la cámara. Datos obtenidos por el sistema de visión activo (azul) y datos obtenidos por el sistema de posicionamiento (rojo).	77
5.11.	Estimación de las posiciones de los perfiles con la escala magnética. Datos obtenidos por el sistema de visión activo (azul) y datos obtenidos por el sistema de posicionamiento (rojo).	77
5.12.	Estimación de las posiciones de los perfiles del cilindro con el odómetro. Datos obtenidos por el sistema de visión activo (azul) y datos obtenidos por el sistema de posicionamiento (rojo).	78
5.13.	Comparación de las posiciones de los perfiles del cilindro con ambos sistemas. Datos obtenidos por el sistema de visión activo (azul) y datos obtenidos por el sistema de posicionamiento (rojo).	79
A.1.	Tarjeta de adquisición de datos	102
A.2.	Matriz de led	102
A.3.	Circuito interno de la matriz de led	103
A.4.	Mesa deslizable y control de posición	104
A.5.	Motor de pasos de mesa de desplazamiento	105

Índice de cuadros

4.1. Pasos del algoritmo <i>Máxima Expectación (EM)</i>	49
4.2. Algoritmo de Filtro de Partículas	61
5.1. Datos obtenidos con los sensores (mm)	65
5.2. Datos obtenidos de la mezcla de distribuciones (mm)	70
5.3. Datos obtenidos de todas las estimaciones (mm)	73
5.4. Datos estimados con el Filtro de Partículas (mm)	74
5.5. Incertidumbres obtenidas de estimaciones de posición discretas (mm)	76
A.1. Relación de los pulsos con la distancia	101
A.2. Tabla de conversiones mm a spr	106

Capítulo 1

Introducción

En este capítulo se presenta una descripción general del trabajo realizado, la motivación y justificación del planteamiento del mismo y los objetivos planteados para su realización, así como la estructura de la tesis.

1.1. Introducción

En este trabajo se desarrolló un sistema de posicionamiento basado en el análisis de imágenes y sensores de desplazamiento lineal. Partiremos de un sistema de medición basado en la visión activa desarrollado en CICATA. Este sistema de mediciones consta de un sistema de proyección de luz, un fibroscopio y una cámara externa al fibroscopio, las mediciones desarrolladas con este sistema están en el orden de 0.1 milímetros. Sin embargo, en este sistema no se ha considerado la posición del sistema de medición. Nuestros esfuerzos van dirigidos en obtener la posición del sistema para aumentar la precisión de la posición del sistema de medición para mejorar el posicionamiento y obtener mejores mediciones.

Se describe la metodología para resolver el problema para la obtención de las estimaciones de posición utilizando un sistema de medición basado en un sistema de visión y dos sensores de desplazamiento lineal. El sistema de posicionamiento desarrollado está conformado por un sistema de visión, un sensor magnético y un odómetro. La cámara utilizada esta integrada a un endoscopio flexible de 7 mm de diámetro con una distancia de trabajo de 150 mm y captura imágenes con una resolución de 640x480 pixeles. El sensor magnético funciona como un potenciómetro cuyo valor de resistencia está relacionado con el valor de la posición, el odómetro se coloca en forma paralela a la cámara y se desplaza en dirección al eje óptico de la cámara. La adaptación del sistema de visión junto con la integración de sensores de desplazamiento consiste en fusionar las mediciones provenientes de los sensores para obtener información más precisa en la que se pueda tomar una decisión de donde se encuentra localizado el sistema. Para disminuir los errores de posicionamiento propios a los datos de los sensores y al sistema de medición. Presentamos la implementación de métodos de estimación de la posición que utiliza la información procedente de los sensores aplicando técnicas de fusión de datos, filtros probabilísticos como el Filtro de Kalman (FK) y Filtro de Partículas (FP) y se muestran los resultados de los experimentos realizados. A lo largo de este capítulo se describe el problema de obtener la posición del sistema de medición, se presentan los objetivos de la investigación y su justificación y el contenido de los capítulos de la tesis.

1.2. Justificación

Existe la necesidad de mejorar un sistema de visión de luz activa que permite el escaneo 3D del interior de objetos con geometrías irregulares desarrollado con anterioridad en CICATA con la finalidad de obtener la posición de dicho sistema y aumentar su exactitud mientras se va desplazando en el interior del objeto bajo medición. La modelización del sistema de posicionamiento propuesto tiene el objetivo de optimizar el diseño y obtener una mejora en la calidad de los resultados obtenidos utilizando un sistema de medición menos robusto.

El sistema de posicionamiento propuesto tiene como finalidad obtener información a partir de una serie de imágenes y sensores de posicionamiento que complementen al sistema para poder disponer de más datos de medición. A partir de estos datos, realizaremos una fusión de los mismos para combinar la información proveniente de los diferentes sensores para obtener información apropiada con la que se pueda tomar una decisión de donde se encuentra localizado el sistema y obtener una mejora en la exactitud en cada posición.

1.3. Objetivos

Objetivo General

Desarrollar un sistema de medición que permita estimar la posición de un sistema de visión mediante una cámara y diferentes sensores de desplazamiento que permitan calcular y estimar su posición de manera controlada en el orden de 1 mm.

Objetivos Específicos

Para alcanzar el objetivo general de la tesis, es necesario definir los objetivos específicos sobre el cual está planteado el problema estos son:

1. Desarrollar el diseño del sistema de visión y adaptación de múltiples sensores de desplazamiento lineal
2. Caracterización de los diferentes sensores

3. Adquisición de datos de los sensores a utilizar
4. Modelizar el sistema de dimensionamiento
5. Desarrollar algoritmos que permitan obtener la posición del sistema
6. Estudio de las incertidumbres del sistema de visión

1.4. Descripción del trabajo

El proyecto se desarrolló en diferentes etapas: En la primera etapa se trabajó en el diseño e integración de los sensores de desplazamiento lineal que posicionan al sistema de medición, en una segunda etapa se desarrolló el diseño del sistema de visión y se modeló el sistema matemáticamente con la finalidad de obtener información del movimiento del sistema en cada posición. En la tercera etapa, mientras el sistema de medición se va desplazando y capturando imágenes en una posición específica, se obtiene una imagen correspondiente a las dimensiones métricas (mm) de la posición y con los datos de desplazamiento de los sensores, se encuentra la posición de la imagen para calcular el desplazamiento del sistema. En la última etapa del proyecto se trabaja en aplicar algoritmos de estimación del posicionamiento del sistema con la finalidad de minimizar el error entre el desplazamiento de referencia en un punto determinado y el desplazamiento medido por el sistema propuesto en ese mismo punto.

1.5. Estructura de la Tesis

Tomando en cuenta los objetivos mencionados, el presente trabajo se ha organizado en cuatro capítulos en los que se describen los procedimientos principales para la realización de este trabajo.

En el capítulo 2 se realiza una introducción al planteamiento del problema y exponemos el estado del arte de algunas investigaciones relacionadas con la estimación de la posición para tener un panorama general del tema de tesis. En el capítulo 3 se realiza una descripción detallada acerca de los sensores que conforman el sistema de posicionamiento. El capítulo 4 describe la base teórica de los algoritmos para modelar el sistema matemáticamente con la finalidad de establecer el movimiento del sistema en cada posición. En el capítulo 5 se muestran los resultados de las pruebas realizadas, simulaciones y análisis de los resultados obtenidos. En la parte final se dan a conocer las conclusiones del trabajo en base a los resultados obtenidos y se hacen algunas recomendaciones del trabajo futuro.

Capítulo 2

Estado del arte

En este capítulo se presentan algunos trabajos relacionados al tema de investigación, se describen las aplicaciones relacionadas a los sistemas de visión usados para la estimación de la posición.

2.1. Estado del arte

Existe interés por parte de la industria automotriz, aeronáutica, la industria médica, etc. por utilizar alternativas para determinar la posición de un objeto en movimiento, dentro de los sistemas más utilizados están los que utilizan un sistema de visión compuesto por una cámara utilizado como sensor de medición, por ejemplo autores como [2], [3], [4], [5], utilizan estos sistemas para la estimación del movimiento, realizando una correspondencia de puntos de referencia entre imágenes para obtener información acerca de la profundidad. Sin embargo, el uso de sistemas de visión con configuraciones monoculares son susceptibles a movimientos rápidos de la cámara y sus aplicaciones son limitadas debido al campo de visión que ofrece la cámara.

Otros autores como [6], [7], [8], estiman de la posición utilizando un sistema de múltiples cámaras en que la configuración del sistema combina las observaciones de todas las cámaras para calcular los parámetros de rotación y traslación del sistema a partir de una secuencia de imágenes. En [9] y [10] presentan un método que permite calcular los valores de la posición y rotación de la navegación de una cámara monocular, en el trabajo calculan directamente los parámetros de movimiento a partir de una serie de imágenes y estiman la precisión de los parámetros por el método de descomposición de valores singulares, la utilización de estos sistemas posibilita la localización de objetos.

Una forma de mejorar los resultados obtenidos de manera visual, es presentada por autores como [11], [12], [13], [14] que utilizan sistemas de visión que se adaptan a la inclusión de sensores inerciales para obtener información de su localización y tener un control para determinar la posición en cada instante de tiempo, con el objetivo de integrar la información de la posición proveniente de diferentes sensores y mejorar el resultado de las mediciones. En [15], [16], [17] describen la implementación de algoritmos de navegación para determinar la posición de un robot móvil a partir de la estimación odométrica cuando este se mueve en un entorno conocido, los autores muestran la integración de sensores odométricos en aplicaciones de robótica móvil donde el robot puede rotar y trasladarse a través del entorno y a su vez obtener información constantemente de su localización.

Otro enfoque para resolver el problema de localización de un objeto es el trabajo presentado por [18], [19] que utilizan un sistema de detección de posición lineal, utilizando una serie de sensores magneto resistivos (MR) y señales de acondicionamiento electrónico. Los sensores

se utilizan para determinar la posición de un imán que está unido a un objeto en movimiento, este sensor mide la relación de la posición del imán y la función del campo magnético para determinar la posición de objeto. En el trabajo de [20] describen como los sensores magneto resistivos son utilizados para medir el desplazamiento lineal. El cálculo de la posición se consigue midiendo la dirección del campo magnético en lugar de la fuerza de campo, los sensores utilizados en este trabajo son dos circuitos de montaje superficial, a diferencia del sensor que utilizamos en este trabajo que es un sensor magnético de película delgada.

La gran aplicación de los sistemas de visión y la facilidad con la que podemos obtener información de la posición de la cámara y del entorno en el que se mueve ha provocado el interés sobre la integración de estos sistemas en aplicaciones como la medicina, la industria metal mecánica, aeronáutica, etc., en las que se busca obtener información acerca del objeto bajo inspección. Se han desarrollado múltiples configuraciones de los sistemas de visión, que han sido desarrollados con la finalidad de mejorar la exactitud de la posición, para seguimiento y reconstrucción de objetos, la mayoría de los prototipos encontrados en la literatura, usan visión monocular, visión estéreo (dos cámaras), sistemas de visión que utilizan sensores inerciales, que se basan en diferentes técnicas ópticas con una exactitud definida. En esta sección se revisan algunas configuraciones de los sistemas de visión y sus aplicaciones.

2.1.1. Sistemas de visión aplicados a la industria

En la industria, ha existido la necesidad de obtener mediciones 3D de alta exactitud de las piezas de ensamble para fines de control de calidad, a un bajo costo y rapidez en la inspección para optimizar los procesos de ensamble.

Tradicionalmente, en áreas de metrología la medición de piezas se ha realizado a través de máquinas de medición de coordenadas (CMM). Con el fin de mejorar los procesos de inspección, se han utilizado tecnologías basados en la visión que incluye el uso de robots articulados equipados con sistemas de visión 3D como se muestra en la Figura 2.1. Por ejemplo, [21] y [22] integran la información dimensional obtenida con la CMM y la información obtenida de las imágenes capturadas por el sistema de visión con el objetivo de escanear el modelo de la pieza en 3D con fines de dimensionamiento. En [23] se presenta un método para integrar la medición de un sistema de visión estereoscópica y un robot industrial Fanuc, los resultados muestran que el sistema de visión es capaz de proporcionar la medición de la profundidad con una exactitud de 0.152 mm a 0.342 mm. En [24] se ha propuesto la integración de un sensor

láser a un robot articulado (AACMM) para mejorar la precisión del escaneo 3D de una pieza bajo inspección, la aportación de estos autores esta en la calibración de la cámara para mejorar los parámetros intrínsecos y extrínsecos del sensor previo al escaneo 3D. En [25] y [26] proponen el uso de robots para el escaneo 3D de piezas para el control de calidad, estos sistemas son utilizados por [27], [28],[29] y [30] en la industria mecánica para medir superficies de materiales como el acero y aluminio. Sin embargo, estas técnicas consumen demasiado tiempo para realizar la medición de la pieza, se requiere de un conocimiento de programación de las máquinas, utilizan resultados de medición previos y están limitadas a la inspección de superficies externas, el procesamiento de los datos se realiza con el uso de programas especializados.

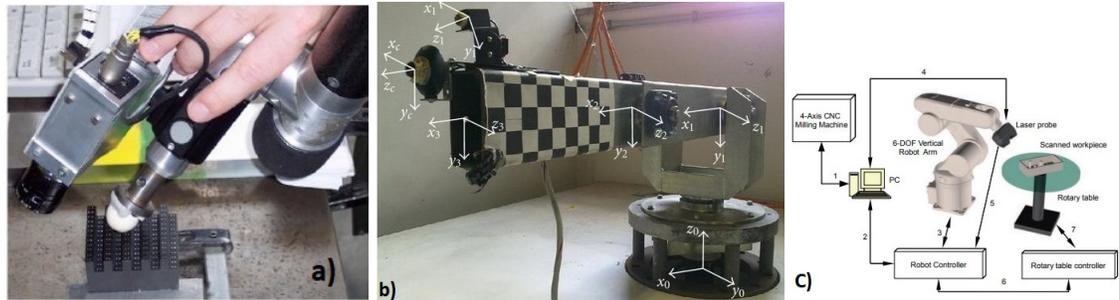


Figura 2.1: a) Alineación del robot AACMM y el patrón de medida [24], b) Sistema de referencia del brazo del robot mediante un sistema de visión [29], c) Sistema de escaneo de un robot 6DOF [30]

Una práctica común en la industria para acelerar los procesos de inspección, es utilizar los sistemas de visión para predecir la forma final de una pieza y analizar si la pieza final de ensamble cumple con las especificaciones geométricas del diseño, esto implica comparar las dimensiones físicas del objeto con un modelo o patrón que describa las dimensiones del objeto. Autores como [31] evalúan la calidad de la geometría de la pieza de inspección contra el modelo CAD y proponen un método que realiza un suavizado en la nube de puntos antes de reconstruir la superficie 3D de la pieza, los resultados de precisión obtenidos están en el rango de 0.20 mm. En [32] se presentó un sistema de visión estéreo basado en modelos CAD para mediciones de huecos en la superficie de piezas industriales, el sistema permite realizar el dimensionamiento con una exactitud de 0.1 mm.

En la mejora constante de los sistemas de visión, se han desarrollado sistemas para la obtención del modelo tridimensional de piezas utilizando una cámara, por ejemplo, en [33]

desarrollaron un sistema de inspección para el control de calidad de la estructura de una puerta y de un parabrisas de vehículos. El sistema de inspección está compuesto por un proyector de luz que proyecta un patrón de franjas codificadas sobre la superficie de la pieza, mientras la cámara captura la luz reflejada sobre el objeto, el sistema puede generar la superficie de la pieza a través de una nube de puntos. Posteriormente se realiza una comparación de la medición de la forma 3D obtenida con el sistema de visión y el modelo CAD de la pieza, los resultados experimentales muestran que el sistema tiene una exactitud de 0.182 mm.

En [34], se propone un sistema de medición basado en visión estéreo para la dimensión de los diámetros de una barra de acero. En primer lugar, se capturan imágenes de la pieza por las dos cámaras CCD, y se proyecta un patrón de franjas sobre la superficie de la pieza, se realiza la calibración de las cámaras para obtener los parámetros intrínsecos y extrínsecos, se proyectan ocho franjas de luz sobre la barra de acero, se ubican los puntos de intersección de las franjas proyectadas en diferentes imágenes de manera subpíxelica, los resultados experimentales indican que el error relativo de medir diámetros de la barra de acero es de 0.5 mm a 0.9 mm.

En [35] presentan un sistema de visión para medir la superficie interna de tuberías cilíndricas. El dispositivo consta de dos cámaras idénticas alineadas con el eje óptico, dos lentes cónicas y un proyector de franjas. El patrón de franjas se proyecta en la superficie interna de la tubería, y es capturado por ambas cámaras, las franjas proyectadas se utilizan para reconstruir la superficie 3D de la tubería, se presentan los resultados para tuberías de 150 mm de diámetro, con una incertidumbre de 0.21 mm.



Figura 2.2: Sistema de inspección de luz estructurada: a) [33], b) proyección de franjas [35], c) proyección de un patrón de luz circular [34]

Dentro de los métodos de medición basados en un sistema de visión que utiliza dos cámaras son los presentados por [36], este sistema realiza mediciones de la pieza de frenado de automóviles. El método consiste en realizar una segmentación de las imágenes mediante técnicas de binarización para detectar los bordes de la pieza y posteriormente realizar la medición de los bordes de la pieza captados por la cámara. Los resultados mostraron que la exactitud de este sistema es de 0.019 mm. La configuración del sistema propuesto por [37], consta de dos cámaras estéreo y dos lámparas infrarrojas, que se utilizan para resaltar los bordes de la separación entre dos piezas de ensamble, el sistema es capaz de medir el largo y ancho de la separación entre las piezas.

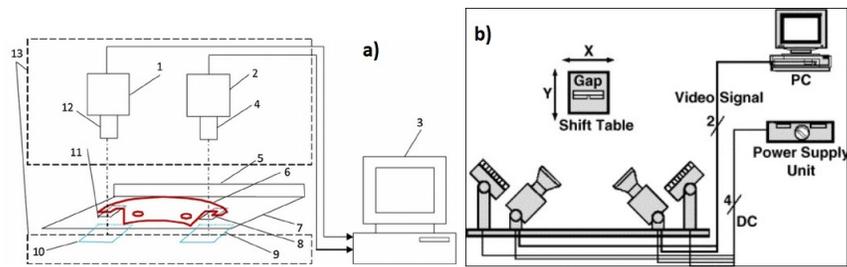


Figura 2.3: Sistemas de visión estéreo: a) Inspección de pastillas de freno de automóviles [33], b) Inspección de separaciones de ensamblaje [37]

En [38] presentan un sistema de medición 3D que se adapta a un robot para corregir su posicionamiento y generar la forma 3D de la pieza con una exactitud de 0.23 mm .

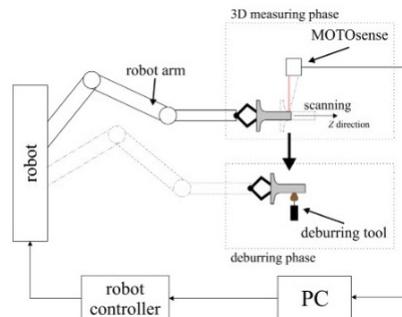


Figura 2.4: Sistemas de visión estéreo adaptado a un robot [38]

En [39] proponen un sistema para la inspección de la superficie interna de tuberías de 14 mm de diámetro que tiene defectos en el interior, para el posicionamiento del sensor dentro de

la tubería, se coloca un espejo en forma de cono en el cabezal del sensor, la posición del sensor en el interior de la tubería es controlada por un sistema de motor pasos con un error de 0.2 mm

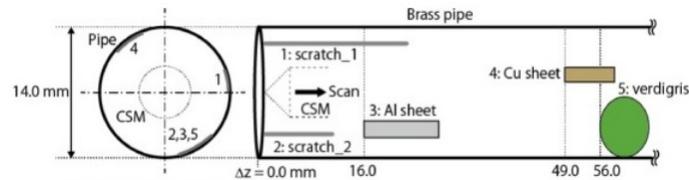


Figura 2.5: Sistemas de visión para la inspección de tuberías [39]

En [40] proponen un sistema de medición para el diámetro interno de tuberías, el sistema consiste de un espejo cónico y un diodo láser para formar un haz de luz circular que es proyectado en el interior del tubo, sin embargo, el tamaño del dispositivo limita su aplicación para pequeños orificios internos.

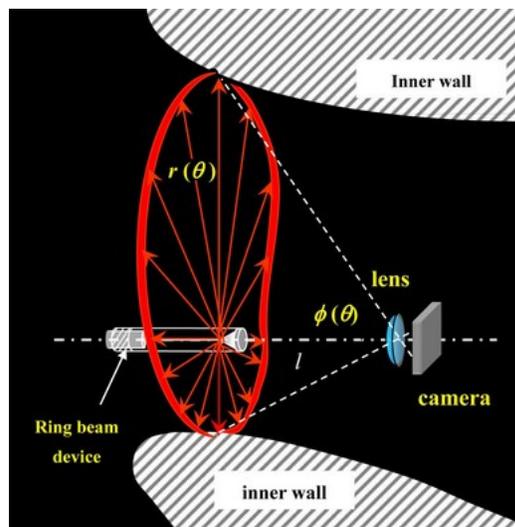


Figura 2.6: Sistemas de visión que utiliza un haz de luz circular [40]

Aunque la configuración de estos sistemas muestran resultados aceptables, la desventaja de estos sistemas es que pierden flexibilidad por que cada diseño tienen sus propias especificaciones, para realizar una tarea específica, utilizan cámaras que son de gran tamaño lo que dificulta su adaptación en procesos de inspección intermedios, los resultados obtenidos por estos sistemas son dependientes del campo de visión de la cámara, generalmente han demostrado ser más útiles en procesos de ensamble e inspección final, el manejo de los sistemas aún queda

a disposición del usuario, lo que provoca una disminución en el rendimiento de los sistemas en procesos de inspección prolongados.

2.2. Sistemas endoscópicos

En los procesos industriales es importante asegurar la calidad de un producto final, esto con lleva la necesidad de realizar una verificación del proceso de elaboración de piezas y realizar un mantenimiento preventivo de las máquinas usadas en sus procesos. Con el fin no de no alterar las propiedades físicas y mecánicas del objeto a analizar se han buscado alternativas de medición sin contacto para realizar una inspección de las piezas. Una tendencia de los sistemas basados en visión es el uso de cámaras de pequeña dimensión para poder acceder a áreas sin la intervención humana y ha propiciado el desarrollo de sistemas de visión que utilizan cámaras endoscópicas. Los endoscopios al poder acoplar una pequeña cámara, ser ligeros, flexibles, se pueden adaptar con facilidad a la inspección del interior de máquinas, en instalaciones que no son visibles de forma directa, permiten visualizar el interior de cavidades de piezas de diámetro reducido con el objetivo de obtener información de sus dimensiones de una forma más rápida.

2.2.1. Sistemas monoculares con endoscopios

En los sistemas de visión monocular, se puede calcular la posición utilizando la información de las imágenes capturadas por una cámara que se mueve, primero se establece la posición de la primer imagen capturada como referencia y a partir de esta se calculan las posiciones de las imágenes sucesivas. La configuración básica de los sistemas de visión está compuesto por una cámara, un patrón de calibración y una fuente de luz, que trabajan de manera conjunta para adquirir imágenes, a partir de una secuencia de imágenes se extraen un conjunto de características dentro de cada imagen, se realiza una correspondencia de puntos del espacio 3D y su proyección 2D en función de la detección y seguimiento de los puntos característicos en las imágenes, y mediante métodos de procesamiento de imágenes se obtiene la información de la forma y posición del objeto.

Entre los sistemas de visión que utilizan este tipo de configuración se encuentran, el trabajo propuesto por [41] donde los autores presentan un sistema de visión compuesto por un

endoscopio rígido y una cámara de pequeña dimensión, utilizando el sistema de proyección de franjas ambos sistemas son comparados, con el sistema endoscopico se logran mediciones de geometrías cilíndricas con un radio de 1 mm, mientras que con el sistema de proyección de la cámara se logran mediciones con un radio de 6 mm. Las mediciones demuestran la capacidad de ambos sistemas para inspeccionar partes de máquinas en espacios restringidos.

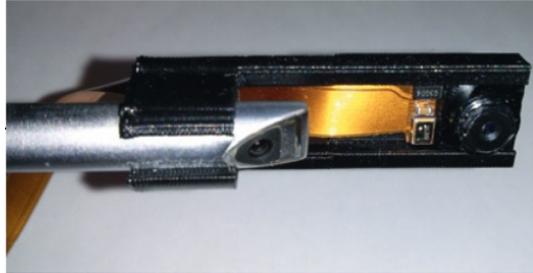


Figura 2.7: Arreglo de cámaras de 7 mm de diámetro [41]

En [42] presentan un sistema de visión endoscópico que utiliza un mecanismo (ETS) para determinar los cambios de posición del endoscopio para obtener el escaneo 3D de los contornos del objeto bajo inspección.

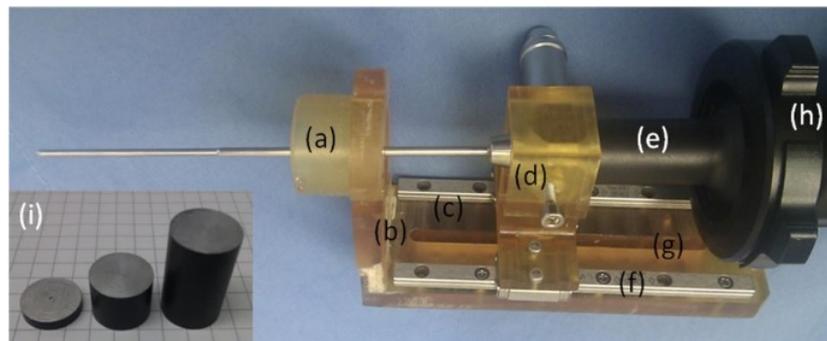


Figura 2.8: Sistema de inspección sobre mecanismo (ETS) [42]

En el trabajo presentado por [43] presentan un sistema de escaneo 3D basado en luz estructurada, en la punta del endoscopio se adapta un espejo catadióptrico y un patrón de calibración, la aportación de este trabajo es trabajar en el proceso de calibración del sistema. El escaner esta diseñado para cavidades cilíndricas de 14 mm de longitud y 30 mm de

diámetro, la exactitud del sistema es de 0.1 mm.

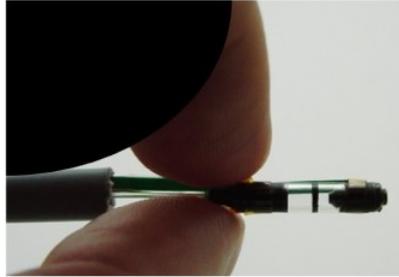


Figura 2.9: Sistema de visión de 3.6 mm de diámetro [43]

En el trabajo de [44] se presenta un sistema de visión para el escaneo 3D del objeto de interés. El sistema consta de un endoscopio al que se le añaden componentes ópticos como un micro lente y un patrón de franjas, el sistema proyecta el patrón de franjas sobre la superficie del objeto y genera puntos de muestreo del perfil de la superficie. El sistema se evaluó con las mediciones tridimensionales de dos cilindros de 12.34 y 28.77 mm de diámetro, los resultados muestran un error de medición de 0.23 mm y 0.36 mm respectivamente.

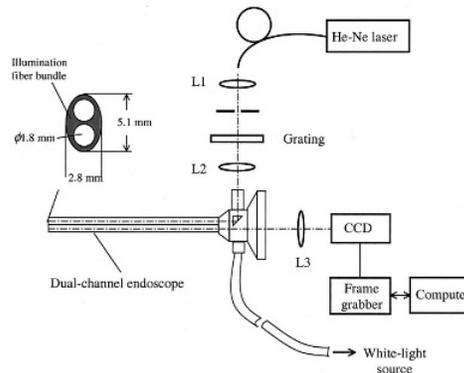


Figura 2.10: Esquema del sistema de visión endoscópico de doble canal [44]

En [45] se propone el seguimiento de un endoscopio colocando una tira de color en la punta del endoscopio, el método calcula la posición del objeto utilizando la proyección de la forma cilíndrica de la punta del endoscopio codificada en la imagen por colores, la precisión de este sistema es de 1mm, debido al tamaño del sistema se necesita una distancia de medición

entre la cámara y el objeto de 100 mm.

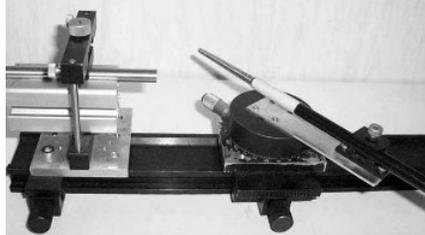


Figura 2.11: Sistema de seguimiento del endoscopio [45]

2.2.2. Sistemas de visión estéreo con endoscopios

La visión estereoscópica se basa en la adquisición simultánea de dos imágenes desde dos puntos de vista diferentes que nos permite tener una percepción de la profundidad. La configuración de este tipo de sistemas incluye el uso de dos cámaras situadas en la misma posición, separadas entre sí, procurando que la línea de visión de estas cámaras se enfoque hacia un punto medio.

Existen distintos sistemas basados en la técnica de visión estereoscópica que utilizan cámaras endoscópicas por ejemplo, el trabajo [46] proponen un método de inspección de tuberías de 775 a 849 mm de diámetro, utilizan un robot de rastreo equipado con un sistema de visión estéreo y la proyección de luz láser, el robot se mueve a lo largo de la tubería y va tomando imágenes de la superficie interna y de la proyección de la luz láser. Las imágenes tomadas por el sistema se utilizan para calcular la dimensión de grietas en superficie de la tubería.

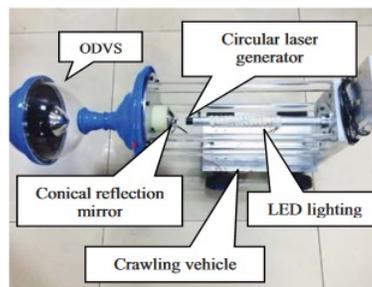


Figura 2.12: Robot para la inspección de tuberías [46]

En [47], se introduce un sistema de visión para inspeccionar el interior de espacios de difícil acceso, como cavidades de tanques de combustible y tuberías. El sistema utiliza dos cámaras que se multiplexan para capturar el video de la parte interna de la tubería, después de corregir la distorsión de la lente del endoscopio, el sistema es útil para medir objetos localizados frente a la cámara a una distancia de 25 mm hasta 500 mm.

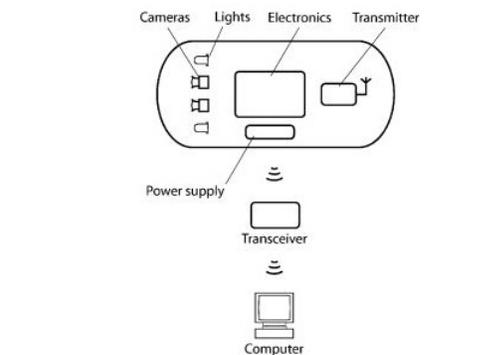


Figura 2.13: Esquema del sistema de visión de estereo visión [47]

En [48], presentan un método de evaluación de precisión de dos sistemas de visión estereoscópica, uno utiliza dos cámaras web comerciales, mientras que el otro sistema utiliza cámaras LMS infrarrojas. Los dos sistemas se usaron para determinar las dimensiones de un bloque de metal que ha sido previamente medido usando una máquina de medición de coordenadas (CMM). Los resultados muestran que las cámaras web tienen un mejor rendimiento, para medir objetos a una distancia de 700 mm con un intervalo de exactitud de 0.64 y 1.69 mm, mientras que las cámaras LMS miden a una distancia de 300 mm con una exactitud de 1.75 a 3 mm.

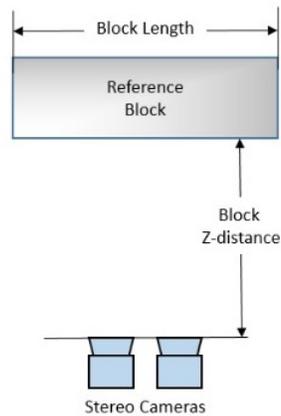


Figura 2.14: Sistema de visión endoscópico [48]

En [49] presentan un sistema de visión en el que adaptan un patrón de franjas sinusoidales en la punta del endoscopio, este patrón es proyectado sobre la superficie del objeto para obtener el escaneo 3D.

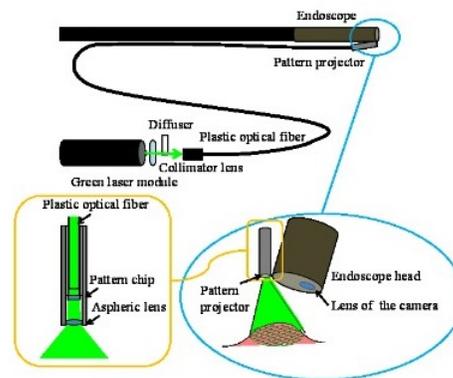


Figura 2.15: Esquema del sistema de visión endoscópico [49]

La desventaja de los sistemas de visión estéreo es que usan un proyector de luz y un sensor infrarrojo, además que utilizan configuraciones que incluye más componentes ópticos como espejos y rejillas, servo motores y plataformas de desplazamiento para el control de la posición.

2.2.3. Sistemas endoscópicos con sensores

Las investigaciones relacionadas con la estimación de la posición, se han enfocado en desarrollar técnicas para extraer información mediante el uso de diferentes sensores para definir la posición y orientación de las imágenes tomadas por el endoscopio. Algunos de los sistemas desarrollados que utilizan sensores son por ejemplo, el trabajo reportado por [50] que propone un sistema para medir la longitud de tuberías utilizando un endoscopio y un sensor de desplazamiento electromagnético (EM) en tuberías de 90 a 220 mm de longitud con un error de 1.12 mm. Al igual que el trabajo desarrollado por [51] que propone un método de localización usando un sistema endoscópico que integra 16 sensores magneto resistivos obteniendo un error de posición de 3.3 mm. La dificultad del uso de este tipo de sensores es la presencia de campos magnéticos ya que es altamente sensible a ellos.

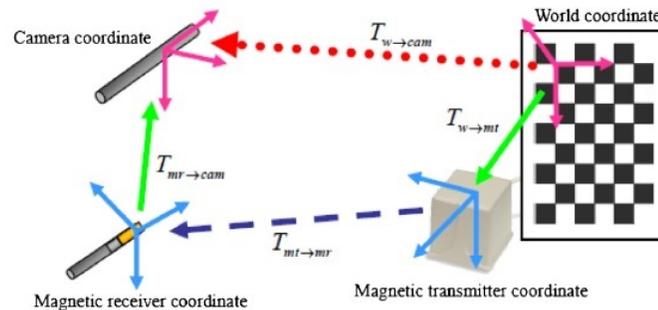


Figura 2.16: Transformación de coordenadas del sistema de visión endoscópica y el sensor magnético [50]

La técnica de fusión de datos, consiste en realizar la combinación de las mediciones de los sensores para aprovechar las características de cada sensor y minimizar el error de medición. El desarrollo de sistemas que utilizan sensores inerciales como giroscopios, acelerómetros y magnetómetros, para poder calcular la orientación y posición mientras el endoscopio se mueve durante la captura de las imágenes, es propuesto en [52],[53],[54].



Figura 2.17: Endoscopios con sensores inerciales [52],[54]

En [55] fusionan la información de los sensores inerciales para calcular la posición del endoscopio con un error de exactitud de 0.3 cm. Otro método es el desarrollado por [56] que integra en la punta del endoscopio 8 sensores inerciales, mientras el endoscopio se mueve dentro de la superficie, los sensores recopilan datos que posteriormente son fusionados para obtener información de la posición con un error de exactitud de 1.8 cm, aunque estos sensores son pequeños y de bajo costo pierden su orientación translacional por lo tanto deben ser ajustados continuamente, además que su rendimiento operativo disminuye en presencia de humedad.

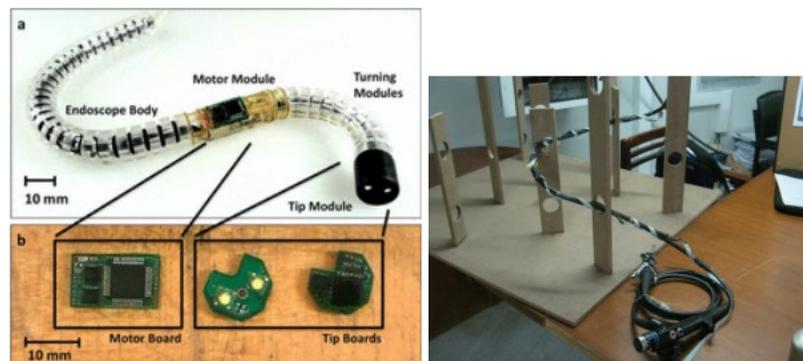


Figura 2.18: Endoscopios con sensores inerciales [55],[56]

2.2.4. Aplicación de sistemas endoscópicos en la industria

En [57] presentan un sistema endoscópico basado en luz estructurada, para la medición de tuberías de 95 mm con un diámetro de 70 mm. La cámara del sensor es un endoscopio industrial USB de 7 mm que contiene 6 láseres montado sobre un robot y un sistema de control.

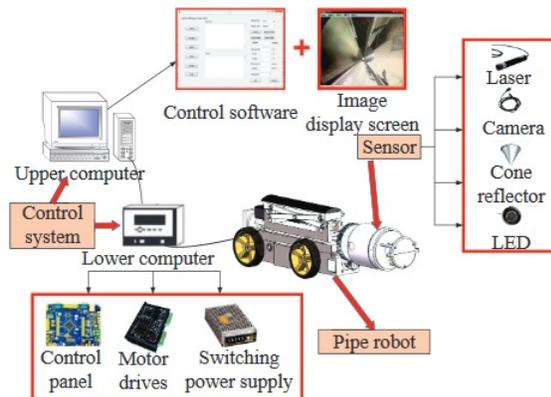


Figura 2.19: Esquema del sistema de visión [57]

En [58] se propuso un sistema de inspección de visión 3D para la superficie interna de la tubería mediante el uso de un proyector láser circular. Las superficies internas de la tubería se inspeccionaron en base al sistema de proyección de luz circular y se reconstruyó la forma tridimensional de la superficie de la tubería. Los resultados experimentales indican que la exactitud de calibración del sistema es de 0.081 mm.



Figura 2.20: Esquema del sistema de visión [58]

En [59] se desarrolló un sistema para inspeccionar barrenos que utiliza un endoscopio rígido y un proyector láser que proyecta un patrón de luz circular, el sistema es guiado por un brazo robótico e inspecciona diámetros de barrenos entre 4 mm y 50 mm con una profundidad de 100 mm.

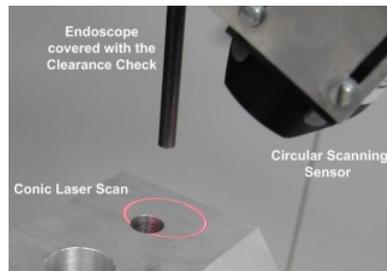


Figura 2.21: Sistema de escaneo [59]

En [60] se propuso un nuevo enfoque de metrología óptica tridimensional para la medición de la superficie interna de las tuberías de 7 a 8 mm de diámetro mediante la utilización de un Endoscopio de Fibra (SFE) y una técnica de visión estéreo, el error de medición que se obtiene con este sistema es de 0.4333 mm.

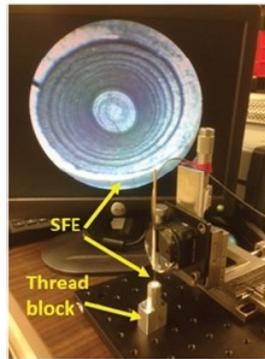


Figura 2.22: Sistema de visión Axial [60]

2.2.5. Estimación de la profundidad

El problema a resolver en este trabajo se centra en estimar la posición de un sistema de escaneo 3D de interiores, que obtiene información de los datos obtenidos por los sensores, asociado al planteamiento de un modelo matemático que describe el comportamiento del sistema y que integre las mediciones de la posición con algoritmos de estimación basados en filtros probabilísticos los cuales son capaces de estimar la posición del sistema en cada instante de tiempo.

Resulta interesante analizar técnicas que permitan estimar la posición de un sistema mientras este se mueve, entre estas técnicas están aquellas que se basan en calcular la profundidad

con modelos probabilísticos, mediante la implementación del Filtro de Kalman [61], mezcla de gaussianas [62], localización de markov para entornos dinámicos como [63], Filtro de Partículas [64], etc.

Para dar una solución al problema de estimación de la posición, es necesario utilizar métodos como el propuesto en [65] que presentan la realización de la fusión de un sensor inercial y un sistema de visión para determinar la posición de un robot móvil, mediante la aplicación del Filtro de Kalman Extendido. En [66], plantean el problema de la localización y control de posición de un móvil mediante el uso de sensores y la fusión de datos obtenidos de estos sensores, primero los datos son obtenidos por los sensores del robot y mediante el Filtro de Kalman realizan la corrección de las incertidumbres de los datos para tener mayor control de la posición. En [67], [68] proponen un algoritmo de localización basado en el Filtro de Partículas, otros autores como [69], muestran resultados comparativos entre el Filtro de Kalman y el Filtro de Partículas como métodos de autolocalización. En el trabajo propuesto por [70] abordan el problema de localización utilizando un algoritmo de mapeo probabilístico y localización simultáneos (SLAM) utilizando una sola cámara. El algoritmo SLAM permite generar mapas probabilísticos del entorno dados los puntos de las proyecciones de la imagen con los mapas obtenidos.

Por otra parte, en [71] proponen un método de localización de un objeto en movimiento a través de una secuencia de imágenes tomadas por una cámara, utiliza el filtro de Partículas como algoritmo de seguimiento basado en la información de múltiples sensores, integran un sistema de visión junto con un sistema de control para seguir de forma continua un objeto. Al igual que autores como [72], proponen un método de seguimiento de objetos basado en el control de movimiento de una cámara utilizan el filtro de Partículas para predecir la posición del objeto en movimiento correspondiente a la información obtenida de una imagen. Autores como [73] analizan el problema entre la detección de un objeto y la estimación de la profundidad y realizan un seguimiento del objeto usando Filtro de Partículas, donde la posición de este objeto es modelado para la estimación de la profundidad. En [74] los autores presentan el seguimiento de un objeto en una secuencia de video, en sustitución de un modelo dinámico del objeto utilizan el método de substracción de fondo para predecir las ubicaciones del objeto y la aplicación del Filtro de Partículas para el seguimiento del objeto.

Capítulo 3

Sensores de desplazamiento

Para la implementación de un sistema de medición que integra diferentes tipos de sensores es necesario conocer sus características, en este capítulo describimos de manera general las características que los sensores de posición ofrecen, así mismo se describe la obtención de los datos y el cálculo de la posición.

3.1. Introducción

En este trabajo queremos estimar la posición de un sistema de escaneo 3D de interiores mientras va recorriendo una trayectoria. La propuesta es utilizar la información que proviene de las mediciones de diferentes sensores de desplazamiento lineal. En este trabajo utilizamos tres sensores: un odométrico, un magnético y un sistema de visión compuesto por una cámara. A partir de estos sensores se integra un solo sistema de medición que nos permitirán extraer la información necesaria para crear un modelo del sistema y dar una solución al objetivo de estimar la posición del sistema.

Estos sensores son la parte principal del sistema de posicionamiento con ellos podemos medir y saber donde se encuentra nuestro sistema de escaneo 3D de interiores y cuanto se desplaza en base a el procesamiento de los datos obtenidos. Por ello, es necesario describir el funcionamiento de los sensores utilizados, ya que de este modo se logra aprovechar las características que ofrecen cada uno de estos para conseguir los objetivos propuestos de esta tesis. La elección de los sensores fue influenciada por su disponibilidad y al uso de trabajos ya desarrollados en el laboratorio de análisis de imágenes, se busca que estos sensores sean complementarios entre sí para la integración de un solo sistema. De esta manera, las mediciones obtenidas por los sensores deberían mejorarse.

3.2. Sensor magnético

Existe el interés de buscar alternativas para determinar la posición de sistemas de escaneo 3D de interiores. Una de las tecnologías que han surgido son los sensores magnéticos que permiten bajo un cierto acondicionamiento determinar la posición de la cámara endoscópica dentro del objeto de inspección. Dentro de este tipo de sensores se encuentran los dispositivos electromagnéticos que son capaces de medir la posición detectando variaciones de inductancia magnética. En trabajos como el de [75] y [76] presentan el uso de sensores electromagnéticos como una solución al problema del seguimiento del movimiento de un endoscopio, el sensor electromagnético se conecta en la punta del endoscopio para medir los movimientos del endoscopio. El sistema es capaz de estimar la posición con un error de 3.83 mm a 6.43 mm. Se ha trabajado con la implementación de métodos para obtener el posicionamiento del endoscopio mediante el análisis de la información obtenida por los sensores, autores como [77] proponen un algoritmo de fusión de datos de los sensores electromagnético y de visión para hacer la medición más precisa, en [78] plantean la implementación del Filtro de Partículas

para la estimación de la posición del endoscopio con los resultados experimentales obtienen una precisión de 2.48 mm. Aunque este tipo de sensores han aportado buenos resultados se han buscado otras alternativas para optimizar el tamaño de los sensores electromagnéticos, como el sistema presentado por [79] que propone un sistema de seguimiento construido en base a sensores magnéticos digitales con un error de posición de 6.62 mm. Los sensores magneto resistivos del tipo soft pot son una alternativa para medir el valor del posicionamiento lineal con respecto a una posición inicial. Gracias a su alta precisión, sus compactas dimensiones y su fácil integración se pueden utilizar fácilmente en una amplia variedad de aplicaciones como por ejemplo, en [80] implementan un sistema automático de control de nivel de agua que se basa en un valor de ajuste definido por el sensor soft pot, en [81] regulan la frecuencia del sonido de un instrumento musical proporcionada por la lectura de las posiciones de dos potenciómetros de membrana soft pot, en [82] estiman la profundidad del sistema de visión utilizando un sensor de membrana soft pot con una resolución de 0.2 mm. En este trabajo utilizamos este tipo de sensor como una solución de medida, su operación se fundamenta en la variación de la resistencia en función de la posición de un imán que va desplazando el potenciómetro lineal.

El sensor soft pot utilizado es un potenciómetro de película delgada en forma de tira con una resistencia variable de 10k, que consta de un cursor móvil (imán) que se desliza por el interior de la tira magnética. Para calcular el desplazamiento lineal un segundo imán se coloca sobre la superficie de la tira y se ejerce presión sobre la capa superior del sensor, el contacto móvil se desliza a lo largo de la cinta resistiva que situado en una o varias posiciones origina un cambio en la resistencia. Los cambios en la resistencia generan mediciones de voltaje a la salida, los cambios en las mediciones de voltaje de salida guardan una relación lineal con los desplazamientos observados.

Para poder calcular el desplazamiento lineal del sistema de escaneo 3D de interiores, se coloca un pequeño metal en la punta del endoscopio, este metal entra a su vez en contacto con el imán localizado en el interior de la escala magnética (soft pot), después con la posición del imán en cada sección lineal del interior de la pieza a escanear se puede leer la medición de la resistencia de la escala magnética y generar datos de voltaje correspondientes a la posición donde se encuentra el imán, que representan la información de posición o desplazamiento lineal del sistema de escaneo 3D de interiores. De acuerdo con [83], la ecuación que relaciona la resistencia con el valor de posición se define en la ecuación 3.1.

Considerando el circuito del sensor soft pot de la Figura 3.1, tenemos una resistencia con

un valor constante R_T de 10 K por unidad de longitud l_T , con un contacto deslizante que puede moverse a lo largo de la cinta magnética que varía el valor de la resistencia R_l , si se le aplica un voltaje constante V_e , da como respuesta un valor de voltaje V_s en relación con el desplazamiento recorrido l_1 . El desplazamiento lineal puede ser calculado de tal manera que por cada voltaje medido se obtenga proporcionalmente una distancia de desplazamiento si cumple con la relación:

$$l_1 = \frac{R_l * l_T}{R_T} = \frac{V_s * l_T}{V_e} \quad (3.1)$$

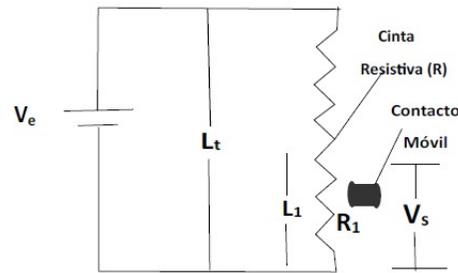


Figura 3.1: Circuito de la resistencia móvil

La Figura 3.2 muestra el deslizamiento del cursor móvil sobre la escala magnética del sensor (en rojo), el contacto móvil (imán) se mueve en dirección horizontal a lo largo de esta superficie activa del sensor.

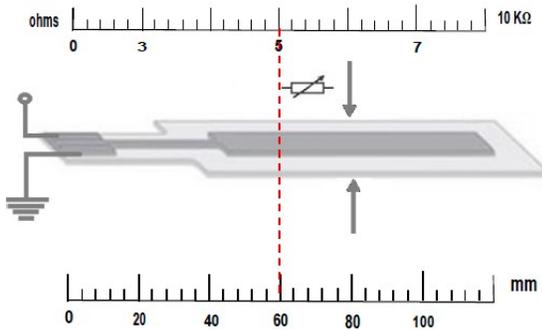


Figura 3.2: Interior de la banda magnética

Los datos generados por el sensor soft pot se adquirieron por medio de un módulo bluetooth

y un microcontrolador desarrollado por [1], este se alimenta con un voltaje constante de 5V, las conexiones se muestran en la Figura 3.3.

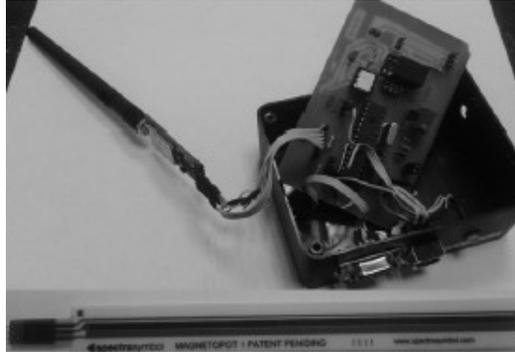


Figura 3.3: Arriba: Controlador bluetooth desarrollado por [1] y abajo escala magnética o soft pot

La razón para usar este sensor de desplazamiento es por que los experimentos requirieron un sistema de posicionamiento que realice mediciones que puedan mejorar el cálculo de la posición a partir del sistema óptico. Entre sus ventajas vemos que es un sensor ligero y delgado que se adapta con facilidad a la configuración del sistema de posicionamiento, es de fácil instalación ya que no requiere de circuitos adicionales para su funcionamiento, sin embargo, entre sus desventajas se encuentra que es muy sensible al tacto, que el voltaje de salida del sensor oscila cuando no se toca el contacto móvil del sensor, además que se tiene que fijar en una posición de referencia y a partir de esta realizar las mediciones.

3.3. Sensor odométrico

La odometría es uno de los sistemas básicos para calcular la posición del sistema con respecto a una referencia. Los sensores odométricos son muy baratos y fáciles de implementar, la estimación de la posición mediante odometría ha sido utilizado por [84], [85], [86]. Sin embargo, la desventaja de los odómetros consiste en una acumulación de errores, usualmente para corregir estos errores, autores como [15], [87],[88] han propuesto un método para reducir los errores de odometría mediante la calibración de los parámetros de posición del robot, otros autores como en [89] y [90] combinan un sensor láser con un odómetro para mejorar la estimación del error de la posición del robot. En [91] realizan una fusión de medidas de GPS con

odometría para la estimación de la localización de un vehículo. En [92] proponen un método de corrección de error mediante el procesamiento de imágenes. En [93] presentan un sistema de navegación de un vehículo autónomo basado en odometría, para modelar el error establecen un modelo matemático para representar el movimiento del vehículo. Las estimaciones de posición y orientación por métodos de odometría se deterioran a medida que el desplazamiento aumenta, debido principalmente al diámetro de las ruedas. El error puede reducirse fusionando las medidas de odometría con mediciones de otros sensores.

Utilizamos un odómetro como un elemento más para realizar la medición de la distancia recorrida por el sistema de medición de interiores mientras que este se mueve, el sensor odométrico utilizado es un prototipo desarrollado por [94]. Mediante este sensor se estima la posición del sistema contando el número de pulsos generados equivalentes al número de vueltas que da el encoder al desplazarse el sistema de medición. Para llevar la cuenta del número de vueltas el hardware utiliza un conjunto de tarjetas electrónicas que componen al sensor odométrico, estas tarjetas están encargadas de realizar los cálculos de la medición de la posición.

El módulo lineal usa un encoder formado por un disco dentado que cuenta con 32 franjas equidistantes entre sí, un led emisor de luz infrarroja que proyecta un haz de luz sobre el disco, un opto acoplador electrónico que actúa como receptor de la luz adjunto a un rodillo con un perímetro de 1.1 mm. Se jala un cordel retráctil que hace girar al disco, así cada vez que se detecte la finalización de una vuelta el encoder hace un conteo de los pulsos generados. El conteo de los pulsos generados por el encoder relaciona las vueltas del disco y el desplazamiento lineal que se produce al jalar la cuerda del encoder, de esta manera podemos calcular la distancia lineal que recorre el sistema de posicionamiento.

En la Figura 3.4 se muestra un esquema del odómetro, de manera general el encoder óptico está formado por un disco de diámetro fijo con un número determinado de ranuras distribuidas uniformemente y se coloca de tal forma que el eje del disco coincida con el eje del rodillo. Debajo del disco se coloca un fototransistor infrarrojo, y enfrente a él un led emisor. Así, cuando el disco gira, las ranuras hacen que el fototransistor reciba luz de manera intermitente por parte del led, generándose así una señal formada por una secuencia de pulsos. Los pulsos detectados se van contando y con el número de vueltas completadas por la rueda podemos conocer la distancia recorrida por el odómetro.

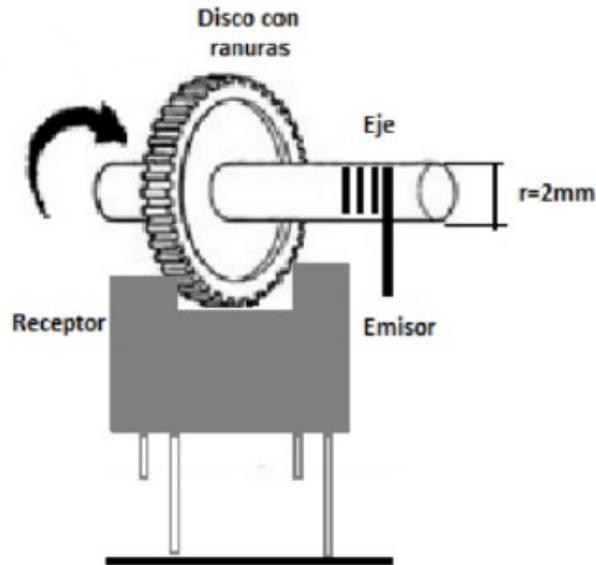


Figura 3.4: Encoder optoelectrónico

En la Figura 3.4 se aprecia el disco utilizado por el odómetro, básicamente podemos observar que éste elemento es una rueda de un diámetro fijo y con un número de dientes uniformemente distribuido a lo largo del perímetro de la rueda.

El cálculo del desplazamiento se realiza al igual que en [84], utilizando la información del encoder y se determina a partir de la ecuación 3.2, la finalización de una vuelta se habrá incrementado en un factor de $2\pi r$ siendo r el radio de la rueda, de esta forma la distancia recorrida esta en función del número de vueltas que haya girado la rueda. La distancia recorrida D en una vuelta esta en función del diámetro de la rueda. Puesto que el perímetro de la rueda es de 2 mm, entonces la distancia lineal que recorre el sistema al contar los pulsos que genera el sistema se calcula de la siguiente forma:

$$Desplazamiento\ lineal(D) = \frac{((2 * \pi * r)(\Delta N))}{n} \quad (3.2)$$

$$Desplazamiento\ lineal(D) = (C * (\Delta N))$$

Donde :

$C = (2\pi r/n)$ se conoce como la constante de sensibilidad odométrica, expresada en unidades de longitud por pulso

r : es el radio de la rueda

n : la distancia que recorre la rueda en cada revolución

ΔN :es la cantidad de pulsos detectados por el encoder al desplazarse

Los odómetros son susceptibles a la acumulación de errores, por lo que es necesario analizar y simular el comportamiento que tiene el odómetro bajo ciertas condiciones para la adaptación del sistema de posicionamiento. Para realizar las pruebas utilizando este sensor mantenemos al odómetro en una posición fija sobre un eje de referencia y solo basta con contar el número de vueltas completadas por la rueda para conocer la distancia recorrida por el odómetro, realizamos pruebas a diferentes intervalos de tiempo, con estas mediciones será posible promediarlas y obtener datos de posición con una mejor estimación. La ventaja del uso del odómetro es su facilidad de manejo para realizar mediciones.

3.4. Sistema de visión

El enfoque de la odometría visual se basa en la extracción de características entre imágenes consecutivas capturadas por una cámara, en el que se establecen las correspondencias de puntos 3D-2D , para obtener información de la estimación del movimiento de la cámara, los trabajos de [95], [96] y [97] presentan un sistema de visión monocular para la estimación del movimiento mediante la correspondencia de puntos entre imágenes, el complementar los sensores de visión con mediciones inerciales mejora la precisión del posicionamiento, por lo tanto se han desarrollado técnicas de seguimiento visual que utilizan la combinación de sensores, estas son propuestas por los autores [98], [99] y [100] que desarrollaron sistemas de visión-inerciales, conformados por una cámara y una unidad de medición inercial (IMU) para estimar la posición de la cámara, utilizan un método basado en la generación de mapas de profundidad utilizando imágenes tomadas en diferentes instantes de tiempo. En [101] presentan un método que utiliza la transformada de Fourier para estimar el movimiento demostrando su viabilidad para un entorno sin obstáculos, la localización y mapeo simultáneo es otra de las técnicas relacionadas al problema de la estimación y ha sido ampliamente utilizada en la localización de robots, en [102] y [103] presentan un método que fusiona datos de un sensor IMU que comprende los 3 ejes de un acelerómetro y los datos obtenidos por un sistema de visión, el algoritmo genera mapas 3D de la escena para calcular la posición de un robot móvil. En el trabajo de [104] utilizan el algoritmo del Filtro de Kalman para combinar datos del sistema de visión con medidas de sensores inerciales mejorando así la estimación del movimiento de un

robot en ambientes interiores y exteriores. Aunque existen diferentes configuraciones de sistemas de odometría visual, como los mencionados anteriormente, este tipo de sistemas muestran varios problemas relacionados con el campo de visión de la cámara, presentan errores en la adquisición de imágenes debido a la presencia de distorsión en las imágenes y la calibración inadecuada de la cámara lo que ocasiona falta de exactitud en la estimación del movimiento. En este trabajo nos enfocamos en estimar los parámetros intrínsecos y extrínsecos de la cámara para obtener una estimación del movimiento más exacta.

El sistema de visión utilizado está compuesto por una cámara del tipo endoscopio y un patrón de círculos de referencia como el de la Figura 3.5. El sistema adquiere una secuencia de imágenes capturadas por la cámara mientras se va moviendo, posteriormente estas imágenes son procesadas para obtener información de la profundidad a la que se encuentra el sistema de visión.

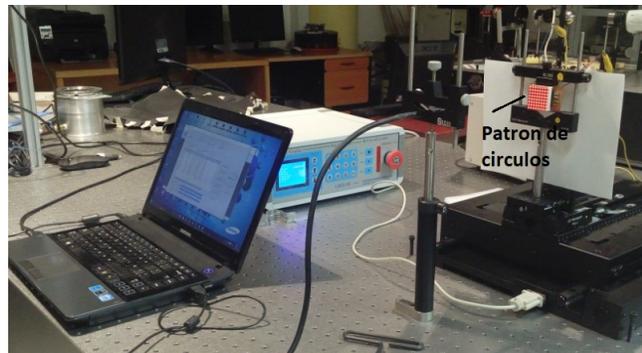


Figura 3.5: Sistema de visión

Para el cálculo del posicionamiento de la cámara que forma parte del sistema de visión, primero debemos realizar la calibración de la cámara, utilizando una plantilla bidimensional de círculos como patrón de calibración, tomando en cuenta que necesitamos encontrar las relaciones entre los sistemas de coordenadas del mundo representado en el patrón de círculos y de la cámara consideramos utilizar el modelo pin hole [105] que se encuentra representado en la Figura 3.6. Observamos como un punto $P(X_w, Y_w, Z_w)$ en el espacio 3D, es representado en el plano de la imagen como un punto $P(x, y)$. El proceso de calibración se llevó a cabo siguiendo la metodología del Toolbox para MatLab desarrollado por Jean Yves Bouguet [106] como resultado se obtienen los parámetros intrínsecos y extrínsecos de la cámara.

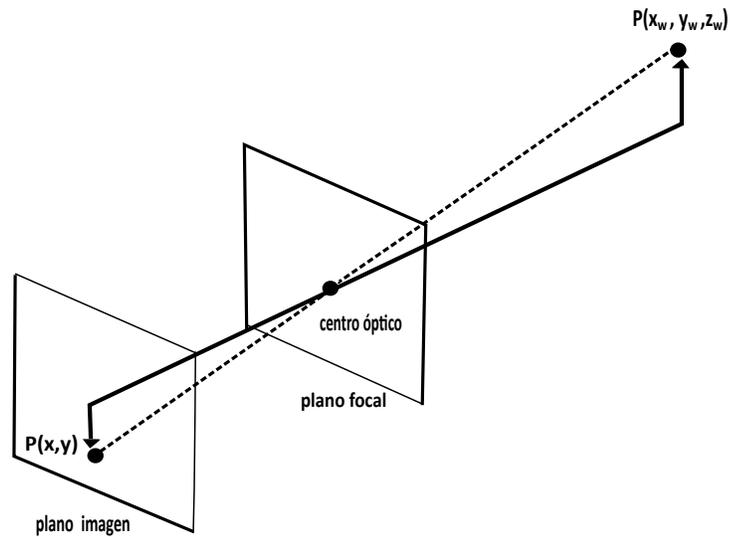


Figura 3.6: Proyección de puntos en la imagen

3.4.1. Modelo para el sistema de visión

El sistema de visión se desplaza con respecto al eje óptico de la cámara, ubicado en el eje z , sin embargo, la posición del sistema de visión puede mostrar una variación menor para los ejes (x, y) . El sistema de visión realiza la adquisición de una secuencia de imágenes del patrón de referencia que se coloca de manera perpendicular a la cámara mientras se va moviendo en 15 posiciones diferentes, este sistema proporciona un valor de posición con respecto a las imágenes adquiridas. De cada imagen del patrón de círculos extraemos los centros de los círculos de manera subpixelica y calculando el centroide de cada círculo. Las coordenadas del centroide de cada círculo (x_w, y_w, z_w) en el espacio 3D son transformados al sistema de

coordenadas de la cámara $(x_c, y_c, z_c)^t$, mediante una rotación y una translación dada por:

$$s \begin{bmatrix} x_c \\ y_c \\ 1 \end{bmatrix} = \begin{bmatrix} \mathbf{R} & \vec{\mathbf{T}} \\ \vec{0} & 1 \end{bmatrix} \begin{bmatrix} x_w \\ y_w \\ z_w \\ 1 \end{bmatrix} \quad (3.3)$$

Donde $X = [x_w, y_w, z_w, 1]^t$ es el vector que contiene las coordenadas de los centroides de cada círculo en el sistema de referencia en el mundo, $x = [x_c, y_c, 1]^t$ son las coordenadas en el sistema de coordenadas de la cámara, s es un factor de escala, $\mathbf{R}=(R_x R_y R_z)$ y $\mathbf{t}=(t_x, t_y, t_z)^T$ son la matriz y el vector con los parámetros extrínsecos de la cámara.

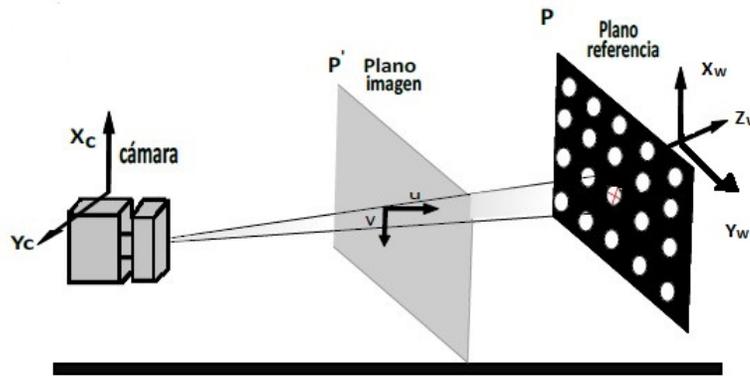


Figura 3.7: Relación entre el movimiento de la cámara y la posición de los puntos en la imagen.

Al colocar el patrón de referencia a una distancia alejado de la cámara, formamos un plano imagen casi perpendicular al eje óptico de la cámara como se muestra en la Figura 3.7.

Para determinar la posición de la imagen con respecto de la cámara debemos poner todos los puntos con respecto al sistema de coordenadas de la cámara. Para lograr esto, utilizamos los parámetros intrínsecos que me ayudan a pasar del plano imagen $(u_i, v_i)^t$ al sistema de coordenadas de la cámara $(x_c, y_c, z_c)^t$ y los parámetros extrínsecos \mathbf{R} y \mathbf{t} , que me ayudan a pasar del sistema de coordenadas del mundo al sistema de coordenadas de la cámara. La ecuación 3.4 define matemáticamente como realizar lo anteriormente descrito. La posición de

la imagen con respecto de la cámara esta contenida en el valor ZI_n del vector de traslación \mathbf{t} .

$$s \begin{bmatrix} u_i \\ v_i \\ 1 \end{bmatrix} = \begin{bmatrix} \alpha & 0 & u_0 & 0 \\ 0 & \beta & v_0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_x \\ r_{21} & r_{22} & r_{23} & t_y \\ r_{31} & r_{32} & r_{33} & t_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_{I_n} \\ y_{I_n} \\ z_{I_n} \\ 1 \end{bmatrix} \quad (3.4)$$

Si se agrupan los parámetros intrínsecos α , β , u_0 , v_0 y los parámetros extrínsecos $r_1 = [r_{11} \ r_{12} \ r_{13}]$, $r_2 = [r_{21} \ r_{22} \ r_{23}]$ y $r_3 = [r_{31} \ r_{32} \ r_{33}]$ del modelo de la cámara en una sola matriz, podemos escribir la ecuación 3.4 como:

$$s \begin{bmatrix} u_i \\ v_i \\ 1 \end{bmatrix} = \begin{bmatrix} \alpha r_1 + u r_3 & \alpha t_x + u t_z \\ \beta r_2 + v r_3 & \beta t_y + v t_z \\ r_3 & t_z \end{bmatrix} \quad (3.5)$$

Si los puntos 3D del mundo se proyectan en la imagen, debemos considerar la matriz de transformación \mathbf{M} definida por:

$$s \begin{bmatrix} u_i \\ v_i \\ 1 \end{bmatrix} = \begin{bmatrix} m_{11} & m_{12} & m_{13} \\ m_{21} & m_{22} & m_{23} \\ m_{31} & m_{32} & m_{33} \end{bmatrix} \quad (3.6)$$

3.4.2. Estimación de la posición

La estimación de la profundidad del sistema de posicionamiento esta relacionada con los cambios entre las coordenadas extraídas de los centroides de los círculos de las imágenes 3.8 y de las proyecciones de sus puntos utilizando el modelo de la cámara. Para la localización del sistema de visión, tenemos un conjunto de imágenes I_n para $n = 1, 2, \dots, 15$, del patrón de referencia que se coloca de manera perpendicular a la cámara de las que se obtiene información del conjunto de puntos característicos sobre cada imagen de los que se conoce su valor de coordenadas en el espacio 3D y de la estimación de los parámetros intrínsecos y extrínsecos de la cámara que son calculados con el toolbox de calibración de Bouguet, ver [106]. Para este trabajo, es importante estimar los parámetros de traslación de la imagen con respecto al sistema de coordenadas de la cámara, el valor ZI_n del vector de traslación \mathbf{t} representan la ubicación del sistema de posicionamiento.

Si se conoce la posición del conjunto de puntos i en la imagen, con coordenadas

$(x_{iw}, y_{iw}, 0)$ en el espacio, se asume que $z_w = 0$, debido a que el patrón de referencia forma un plano con respecto a la cámara, estos puntos se proyectan con coordenadas (u_i, v_i) localizados en la imagen I_1 , entonces se puede estimar la posición del sistema. Utilizando el método de Faugeras [107], se busca encontrar la correspondencia para estos mismos puntos entre imágenes consecutivas hasta la imagen $I_{1:n}$.

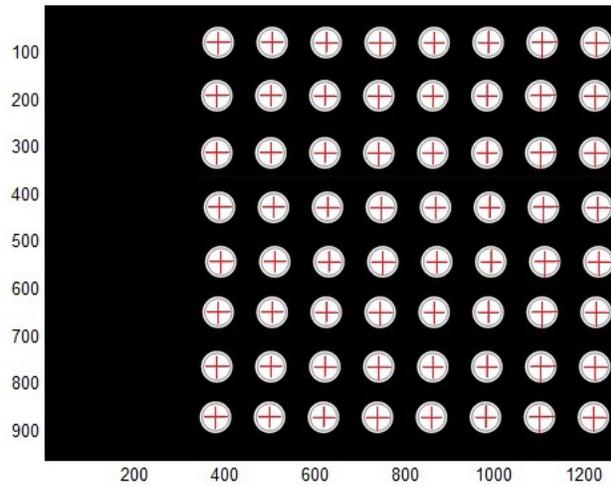


Figura 3.8: Detección de puntos subpixelicos en la imagen

A partir de la representación de las i correspondencias de puntos (x_{iw}, y_{iw}) con su correspondencia de i puntos en la imagen (u_i, v_i) , se calcula la matriz de proyección de la ecuación 3.6. Cada punto (x_{iw}, y_{iw}) se proyecta en (u_i, v_i) se puede expresar de la forma:

$$u_i = \frac{m_{11}X + m_{12}Y + m_{13}Z + m_{14}}{m_{31}X + m_{32}Y + m_{33}Z + m_{34}} \quad (3.7)$$

$$v_i = \frac{m_{21}X + m_{22}Y + m_{23}Z + m_{24}}{m_{31}X + m_{32}Y + m_{33}Z + m_{34}} \quad (3.8)$$

Estas ecuaciones se pueden representar de manera matricial de la forma:

$$\begin{bmatrix} x_i & y_i & 0 & 1 & 0 & 0 & -u_i x_i & u_i y_i & 0 & -x_i u_i \\ 0 & 0 & 0 & x_i & y_i & 0 & 1 & -v_i x_i & -v_i y_i & -y_i v_i \end{bmatrix} \begin{bmatrix} m_{11} \\ m_{12} \\ m_{13} \\ m_{14} \\ m_{21} \\ m_{23} \\ m_{24} \\ m_{31} \\ m_{32} \\ m_{33} \\ m_{34} \end{bmatrix} = 0 \quad (3.9)$$

La solución al sistema de ecuaciones se obtiene mediante el método de descomposición de valores singulares (SVD) escogiendo el eigenvector correspondiente al valor más pequeño, a partir del cual se extraen todos los parámetros de traslación y rotación \mathbf{R} y \mathbf{t} . Los parámetros que definen el movimiento de la cámara son los 3 parámetros de rotación $r_3 = [m_{31}, m_{32}, m_{33}]$ y el parámetro de traslación $t_z = [m_{34}]$.

Una vez obtenidas las coordenadas de los puntos (u_i, v_i) de las imágenes I_0 y I_i , entonces se puede obtener información de la distancia de la cámara con respecto a cada imagen de referencia. De acuerdo con [108] para estimar su posición en cada imagen estos puntos están descritos por:

$$F = \sum_{i=1}^n [x'_i - x_i]^2 + [y'_i - y_i]^2 \quad (3.10)$$

Donde $i = 1, 2, \dots, 15$ es el número de imágenes, (x'_i, y'_i) son los valores de las coordenadas de los píxeles usando los parámetros de la cámara y (x_i, y_i) los valores actuales de las coordenadas en la imagen y F es resultado el valor de la posición.

3.5. Descripción del sistema de posicionamiento

Se requiere implementar un sistema de medición para determinar la posición de un sistema de visión activa, que se desplaza en diferentes posiciones. La configuración experimental del sistema está integrado por los sensores descritos en la sección 3.2: el sensor magnético, el odómetro, y el sistema de visión se colocan en forma paralela para desplazarse en una misma dirección. En la Figura 3.9, se muestra de manera general la ubicación de cada uno de los componentes del sistema de medición.

La captura de las imágenes se llevó a cabo mediante la utilización de una cámara del tipo endoscopio digital USB flexible de 7 mm de diámetro, la parte funcional del arreglo óptico de la cámara está compuesto por un cable flexible de fibras de vidrio de 50 cm de largo, debido a la flexibilidad y diseño de la cámara permite acceder a espacios limitados, útil para inspeccionar sitios difíciles de alcanzar. La cámara captura imágenes a color con una resolución de 640 x 480 píxeles y lleva incorporada la iluminación de 4 leds de alta intensidad con un control para ajustar la intensidad de iluminación, las imágenes tomadas por el endoscopio se pueden almacenar directamente a la computadora sin necesidad de algún tipo dispositivo adicional. El patrón que se utiliza está constituido por una matriz de 8 columnas de círculos y 8 renglones de círculos de color blanco con fondo negro, se integran al sistema de medición el sensor magnético, el odómetro que se colocan en forma paralela en dirección al eje óptico de la cámara.

Los sensores magnético y odómetro permiten medir la posición del patrón de referencia de manera simultánea al desplazamiento del sistema de visión, la idea de la integración de estos sensores es comparar las mediciones entre sensores, compensar los errores de medición de cada sensor y obtener una estimación de la posición en función de todas las medidas. Debido a la implementación del sistema de medición podemos evaluar los sensores de manera independiente, se procedió a realizar la adquisición de los datos para cada sensor, se midieron tres secuencias de datos, cada medición se realizó a diferentes posiciones en intervalos de 10 mm, con la finalidad de que las mediciones estén dentro del mismo intervalo de distancias, se consideró un intervalo de medición máximo de 150 mm y tiempo de muestreo para la adquisición de datos de 500 ms.

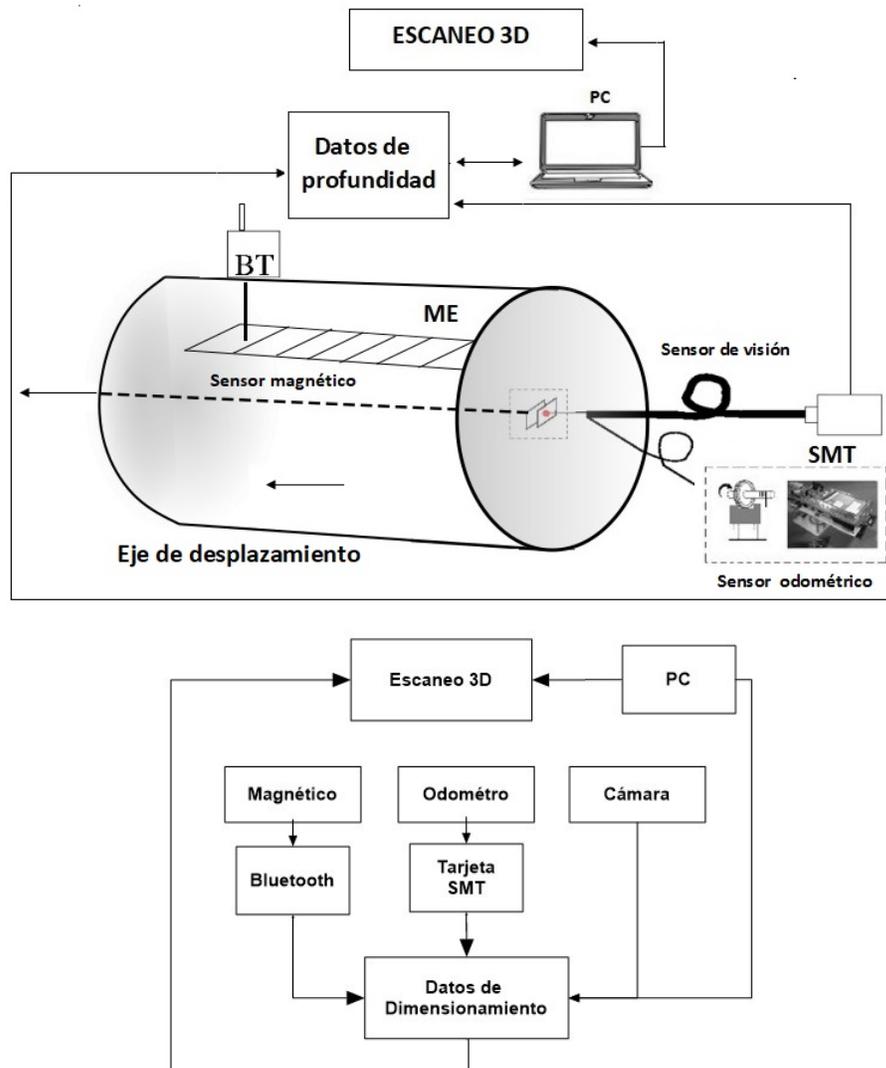


Figura 3.9: a) Sistema de medición propuesto, compuesto por un sensor odométrico, sensor magnético y un sistema de visión, b) Diagrama de adquisición de datos de los sensores.

Una vez hecho el montaje de los sensores se prepara el sistema para hacer pruebas de acuerdo a lo observado en la Figura 3.10, se tomaron en cuenta algunas condiciones iniciales para asegurar la precisión del sistema de medición, cada desplazamiento del sensor se realiza en intervalos de 10 mm en dirección de un solo eje. Nuestra configuración del sistema está diseñado para una distancia de hasta 150 mm de profundidad en la que el campo de visión de la cámara se vuelve limitado.

Para calcular la posición del sistema de medición se considera necesario colocar al sistema

de medición alineado con el eje óptico de la cámara de manera horizontal para definir el eje sobre el que se va desplazando el sistema

- Realizar el montaje de los sensores y formar un solo sistema de medición.
- Se ajustó el sistema de medición en una posición inicial fija que será la referencia de medición.
- El sistema de referencia fijo esta referenciado en dirección al eje óptico de la cámara.
- Los sensores deben estar alineados hacia una misma dirección.
- El patrón de referencia se coloca de manera perpendicular al eje óptico de la cámara para comenzar con la captura de las imágenes
- Definir los intervalos de tiempo de adquisición y desplazamiento para la adquisición de las mediciones con el sistema de medición.
- La posición donde se captura la imagen debe sincronizarse con la adquisición de las mediciones con los sensores adicionales
- Adquisición de las mediciones x_i mientras se mueve el sistema.
- Obtener el cálculo del desplazamiento del sistema usando las ecuaciones de desplazamiento lineal definidas para cada sensor.

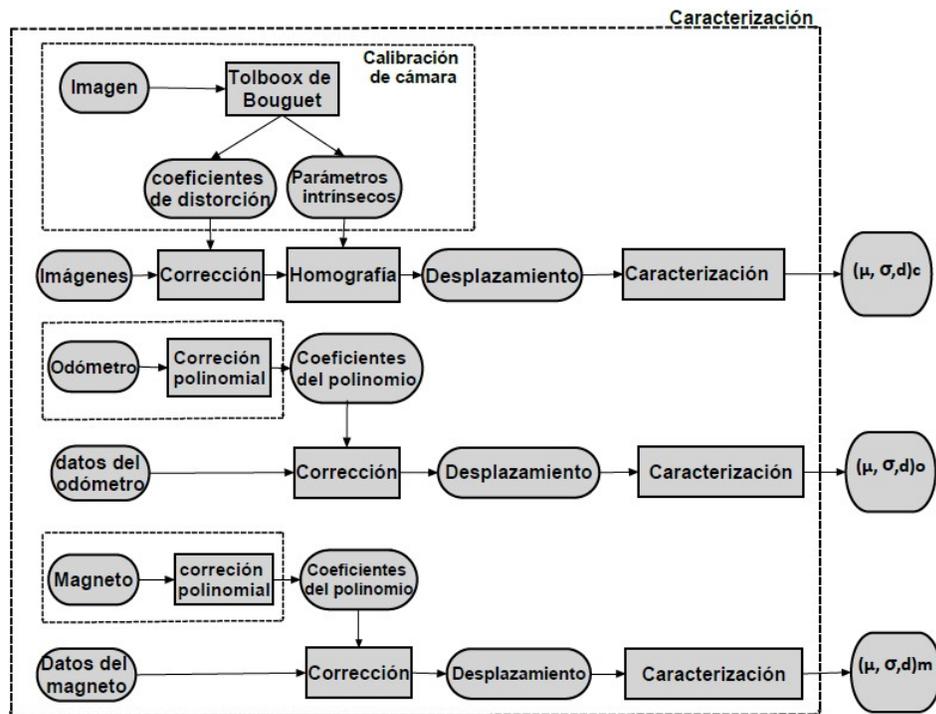


Figura 3.10: Caracterización de los sensores para el cálculo de la profundidad

Una vez que contamos con los datos que nos proporciona la secuencia de imágenes capturadas por la cámara y la adquisición de los datos por los sensores, debemos determinar la manera en la que vamos a estimar la posición del sistema. Para dar solución al problema de la estimación de la posición los datos son modelados mediante técnicas probabilísticas como la fusión de datos y estimadores de estado. Estas técnicas serán explicados en el siguiente Capítulo.

Capítulo 4

Metodología Experimental

En este capítulo realizamos una descripción de las diferentes técnicas propuestas para dar solución al problema de la estimación del posicionamiento del sistema de medición.

4.1. Estimación de la profundidad

En este capítulo se expone la metodología utilizada de los algoritmos propuestos, que constituyen los pasos para la obtención de la solución del problema. Se explica como a partir de los datos de los sensores obtener un modelo del desplazamiento del sistema, proponemos un enfoque probabilístico para modelar las incertidumbres de las posiciones provenientes de los sensores.

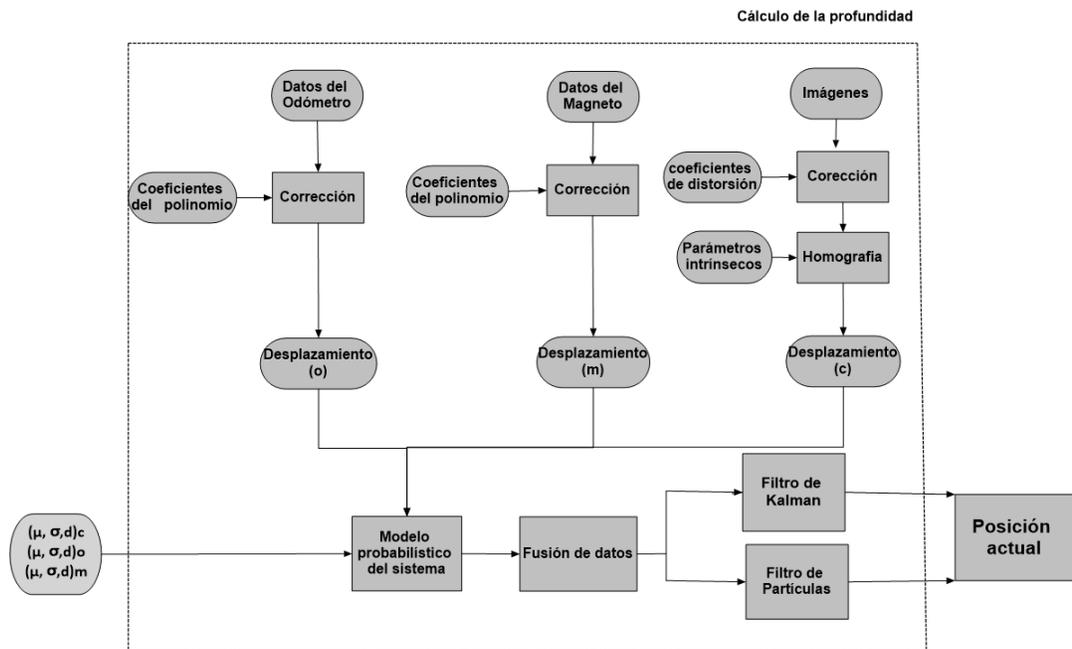


Figura 4.1: Metodología utilizada para el cálculo de la profundidad

La metodología realizada en este trabajo para calcular la profundidad se muestra en la Figura 4.1, se usó el sistema de dimensionamiento descrito en la sección 3.5 del Capítulo 3. Utilizando los datos obtenidos determinamos un modelo para cada sensor mediante distribuciones de probabilidad, fusionamos los datos obtenidos de los sensores mediante la combinación de las distribuciones de probabilidad (PDF) definidas para modelar los datos de cada sensor con la finalidad de disminuir el error en la estimación de la posición. Posteriormente formulamos el modelo que describe el movimiento del sistema, nuestro trabajo se centra en la implementación de algoritmos como los Filtros de Kalman y Filtro de Partículas como estimadores del posicionamiento del sistema, con los resultados obtenidos buscamos encontrar un método que

nos proporcione la menor incertidumbre en la posición del sensor, es decir, reducir el intervalo donde creemos que puede estar el sensor una vez que alcanza una determinada posición.

4.2. Modelo de la medición

El sistema de posicionamiento que utilizamos va tomando una serie de mediciones de manera repetida, estas mediciones constituyen los datos observados por los sensores. Cuando se desea analizar la información extraída de cada sensor acerca de los valores de la posición del sistema, un primer paso consiste en modelar el comportamiento de los datos tomando en cuenta su incertidumbre asociada, esta información puede ser modelada mediante funciones de probabilidad que describen la forma en que varían los resultados como en [109], [110], [111], [112], [113]. En esta sección formalizamos numéricamente el conjunto de datos obtenidos, usando métodos probabilísticos.

Sea X la variable que representa al conjunto de todos los datos obtenidos de la posición durante el proceso de medición y x_i a los distintos valores medidos por los sensores mientras el sistema esta en movimiento, donde $(i = 1, 2, 3, \dots, 15)$ representa el i ésimo valor de posición que forman muestras de tamaño N , donde N es el número de veces que se toma una medida en cierta posición para este caso el número de repeticiones es $N = 3$. Los datos son medidos en intervalos discretos separados cada 500 ms. Estas mediciones están relacionadas mediante la función $X = F(x_1, x_2, \dots, x_i)$, que define que para cada cierta medida x_i proveniente de los sensores se asocia a un valor de probabilidad en cierta posición $F(x) = P(X = x)$, para representar las probabilidades mediante una función de distribución perteneciente a un valor de posición se definen sus parámetros estadísticos de la media como:

$$\mu = E[x] = \sum_{i=1}^n x_i P_i \quad (4.1)$$

La esperanza matemática $E[x]$ representa el valor de la media μ de todos los valores que tomaría la variable X en cada periodo de tiempo, siendo P_i la función de probabilidad de X . Mientras que la varianza σ^2 mide la dispersión o distanciamiento de cada valor de x_i , respecto a la media, se define como:

$$\sigma^2 = V[x] = \sum_{i=1}^n (x_i - \mu)^2 P_i \quad (4.2)$$

4.2.1. Modelos probabilísticos

Al trabajar con datos x_i provenientes de los sensores y su incertidumbre asociada, se requiere elegir un modelo para describir el comportamiento del sistema de posicionamiento, debido a que no se tiene un valor de posición exacto, un modelo estadístico muy utilizado se basa en la representación de los datos mediante distribuciones de probabilidad normal (PDF) denotada por $N(\mu, \sigma)$, así cada valor del conjunto de datos medido por el sistema de posicionamiento, es representado mediante una distribución, esta distribución representa una región todos los posibles valores de X dentro de un intervalo discreto de medición y podemos derivar la máxima probabilidad de un valor de posición, este valor representa donde se encuentra posicionado el sistema en cierto instante de tiempo, denotada por la ecuación [114]:

$$F(x) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (4.3)$$

La función $F(x)$ toma la forma de una gaussiana simétrica con centro en la μ que representa la probabilidad de todos los distintos valores que puede tomar x_i . Donde X_i es el conjunto de datos medidos por los sensores (sistema de visión, odómetro y magnético), μ es la distancia real del objeto y σ es la desviación estándar de la distribución para la medición del sensor.

La función $F(x)$ alcanza su valor máximo entorno a la media μ , entonces será más probable observar un dato cerca al valor medio, por otra parte la desviación estándar σ cuanto mayor sea su valor más se dispersarán los datos entorno a la media, por lo tanto un valor pequeño de este parámetro indica, una gran probabilidad de obtener datos cercanos al valor medio de la distribución.

La Figura 4.6 es una representación de la función de la posición x con sus incertidumbres perteneciente a cada sensor $X(i)$ y muestra la probabilidad de estar en una posición dada una medición. La finalidad de modelar los datos es la de representar la información obtenida de forma que sea posible utilizarla para realizar una asociación de datos proveniente de diferentes fuentes, describir el movimiento del sistema y de actualizar la estimación de la posición en la que se encuentra el sistema en cada instante.

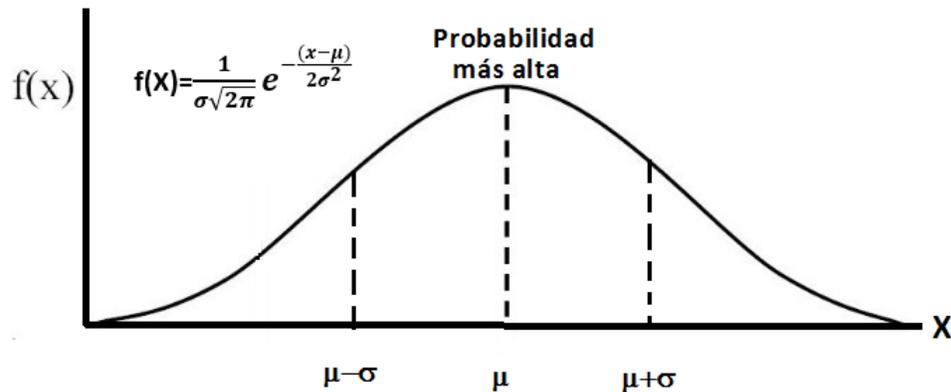


Figura 4.2: Representación de una función densidad de probabilidad

4.3. Estimación de parámetros

Consideramos al sistema de posicionamiento como un sistema dinámico lineal que va tomando una serie de mediciones en intervalos de tiempo discretos, este conjunto de datos está representado por un modelo probabilístico que describe el posicionamiento del sistema, así, cada valor del conjunto de datos medidos por el sistema está representado por una distribución de probabilidad normal $N(\mu, \sigma)$. Para dar seguimiento al sistema, se realiza la estimación de los valores de posición en cada instante de tiempo, sin embargo, en el proceso de estimar la posición del sistema, hay datos de posición que se desconocen. En este tipo de problemas, se plantea la estimación de los datos faltantes mediante la interpolación lineal y el algoritmo de Máxima Expectación (EM) para estimar los parámetros de la distribución de probabilidad que represente el valor de posición de los datos faltantes. Una vez que se tenga un conjunto de datos completos se puede realizar una representación estadística del sistema.

4.3.1. Interpolación lineal y el algoritmo de Máxima Expectación (EM)

En la práctica, el conjunto de mediciones que obtenemos por los sensores puede presentar pérdidas de algunos valores durante las mediciones en algún instante de tiempo, la causa de la pérdida de estos valores puede ser por fallas durante el proceso de adquisición de datos de un sensor, falta de la lectura del sensor, errores durante la adquisición de los valores medidos. Los errores y la presencia de información faltante de manera aleatoria lleva consigo dificultades para el planteamiento del modelo del sistema de posicionamiento [115] y disminución de

precisión en las estimaciones de la posición.

Es importante que cuando se maneje un conjunto de datos con presencia de información faltante, se debe tomar en cuenta utilizar algún tipo de metodología como solución, en [116], proponen la aplicación del algoritmo de Máxima Expectación (EM) como herramienta para realizar una estimación de los datos faltantes en las muestras, a partir de valores ya medidos.

Dado que tenemos un conjunto de datos discretos de tamaño n correspondientes a las posiciones obtenidas por los sensores y posiciones donde no se obtuvo información tal como se muestra en la Figura 4.3. Este trabajo enfrenta al problema de la presencia de datos faltantes, por lo que estimaremos los datos incompletos al igual que en [117],[118], [119] mediante el algoritmo EM. Calculando los parámetros estadísticos de la media y la desviación estándar que involucran el modelado de la distribución de probabilidad del dato que no fue medido y complementar el conjunto de datos como en [120], [121]. Describiremos el algoritmo (EM) y el procedimiento de la estimación de estos parámetros.

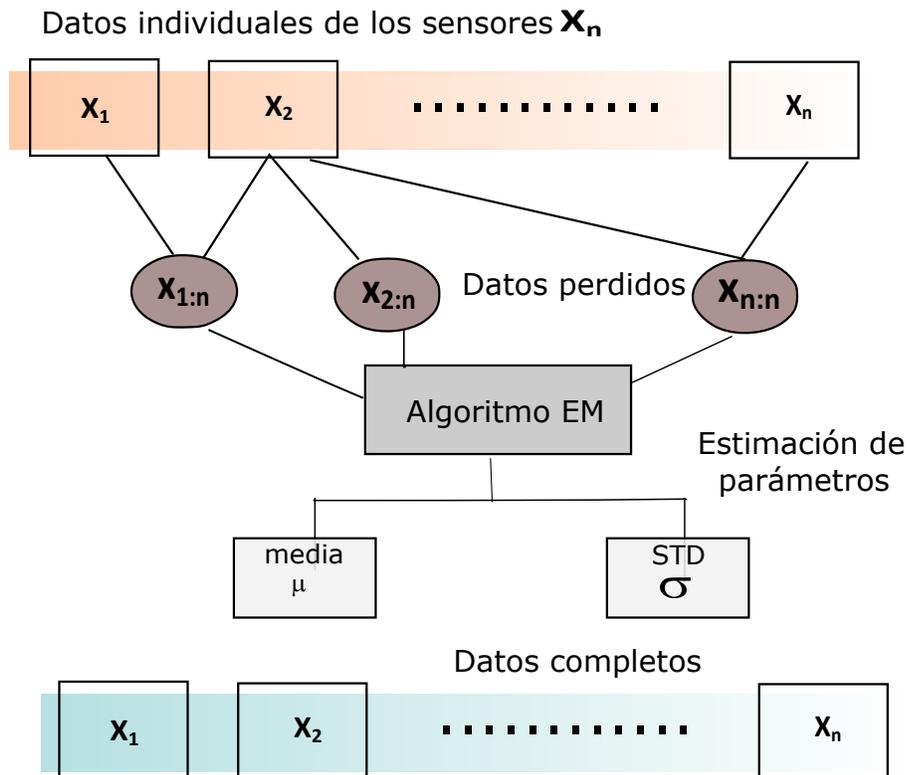


Figura 4.3: Representación de la estimación del conjunto de datos faltantes a partir del conjunto de valores observados.

En el procedimiento del algoritmo EM, el método inicia utilizando el conjunto de datos medidos por el sistema que están representados por una distribución de probabilidad normal $N(\mu, \sigma)$, para estimar los parámetros (μ, σ) de un valor x donde la medición no se obtuvo y poder calcular la distribución de probabilidad $F(x)$ en esa posición. Si conocemos los valores x_1 y x_2 de dos distribuciones representadas por $N_1(\mu_1, \sigma_1)$, $N_2(\mu_2, \sigma_2)$ correspondientes a los intervalos de tiempo t_0 y t_1 respectivamente y se requiere conocer el valor $x_{1,2}$ en un valor de posición que no ha sido medido tal como se muestra en la Figura 4.4. En la metodología propuesta en [122] se emplea la interpolación entre dos valores para estimar los parámetros μ y σ de los datos faltantes, para posteriormente junto con el algoritmo EM encontrar los valores con mayor probabilidad para formar con estos valores una nueva distribución $N_{1,2}(\mu_{1,2}, \sigma_{1,2})$ que modele el valor no adquirido de la posición.

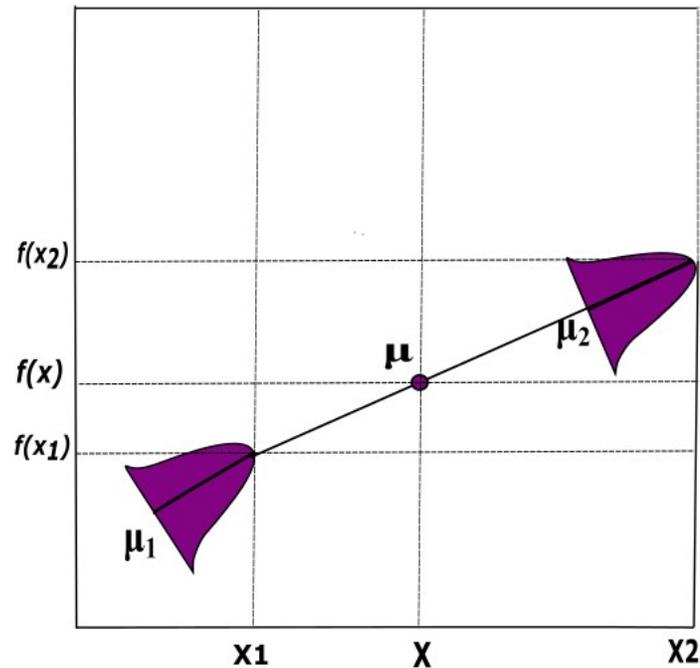


Figura 4.4: Interpolación de densidades de probabilidad

El algoritmo EM utiliza un procedimiento iterativo para la estimación de los parámetros relacionadas a las probabilidades de la posición, consiste básicamente de dos pasos, el Paso *E* (cálculo de esperanzas) y un paso *M* (paso de maximización):

Paso *E* (estimación de los valores faltantes) a partir de los datos observados (medidos) se estiman los datos faltantes, el valor esperado desconocido *E* puede ser estimado por la

media μ , y σ por la desviación estándar, sustituyendo posteriormente estos datos para los datos faltantes.

Paso M (actualización de las estimaciones) se reemplazan las estimaciones obtenidas en el paso *E* y se calculan los parámetros de las máximas probabilidades considerando los datos estimados, donde se tenga valores observados no se modifican los valores y donde se presente la ausencia de valor se sustituyen por los valores de máxima probabilidad, de esta manera las ecuaciones para calcular los nuevos parámetros de la distribución pueden expresarse del siguiente modo:

$$\mu_i = (1 - \alpha)\mu_1 + \alpha\mu_2 \quad (4.4)$$

$$\sigma_i^2 = \alpha^2\sigma_1^2 + (1 - \alpha)^2\sigma_2^2 + 2(1 - \alpha)\alpha\text{cov}(x_1, x_2) \quad (4.5)$$

Cuando obtenemos los valores de la media y varianza de los valores faltantes mediante las ecuaciones 4.4 y 4.5 se establece una formulación general para la deducción de datos faltantes mediante la interpolación lineal y el algoritmo EM. Se demuestra que la interpolación lineal de dos distribuciones da como resultado otra distribución $N_{1,2}(\mu_{1,2}, \sigma_{1,2})$ con una media $\mu_{1,2}$ ($\mu_1 \leq \mu_{1,2} \leq \mu_2$) y una varianza $\sigma_{1,2}$ ($\sigma_1 \leq \sigma_{1,2} \leq \sigma_2$), una vez que se obtenga el conjunto de datos completos en base al enfoque probabilístico podemos realizar una asociación de datos mediante la fusión de sensores. .

4.3.2. Formulación del algoritmo

Para ser más específicos en el procedimiento de la estimación de los datos faltantes, podemos establecer una serie de pasos para la formulación de este algoritmo:

- Inicia suponiendo los parámetros desconocidos con valores aleatorios y los usa para calcular las probabilidades.
- Utilizar los datos conocidos con los parámetros actuales para estimar los valores faltantes.
- Utilizar los valores estimados para completar los datos.
- Re-estimar los parámetros con los nuevos datos.
- Repetir todos los pasos hasta lograr la convergencia de los valores de los parámetros y con esta la obtención de la máxima probabilidad.

El cuadro 4.1 muestra el procedimiento para la estimación de los parámetros mediante el algoritmo EM.

Entrada:	Parámetros iniciales μ y σ
-----------------	---------------------------------------

Etapa E (Expectación): \leftarrow calcular la probabilidad $P(x|z)$

$$P(z|x) = \frac{w_j P(x|z)}{\sum_{i=1}^m P(x|z)}$$

for $i = 1..n$

Etapa M (Maximización): \leftarrow re-estimar los parámetros de $P(x|z)$

$$w_i^{(t+1)} = \frac{\sum_{i=1}^N P(x_i|z)}{N}$$

$$\mu_i^{(t+1)} = \frac{\sum_{i=1}^N P(x_i|z)x_i}{\sum_{i=1}^N P(x_i|z)}$$

$$(\sigma_j^{(t+1)})^2 = \frac{P(x_i|z)(x_i - \mu_j^{(t+1)})(x_i - \mu_j^{(t+1)})}{\sum_{i=1}^N P(x_i|z)}$$

Recurción : \leftarrow Repetir hasta que converga a un valor máximo

end

Salida:	reemplazar los parámetros μ y σ .
----------------	--

Cuadro 4.1: Pasos del algoritmo *Máxima Expectación (EM)*

4.4. Fusión de sensores

Actualmente los procesos de fusión de datos se utilizan para la detección y seguimiento de objetos [11], [123], [124], [125], en el seguimiento de vehículos autónomos [126], [127], [128], para la detección de obstáculos [129], [130], en el reconocimiento de la actividad

humana y el seguimiento de personas en tiempo real [131],[132],[133], en áreas de la industria es utilizado para la reconstrucción tridimensional y evaluación de partes fabricadas [134],[135] [136]. Las investigaciones actuales se centran en la fusión datos de sensores con técnicas probabilísticas [137],[138] como el Filtro de Kalman [139], Filtro de Partículas [140],[141], buscando una solución apropiada.

Puesto que es habitual que los datos provenientes de múltiples sensores son imprecisos, debido a que los sensores pueden proporcionar valores erróneos por circunstancias externas que afectan a la adquisición y procesamiento de los datos. Se deriva la necesidad de mejorar la calidad de la información utilizada, en esta tesis se ha desarrollado un sistema de posicionamiento que permite utilizar distintos sensores, realizamos la fusión de la información de los datos proporcionados por los sensores (odómetro, magnético y óptico) para la estimación de la posición, de acuerdo con el modelo de la Figura 4.5. La principal motivación de la fusión de múltiples sensores es que al combinar sus mediciones se obtendrá una estimación de posición mejorada, realizando una reducción de la imprecisión e incertidumbre de las mediciones, que pueden llegar a presentar por separado dichos sensores [142].

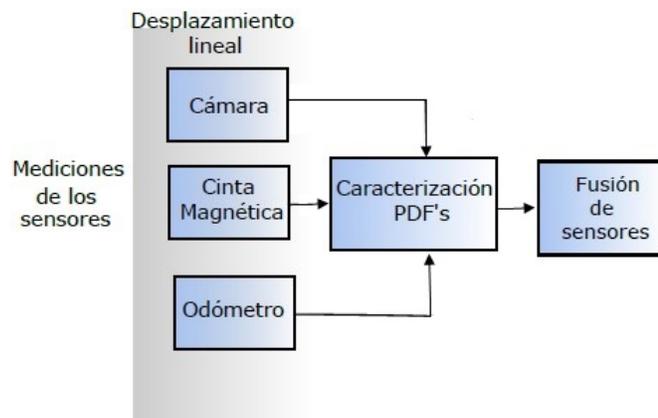


Figura 4.5: Fusión de datos

4.5. Modelo de mezcla de distribuciones

Presentamos el algoritmo EM para estimar los parámetros μ y σ pertenecientes a las distribuciones de los datos faltantes, con el conjunto completo de datos podemos caracterizar las funciones de probabilidad PDF asociadas al modelo de cada sensor como en [143], [144],

[145], [146]. Para agrupar los datos que provienen de los diferentes sensores [147], [148], [149] la asociación de las distribuciones de los datos se realiza mediante una mezcla de gaussianas (GMM).

La mezcla de gaussianas se refiere a la combinación lineal de n distribuciones de probabilidad PDF(x), mediante la multiplicación de las probabilidades que modela cada sensor obteniendo como resultado una función de probabilidad conjunta compuesta por la superposición lineal de las distribuciones, dada la ecuación 4.6, el modelo de la mezcla de las distribuciones se representa como:

$$F_x(x) = \prod_{i=1}^n w_i F_{x_i}(x_i) \quad (4.6)$$

Donde cada F_{x_i} representa la distribución de cada sensor del valor x_i representada por 4.3, x_i es el vector de dimensión i que contiene los parámetros correspondientes a las posiciones, n representa el número de distribuciones que tiene el modelo representadas por la ecuación 4.3. Cada una de estas distribuciones lleva asociado un peso w_i dado que una de las propiedades que deben cumplir las distribuciones es que los datos deben ser números que se encuentren en un intervalo de $[0,1]$, es decir deben estar normalizados de tal forma que $\sum w_i = 1$.

El motivo principal del uso de mezcla de gaussianas es encontrar una estimación de la combinación lineal de dos o más distribuciones que proporcione una mejor caracterización del conjunto de datos con el que se trabaja, para obtener una mejor estimación de la localización del sistema y reducir la incertidumbre de los datos, la posición estimada es corregida mediante estas distribuciones, resultando una distribución de menor varianza, al igual que en [150].

En la Figura 4.6, mostramos un conjunto de datos ajustados por un modelo de mezcla de gaussianas, son tres distribuciones (rojo, verde y azul) que representan el modelo de los sensores, mientras que es posible apreciar en color negro la combinación de las distribuciones. Una vez que estas distribuciones han sido generadas para caracterizar un modelo general de todo el conjunto de datos sin tomar en cuenta las características independientes de los sensores, se pueden utilizar en el desarrollo de métodos de estimación de estados.

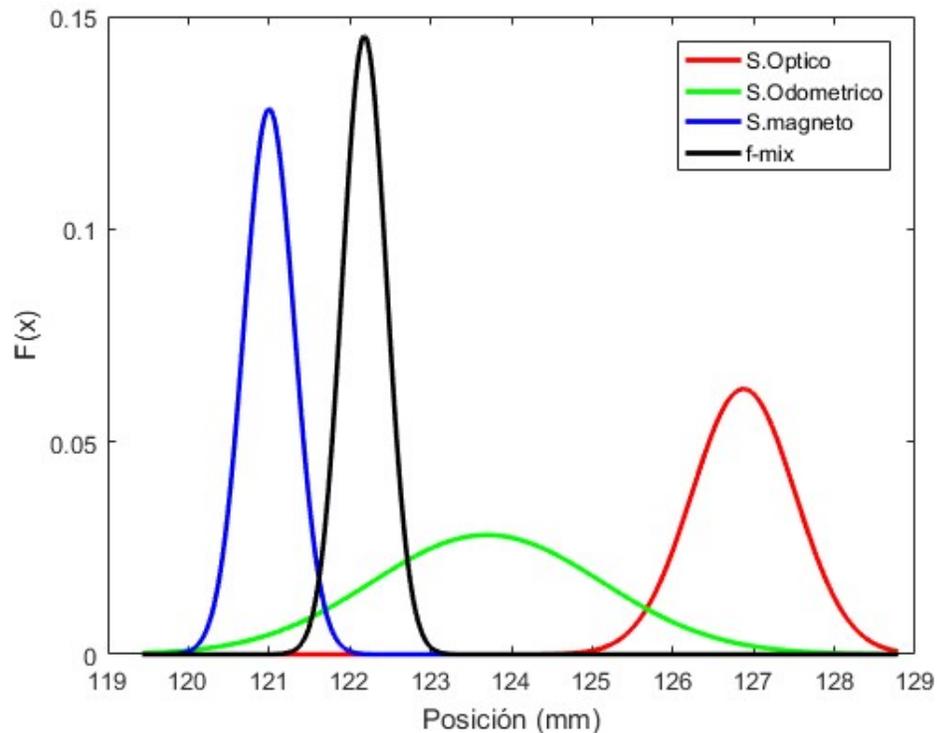


Figura 4.6: Representación de la mezcla de distribuciones. Distribución de probabilidad del sensor óptico (rojo), distribución del sensor odométrico (verde), distribución del sensor magnético (azul) y f-mix representa la mezcla de las distribuciones.

4.6. Solución al problema de estimación

Existen diferentes alternativas para solucionar el problema de estimar la posición de un objeto móvil [151], [152], [153]. Los métodos más utilizados para resolver este problema han sido los filtros probabilísticos [154], dentro de este tipo de filtros se encuentran el Filtro de Kalman (FK) y el Filtro de Partículas (FP). Estas técnicas son muy útiles cuando se necesita modelar mediciones con incertidumbres que son representados mediante distribuciones de probabilidad (PDF). En general ambos filtros se basan en el planteamiento de la modelización de un sistema dinámico lineal que varía en el tiempo, representado por el modelo de movimiento y el modelo de medida de los sensores, ya que consideramos que el sistema se mueve a lo largo de una trayectoria y a su vez va adquiriendo el valor de posición donde los sensores realizan una medición y estimando el estado donde se encuentra en un determinado instante de tiempo.

En esta sección se presentan ambos métodos, nos enfocaremos en la descripción de su formulación, con el objetivo de resolver el problema de estimación obteniendo un vector de estado a partir de un conjunto de observaciones, con el fin de mejorar y compensar el ruido asociado a los valores de localización del sistema de posicionamiento.

4.7. Modelo del sistema

Un sistema dinámico lineal puede ser representado de manera que su espacio de estados es:

$$x_t = A_t x_{t-1} + B_t u_t + v_t \quad (4.7)$$

$$z_t = H_t x_t + w_t \quad (4.8)$$

La actualización del estado estimado en función de los cambios de posición del sistema están dados por la ecuación 4.7 y la ecuación 4.8 que establecen una relación entre el estado estimado del sistema y la observación en un instante de tiempo, donde A_t es un operador de transición de estados y B_t es un operador dentro del espacio de observaciones x_t representa el vector de estados a estimar en cada instante de tiempo t , z_t es el vector de observaciones (medidas) provenientes de los sensores, v_t es un error aleatorio de la estimación de estado y w_t es un error aleatorio asociado a la observación.

El objetivo consiste en hacer una estimación de las variables de estado de un sistema dinámico con respecto al tiempo x_t a partir de un conjunto de observaciones z_t , para calcular la distribución de probabilidad $P(x_t|z_t)$ asociada a la posición representados por:

$$x_t = [x_1(t), x_2(t), x_3(t) \cdots, x_n(t)] \quad (4.9)$$

De manera similar, el vector de mediciones z_t contiene la asociación de los datos de los sensores y es de la forma:

$$z_t = [z_1, z_2, z_3, \cdots z_m(t)] \quad (4.10)$$

donde m y n son el número de estados y de mediciones respectivamente. Tanto el vector de estados como el de mediciones están relacionados de forma que a partir de la realización de

una medición, la estimación del estado se actualiza cada que se dispone de una nueva medición.

El planteamiento de un modelo de estados basado en la ecuación 4.7, es indispensable para tener el conocimiento de la posición del sistema, definimos un modelo de estados como en la Figura 4.7 para representar el comportamiento dinámico del sistema que se encuentra en el estado x_{t-1} mientras que se mueve a un estado x_t , donde puede observarse que el estado actual siempre depende del estado anterior, cada estado está relacionado con la posición del sistema.

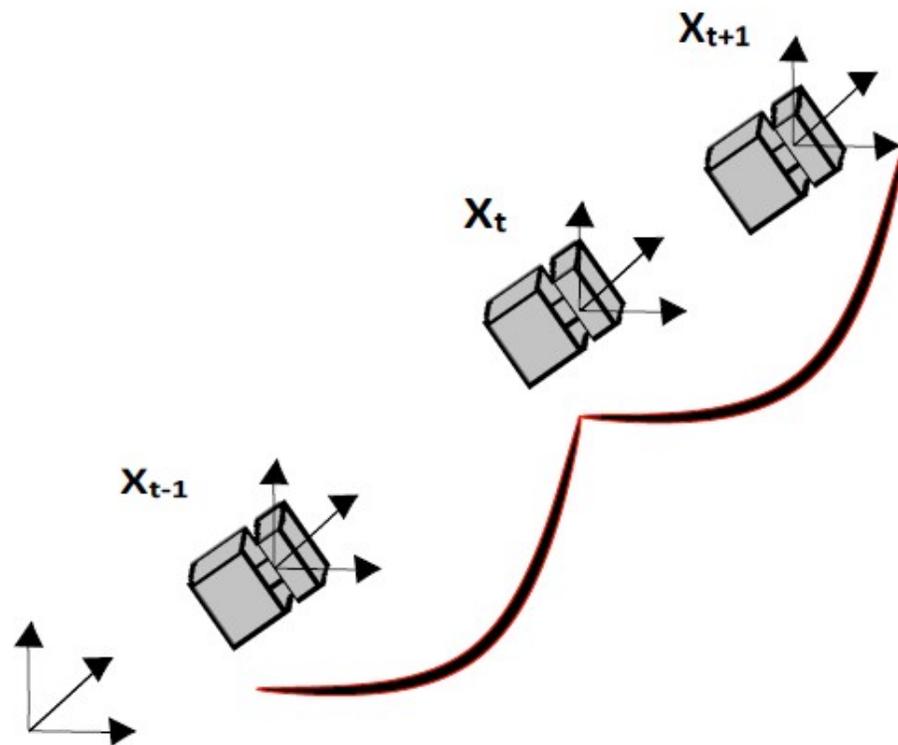


Figura 4.7: Transición de estados. Las estimaciones consecutivas de la posición del sistema de posicionamiento están indicadas en cada estado, la representación del desplazamiento del sistema predice el siguiente estado a partir de la transición de estado anterior.

Las relaciones dinámicas del modelo lineal del sistema son importantes para resolver el problema de la estimación de la posición del sistema y desarrollar posteriormente un análisis estadístico mediante el Filtro de Kalman y el Filtro de Partículas, métodos que en este trabajo han sido propuesto para encontrar la solución a la estimación de estados.

4.8. Filtro de Kalman (FK)

Para resolver el problema de la estimación de la posición del sistema, el Filtro de Kalman es un método recursivo que permite estimar el estado del sistema, predecir una nueva observación y actualizar el valor de posición dado un conjunto de medidas realizadas por los sensores en cada instante de tiempo t tal y como se muestra en la Figura 4.8. En [155],[156], [157], se presenta la aplicación de este método para procesar la información de estado y de las medidas para representar la posición del sistema planteando, con la formulación de este filtro se busca optimizar el error presente en las mediciones.

El Filtro de Kalman propaga la distribución perteneciente al estado x_{t-1} en el instante $t - 1$ recursivamente a través de las ecuaciones 4.7 y 4.8, al inicializar el filtro recibe el valor de la posición en el estado x_{t-1} con una covarianza P_{t-1} , en la etapa de predicción el filtro estima el desplazamiento del sistema de medición que se ha producido desde el instante $t - 1$ al t , luego actualiza el vector de estado x_t con un error u_t , después de las observaciones z_t realizadas por los sensores en el instante t . La actualización se lleva a cabo a través de la ganancia de Kalman K tratando de reducir el error, el filtro encuentra una solución de manera recursiva, tal como se muestra en la Figura 4.8. El Filtro de Kalman calcula la estimación del estado x_t en el instante actual t a partir de todas las observaciones.

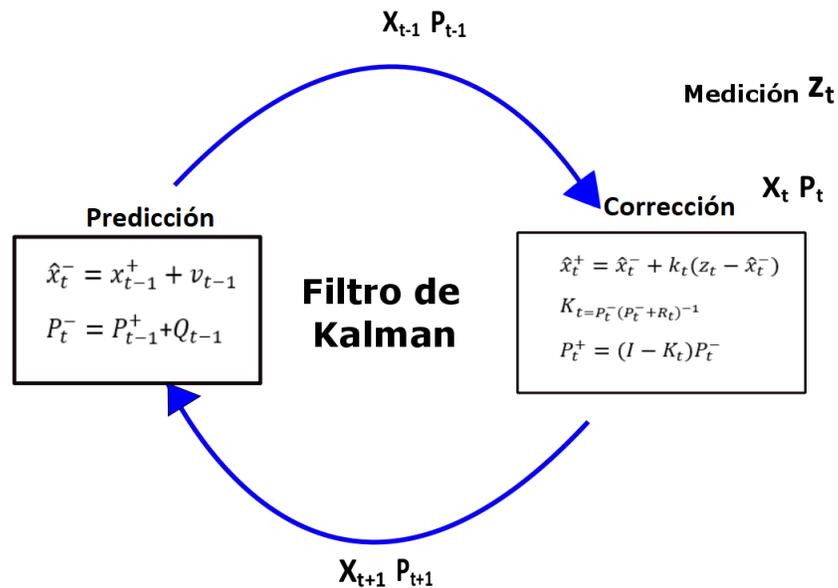


Figura 4.8: Diagrama Filtro de Kalman

Para describir el movimiento del sistema a través de un instante de tiempo, consideramos las ecuaciones de la sección 4.7 para representar el sistema dinámico para la estimación de la posición simplificadas de la siguiente manera:

$$x_t = x_{t-1} + u_t \quad u_t \sim N(0, Q_t) \quad (4.11)$$

$$z_t = x_t + v_t \quad v_t \sim N(0, R_t) \quad (4.12)$$

Donde u_t es ruido asociado al proceso representado por una distribución normal $N(0, Q_t)$ y v_t representa el ruido asociado a la medida representado por una distribución normal $N(0, R_t)$.

Para la inicialización del Filtro de Kalman es necesario plantear un valor inicial de un estado x_0 y un valor de incertidumbre P_0 , estos valores representan el estado x_{t-1} y P_{t-1} , esta etapa de inicialización es importante debido a la recursividad del filtro ya que con estos valores se van realizando las estimaciones de la posición.

$$\hat{x}_0^+ = E(x_0) \quad (4.13)$$

$$\hat{P}_0^+ = E[(x_0 - \hat{x}_0^+)(x_0 - \hat{x}_0^+)^T] \quad (4.14)$$

Una vez que se inicializa el filtro en la etapa de predicción se calcula la proyección de la posición del sistema que se mueve desde un estado en $t - 1$ hasta la posición en el instante actual t , mediante la ecuación 4.15 y la predicción de la varianza 4.16.

$$\hat{x}_t^- = x_{t-1}^+ + v_{t-1} \quad (4.15)$$

$$P_t^- = P_{t-1}^+ + Q_{t-1} \quad (4.16)$$

Posteriormente en la etapa de actualización de la posición del estado y la covarianza estimada, utilizamos el conjunto de observaciones pertenecientes a cada sensor para cada instante de tiempo $t = 1, 2, \dots$, que fueron fusionadas en una única posición tal como se explicó en la sección 4.5 para la retroalimentación del filtro, de la siguiente manera:

$$\hat{x}_t^+ = \hat{x}_t^- + K_t[z_t - \hat{x}_t^-] \quad (4.17)$$

$$P_t^+ = (I - K_t)P_t^- \quad (4.18)$$

El factor que minimiza el error entre la medida estimada \hat{x}_t^- y la medida observada z_t , K_t es definida como la Ganancia de Kalman:

$$K_t = P_t^- (P_t^- + R_t)^{-1} \quad (4.19)$$

De acuerdo a [158] se asume que los ruidos del proceso Q y el ruido de la medición del sensor R son independientes entre sí, de tipo gaussiano con media cero y constantes para nuestro análisis de una dimensión, donde $R = \sigma_x^2$ es la varianza del ruido en la observación y $Q = \sigma_z^2$ es la varianza del error de estimación después de procesar la medición.

Las ecuaciones del Filtro de Kalman se aplican de manera recursiva para calcular la posición, mientras exista una medición proveniente de los sensores, a partir de estas ecuaciones podemos observar como en la etapa de predicción se calcula la posición en la que se encuentra el objeto en ese instante, después se corrige la posición para obtener un valor más preciso.

4.9. Filtro de Partículas (FP)

En esta sección describimos la implementación del Filtro de Partículas como otro método de estimación de la posición del modelo dinámico del sistema definido por las ecuaciones 4.11 y 4.12. Al igual que en el Filtro de Kalman, la estimación de la posición del sistema se basa en el modelo de movimiento del sistema que determina como el sistema cambia de posición en cada instante de tiempo x_t y en el modelo de observación z_t de las mediciones de los sensores con el objetivo de obtener en cada instante de tiempo t una estimación de la distribución de probabilidad de x denotada por $P(x_t|z_t)$.

El Filtro de Partículas es un método recursivo que utiliza como base la aproximación de Monte Carlo, para representar la función de densidad de probabilidad correspondiente a la posición del sistema en un instante de tiempo por un conjunto de N muestras denominadas partículas x_t^i , el número de partículas influye en la representación de la distribución ya que cada partícula es una muestra de la distribución (PDF) que estima un valor de posición, así a mayor número de partículas, mayor cantidad de muestras obtenidas para su representación.

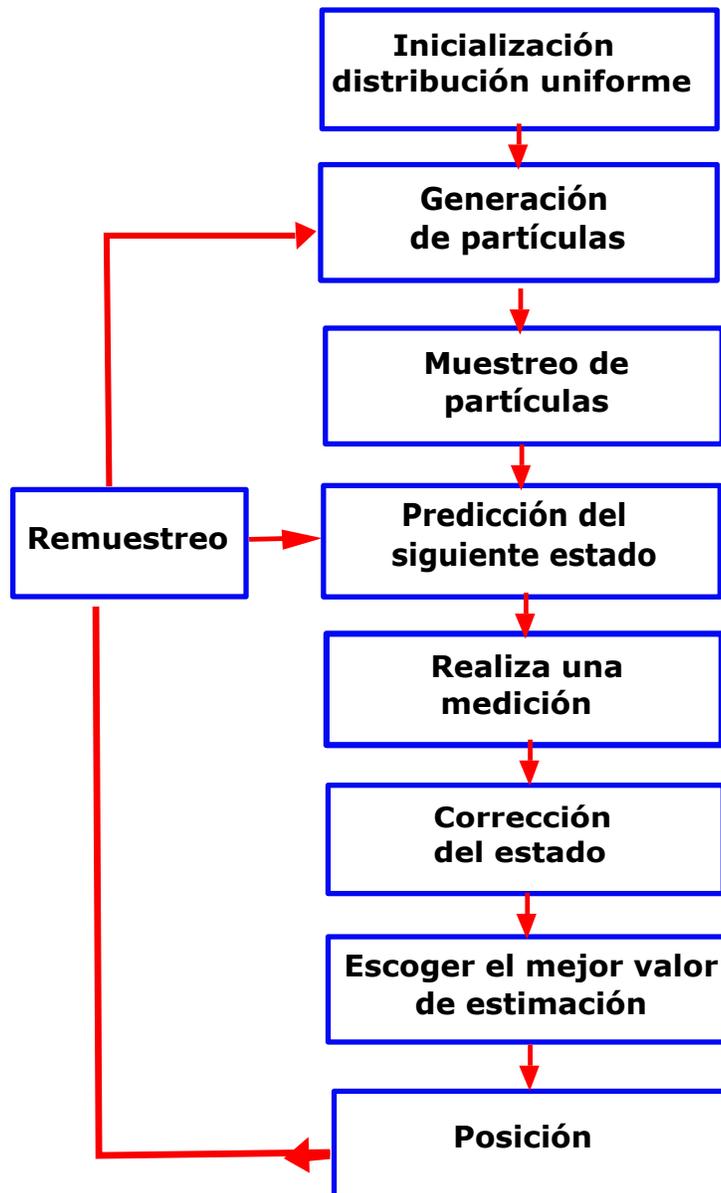


Figura 4.9: Diagrama de flujo del Filtro de Partículas

Inicialmente, se aproxima una distribución (PDF) que depende de los valores que nos proporcionan los sensores, se generan y distribuyen las partículas a partir de este valor, el conjunto de partículas generadas están asociadas a la probabilidad de estimar todas las posibles soluciones de posición en las que pueda estar el sistema de medición mientras se realiza una medición con los sensores. Cada probabilidad representa un peso asociado w_t^i a cada partícula, después para determinar el valor de posición del sistema se utilizan aquellas partículas con valores de probabilidad más alta (mayor peso) se espera que en cada actualización este conjunto de partículas sea capaz de estimar la distribución de probabilidad posterior mientras cambia de posición. En la Figura 4.10 se pueden ver la dinámica del filtro.

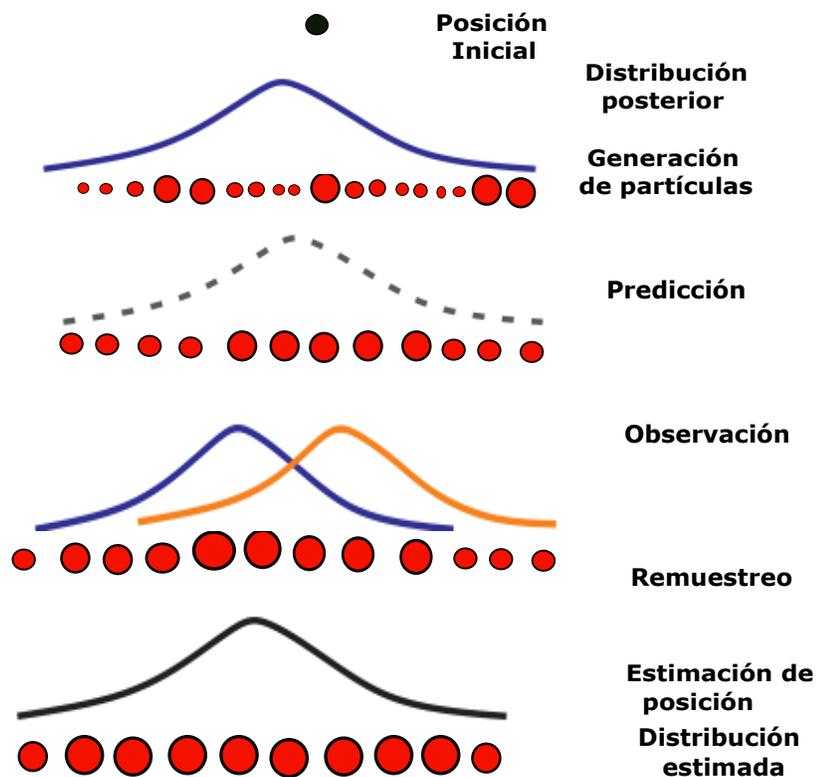


Figura 4.10: Etapas del Filtro de Partículas

Básicamente el Filtro de Partículas puede ser descrito de la siguiente manera:

- **Inicialización** se define una distribución $P(x_o)$ en un estado inicial x_0 , se crea un conjunto de N partículas en torno a un valor cercano a la posición inicial del sistema de medición, en este paso utilizamos como posición inicial la información de las mediciones que ofrecen los sensores, para generar la distribución $P(x_{t-1}|z_{t-1})$ en el instante $t - 1$.

- **Estimación** el sistema de medición se mueve a un estado posterior $P(x_t|x_{t-1})$ a través de la propagación del conjunto anterior de partículas, de partículas, de este modo se genera un nuevo conjunto de partículas que representa a la distribución posterior $P(x_t|z_{t-1})$.
- **Actualización de partículas** se realiza una nueva observación z_t por los sensores $P(z_t|x_t)$ en el instante actual t , se actualiza el peso de cada partícula a partir de la aproximación de la distribución $Q(x_t|x_{t-1}, z_t)$, asociada al modelo de movimiento y al modelo de observación y se obtiene un conjunto de partículas.
- **Remuestreo** Del conjunto de partículas obtenidas en el paso anterior, se realiza una selección de partículas basándose en los pesos de las partículas a cada peso se le asigna un valor de probabilidad, se eliminan las partículas con menor peso y se toma aquellas partículas que mayor peso tengan, esto hace que se trabaje con muestras de partículas cercanas al valor de la posición real aumentando la precisión.
- **Actualización del modelo** se actualiza el modelo de la posición del sistema $P(x_t|z_t)$ mediante la información obtenida en los pasos anteriores.

4.9.1. Filtro de Partículas aplicado al modelo del sistema

Las variables definidas para el Filtro de Partículas son:

X_t conjunto de partículas con sus pesos asociados

x_t^i modela el estado de cada partícula en el instante de tiempo t

x_{t-1}^i estado de anterior en el instante $t - 1$

w_t^i peso asociado a cada partícula

w_{t-1}^i modela el proceso del ruido

El cuadro 4.2 muestra el algoritmo del Filtro de Partículas

Algoritmo:Filtro de Partículas básico

Inicialización: $\rightarrow x_0, P(x_0)$
 $\bar{X}_t = X_t = 0$ **for** $i = 1..N$ muestreo : $\rightarrow x_t^i, P(x_t^i | x_{t-1}^i)$ Peso: $\rightarrow w_t^i = P(z_t | x_t^i)$ actualización de partículas: $\rightarrow \bar{X}_t = \bar{X}_t + (x_t^i, w_t^i)$ **for** $i = 1..N$ Extraer i con probabilidad w_t^i añadir x_t^i a X_t **actualiza** X_t

Cuadro 4.2: Algoritmo de Filtro de Partículas

Como primer paso, para desarrollar el filtro se tiene un conjunto de partículas y sus pesos para representar la distribución posterior:

$$X_t = \{x_t^i, w_t^i\}_{i=1, \dots, N} \quad (4.20)$$

X_t representa a las partículas i , cada partícula esta asociada a un peso normalizado $w_t = \{w_t^i/i\}$. De la información disponible de los sensores representamos el estado inicial x_{t-1}^i dado el conjunto de partículas X_{t-1}^i que caracterizan una PDF $P(x_{t-1} | z_{t-1})$ que representa la posición del sistema en un instante inicial.

Una vez inicializado el filtro, las partículas se propagan para aproximar la PDF posterior a partir de los valores en el instante $t - 1$. Entonces definimos a la representación del estado x_t^i para calcular el valor de posición en cada instante de tiempo mediante la ecuación 4.7:

$$x_t^i = x_{t-1}^i + w_{t-1}^i \quad (4.21)$$

La información para la actualización del estado x_t^i es obtenida a través de mediciones ruidosas proveniente de los sensores z_t , mediante el modelo de observación definido en la ecuación 4.8 cada valor de estado x_t^i representa la probabilidad (PDF) del valor de la posición

que caracterizan la distribución de probabilidad de transición de estados $P(x_t|x_{t-1})$. Dada la probabilidad del cambio de posición del tiempo $t - 1$ a t , obtenemos un nuevo conjunto de N partículas:

$$X_{t|t-1} = \{x_{t|t-1}^i, w_{t|t-1}^i\}_{i=1,\dots,N} \quad (4.22)$$

Donde $X_{t|t-1}$ es el nuevo conjunto de partículas, $x_{t|t-1}^i$ representa el estado de cada partícula y $w_{t|t-1}^i$ el peso de las partículas. Este conjunto de muestras representan la predicción del estado sin considerar la observación. Para tomar en cuenta la observación $P(z_t|x_t)$ realizada en un estado $P(x_t|x_{t-1})$, se obtiene el peso asociado a cada partícula.

$$w(x_t) = w(x_{t-1}) \frac{P(z_t|x_t) * P(x_t|x_{t-1})}{Q(x_t|(x_{t-1}, z_t))} \quad (4.23)$$

En el último paso se realiza la selección de N partículas del conjunto $X_{t|t-1}$, basándose en los pesos de las partículas a cada peso se le asigna un valor de probabilidad, se eliminan las partículas con menor peso y se toma aquellas partículas que mayor peso tengan, esto hace que se trabaje con muestras de partículas cercanas al valor de la posición real. A través de las partículas elegidas se obtiene un nuevo conjunto de partículas:

$$X_t = \{x_t^i, w_t^i\}_{i=1,\dots,N} \quad (4.24)$$

Este nuevo conjunto de partículas X_t , calcula la estimación final de la posición del estado representada por una probabilidad posterior $P(x_t|y_t)$ en el instante de tiempo actual t . Los resultados de esta estimación se utilizan recursivamente como entrada en la ejecución del filtro.

$$x_t^i = x_{t-1}^i + w_{t-1}^i \quad (4.25)$$

Capítulo 5

Resultados Experimentales

En este capítulo se presentan los datos obtenidos del sistema de posicionamiento implementado y los resultados obtenidos con la aplicación de los algoritmos explicados en las secciones anteriores, finalmente se exponen las conclusiones de los resultados.

5.1. Adquisición de datos

Para definir el posicionamiento milimétrico de los sensores, definimos una distancia de referencia utilizando una plataforma de desplazamiento lineal modelo LSDP-JG100 programada a través de un controlador LSKZA-04 (ver anexo A). La plataforma está compuesta por una superficie deslizable controlada por dos motores a pasos de 1.8° colocados en el plano eje XY que desplazan la plataforma en dirección del eje z, dicha plataforma tiene un rango mínimo de desplazamiento de 4mm. El objetivo de utilizar la plataforma de desplazamiento lineal es definir el desplazamiento de los sensores de posicionamiento en una sola dirección sobre el eje z, de esta manera asumimos que los desplazamientos en los ejes XY existen en menor proporción. Los datos de posición se adquirieron con un tiempo de muestreo constante de 500 ms, los valores de los parámetros del posicionamiento de la plataforma lineal se determinan primero por utilizando la ecuación A.2 descrita en el anexo A.

Durante la experimentación los sensores se alinean de manera paralela referenciados al mismo sistema de coordenadas de la plataforma lineal, los sensores se ajustan con respecto al valor de medición de la posición de la plataforma lineal (escala), las posiciones medidas por los sensores son comparadas con las posiciones de la plataforma, la diferencia entre ambos valores de posición son corregidos durante el proceso de medición mediante un ajuste de prueba y error, esta corrección es importante para el desempeño del sistema de medición, ya que sin este procedimiento no se podrían realizar correctamente las mediciones.

El sistema de posicionamiento está equipado con tres sensores de desplazamiento, el sensor óptico, odómetro y magnético cuyo objetivo es estimar las diferentes posiciones en las que se va localizando el sistema mientras este se va moviendo. Después de realizar la corrección de las posiciones con la plataforma lineal, se procedió a realizar diferentes mediciones de manera independiente, en cada posición tomamos tres lecturas de medición en las mismas condiciones para obtener un conjunto de datos de $n=1, \dots, 15$, producidos por cada sensor. Al tener las mediciones de posición por parte de los sensores y trabajar con una medición más fiable se obtuvieron los promedios de las mediciones.

La Tabla 5.1 muestra el valor promedio de las 3 repeticiones de las mediciones tomadas, estos datos son la base para de los parámetros para modelizar el sistema de posicionamiento.

Cuadro 5.1: Datos obtenidos con los sensores (mm)

Distancia de referencia	Distancia S. óptico	Distancia S. magnético	Distancia S. odómetro
0	0	0	0
10	11.10	12.2	12.61
20	20.84	19.5	22.37
30	31.21	28.2	31.18
40	41.57	37.5	41.44
50	52.36	48.6	52.05
60	62.98	58.22	61.21
70	73.53	69.51	72.66
80	84.07	79.64	83.24
90	94.33	90.41	94.81
100	106.25	98.19	101.3
110	116.55	108.19	112.76
120	126.87	119.28	123.69
130	137.46	128.39	132.10
140	147.38	139.74	144.14

A partir de los datos registrados en la Tabla 5.1 es posible construir un gráfico, en la Figura 5.1 se muestra la obtención del valor promedio de las mediciones de los sensores (eje y) en comparación con los valores de posición en la que se encuentra el sensor en ese instante (eje x), se observa que la estimación de los valores de posición obtenidos por los sensores corresponden a la posición de referencia, también observamos que la respuesta dinámica del sistema sigue un comportamiento lineal.

Como podemos observar las mediciones obtenidas son datos con incertidumbres, a partir de los datos obtenidos se estima el error de estas mediciones. La Figura 5.2 corresponde al cálculo de la desviación estándar que describe la tendencia de la incertidumbre de los datos entre las distintas mediciones realizadas para una misma posición del sistema. Podemos observar que las incertidumbres de los datos crecen dentro de un intervalo de 0.1 a 3 mm desde las posiciones de 50 mm a 110 mm.

Puede observarse que los valores de la posición estimados con el sensor magnético presentan un error de 0.1 mm en el intervalo de 20 a 50 mm, en cuanto a los valores de las estimaciones que realiza el sensor odométrico se observa que muestran un error sistemático de 3 mm entre el intervalo de posiciones de 50 a 100 mm este sensor es el más inestable debido a que depende de la forma en la que gira el encoder que es jalado por el cordel retráctil.

Por lo tanto es más probable que vaya acumulando errores en cada posición a medida que se va moviendo, en comparación con el sensor óptico que presenta un error de 0.1 mm a partir del intervalo de posición de los 110 mm esto nos muestra que entre más alejado este la cámara del objeto el error crece debido a que el campo de visión de la cámara y la distancia focal que comprende el punto más lejano en la imagen es mayor, por lo tanto la nitidez de la imagen se reduce.

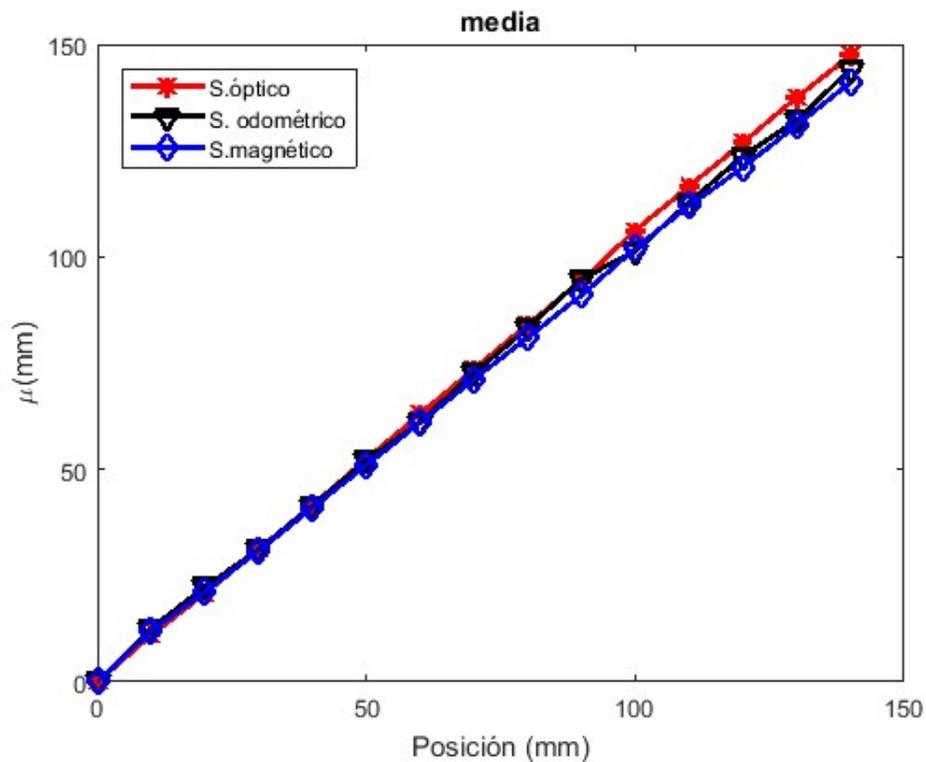


Figura 5.1: Posición del sistema de medición para cada sensor

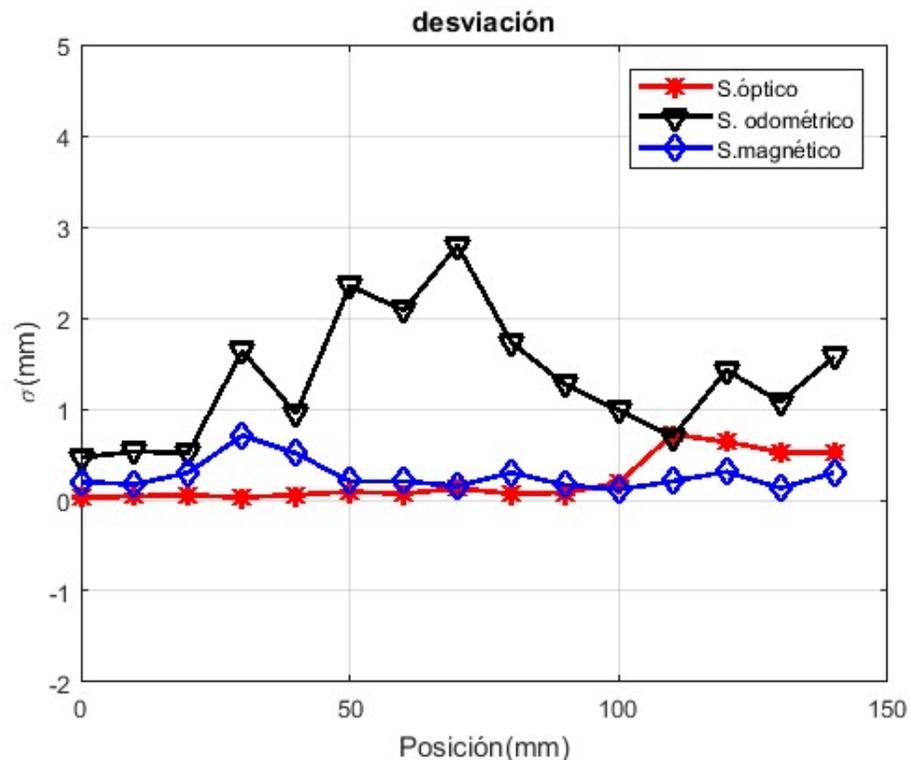


Figura 5.2: Desviación estándar σ de los sensores a diferentes posiciones

Resulta conveniente obtener el comportamiento de los sensores, con los resultados de los parámetros μ y σ se tiene una idea de la tendencia de la variabilidad de las mediciones de los sensores, esperamos que los sensores con menor variabilidad influyan en la estimación final de la posición. Esto es importante ya que a partir de esta información implementaremos el modelo matemático del sistema y así evaluar el error que cada sensor está introduciendo en la medición de la posición.

5.2. Modelo de la medición

A partir de los datos obtenidos se procede a realizar la caracterización del comportamiento de datos mediante métodos probabilísticos. Podemos aproximar los datos a la forma de una distribución normal gaussiana (PDF) empleando los parámetros de la media y de la desviación estándar. La representación de los sensores mediante distribuciones de probabilidad PDF modela el ruido de las mediciones y determina el valor de posición sobre la que se posiciona el sistema a través del tiempo, donde el valor más acertado de posición está centrado en el

valor más alto de la distribución con una dispersión en proporción del error de esta posición.

En la Figura 5.3 se muestran las distribuciones PDF de cada sensor en función de la posición del sistema, la $PDF_1(x)$ en color rojo representa al sensor óptico, la $PDF_2(x)$ en color verde corresponde al sensor odométrico y la $PDF_3(x)$ en azul al sensor magnético.

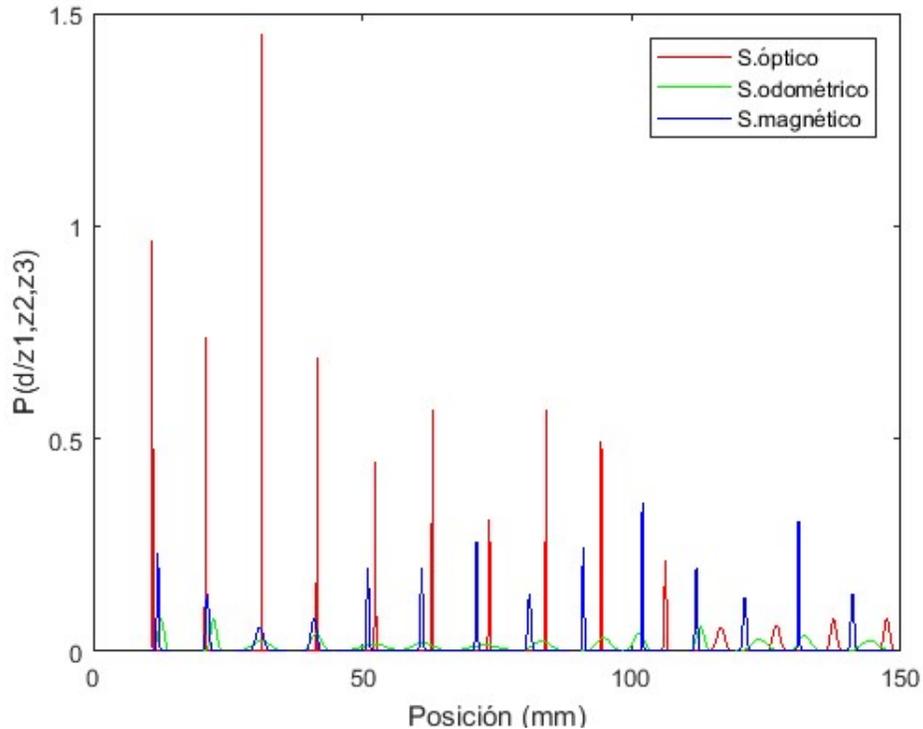


Figura 5.3: Función de probabilidad de los sensores a diferentes posiciones

5.3. Fusión de datos

Nuestra estrategia está enfocada en utilizar un sistema de posicionamiento equipado con tres sensores diferentes con la idea de que cada sensor genere una compensación sobre los valores de las posiciones y sus incertidumbres y de esta manera se pueda tener una mejor estimación de la posición que se está midiendo. Se usó la fusión de datos para combinar las distribuciones que modelan cada sensor mediante el producto de las distribuciones (PDF) individuales de cada uno de los sensores. El resultado de la combinación de las distribuciones se muestra en la Figura 5.4.

Después de fusionar las distribuciones obtenemos como resultado otra distribución denominada distribución conjunta asociada a un conjunto de datos, que representa los valores de posición con cierta compensación podemos observar que las distribuciones resultantes muestran menor dispersión de los datos. El tener una distribución mas estrecha representa que la incertidumbre en los datos se reduce, lo que puede interpretarse con obtener un valor de posición menos incierto. Con estas distribuciones es necesario implementar algoritmos que involucren la fusión de los datos como una solución para obtener la estimación de la posición en cada instante.

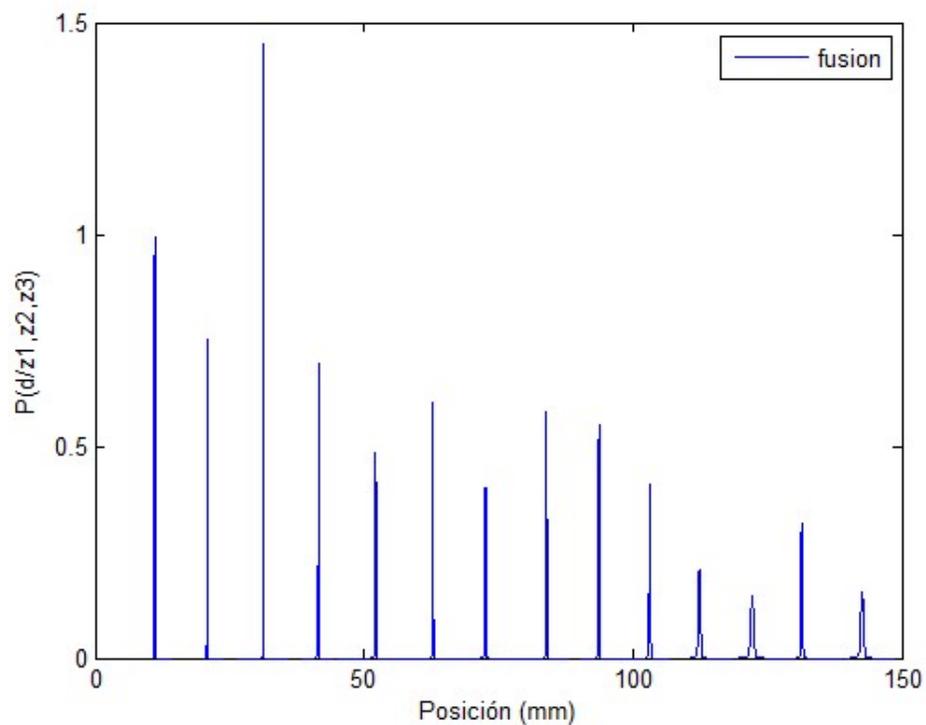


Figura 5.4: Fusión de sensores

En la Tabla 5.2 se recopilan los resultados de la fusión de los datos.

Cuadro 5.2: Datos obtenidos de la mezcla de distribuciones (mm)

Posición de referencia (mm)	Mezcla de Gaussianas (mm)	Incertidumbre (mm)
0	0	0
10	11.072	0.8
20	20.87	0.7
30	31.215	0.9
40	41.565	1.2
50	52.148	1.7
60	62.774	2.2
70	72.582	2.1
80	83.915	3.1
90	93.688	3.0
100	103.133	2.5
110	112.371	1.9
120	122.181	1.7
130	131.388	1.1
140	142.619	2.1

5.4. Filtro de Kalman

En el capítulo anterior en la sección 4.8 se ha descrito la metodología a seguir para el modelo lineal del sistema, para iniciar la estimación de estados a través del Filtro de Kalman es necesario definir un valor inicial de x_{t-1} cuyo valor es 10 mm, además de calcular el valor a las varianzas Q y R de los errores de estimación de estado y de observación, los valores de estas varianzas son $Q=0.176$ y $R=0.1$, calculados al igual que en el trabajo de [158]. A continuación, el Filtro de Kalman utiliza los parámetros definidos en cada posición considerando las mediciones fusionadas de los sensores para la actualización del estado. En la Figura 5.5, observamos que el movimiento del sistema viene dada por una trayectoria lineal.

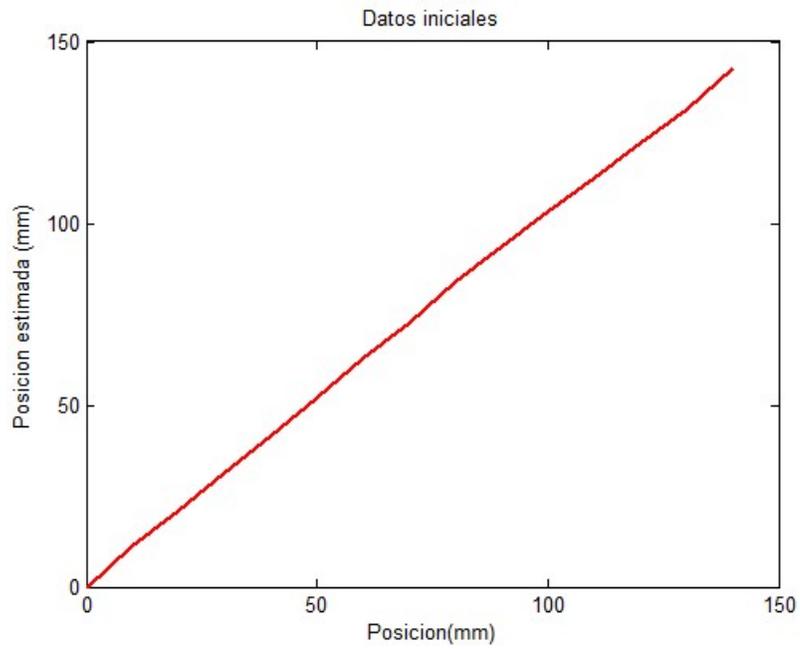


Figura 5.5: Resultados Filtro de Kalman

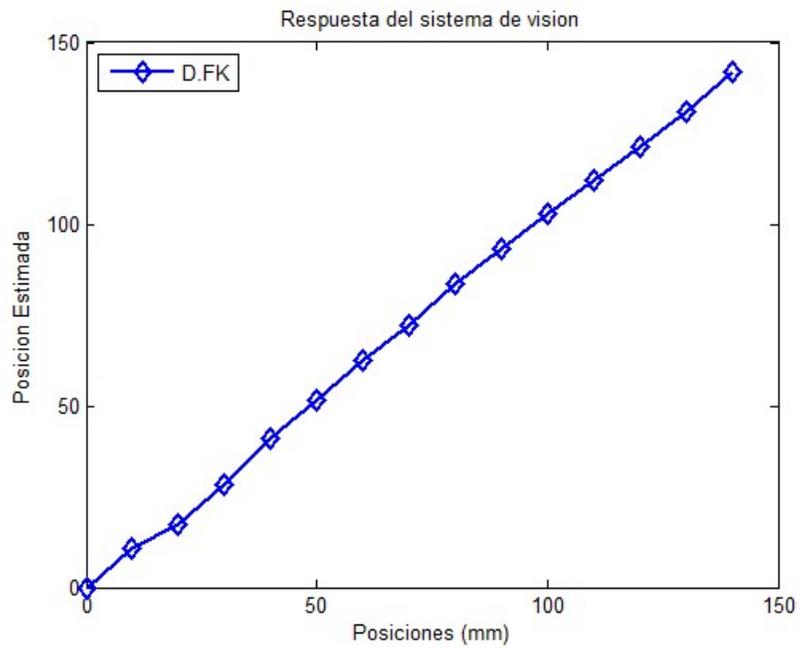


Figura 5.6: Estimación de estados Filtro de Kalman

En la Figura 5.6 se observan los valores de posición del estado estimado correspondientes

a las 15 posiciones sobre las que se mueve el sistema, también se puede observar que las estimaciones del filtro en el rango de 0 a 20 mm muestran una variación en los datos de posición, esto por que el filtro tarda en realizar la estimación del estado, debido a que el sistema permanece en la misma posición hasta que recibe una medición, corrige la estimación de la posición y por último realiza la actualización del estado, pero conforme el filtro recibe información de las mediciones de los sensores, el filtro logra la estimación de las posiciones muy similares a las posiciones reales.

En la Figura 5.7 se muestra la comparación de los resultados del trayecto real (rojo) con la trayectoria estimada (azul) con el Filtro de Kalman. Los resultados muestran que la estimación de la posición se realiza de manera correcta debido a que ambos valores son bastante cercanos a los reales, lo que significa que se logra estimar el lugar donde esta posicionado el sistema en un instante de tiempo.

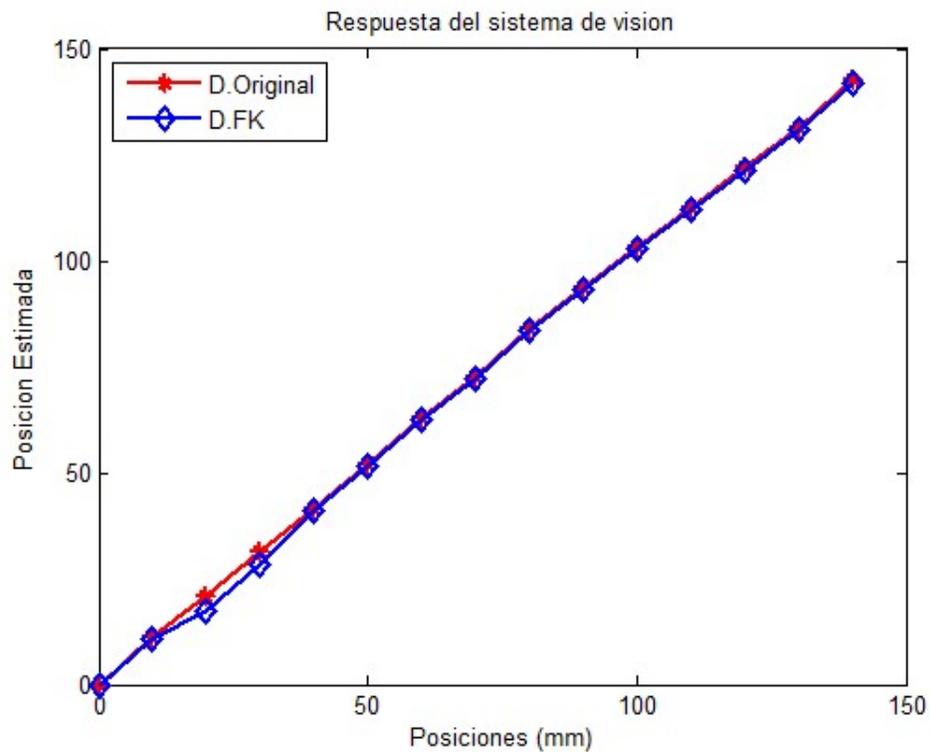


Figura 5.7: Comparación de la Estimación de estados con el valor real

En la Tabla 5.3 se muestran los valores de estimación de la posición, el filtro corrige la estimación en la posición, se observa que con el filtro hay posiciones en las que el error aumenta, esto refleja el comportamiento del sistema.

Cuadro 5.3: Datos obtenidos de todas las estimaciones (mm)

Posición de referencia	Filtro de Kalman	Incertidumbre
0	0	0
10	10.881	0.7
20	17.521	2.0
30	28.324	1.3
40	41.119	0.9
50	51.555	1.2
60	62.508	2.0
70	72.363	1.9
80	83.677	3.0
90	93.401	2.7
100	102.634	2.1
110	112.03	1.6
120	121.251	1.0
130	130.786	0.6
140	141.854	1.5

5.5. Filtro de Partículas

La implementación del Filtro de Partículas a partir del modelo descrito en la sección 4.9 del Capítulo 4. Inicialmente parte de un conjunto de 100 partículas generadas a partir de una distribución PDF situada en la posición inicial del sistema y conforme se realizan las transiciones del conjunto de partículas según el algoritmo general del filtro de la Figura 4.9, se estima una distribución asociada a una posición y a sus propios valores de error.

En la Figura 5.8 se puede ver la estimación de la posición que realiza el Filtro de Partículas en cada iteración y la comparación de la posición real, puede comprobarse que aunque el filtro estima la posición en base a varias muestras cercanas al valor de la media la respuesta del filtro es similar al del Filtro de Kalman.

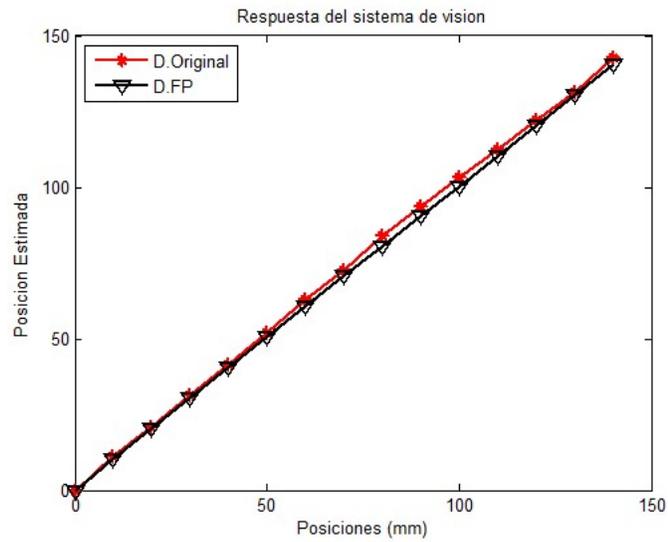


Figura 5.8: Estimación de estados Filtro de Partículas

Cuadro 5.4: Datos estimados con el Filtro de Partículas (mm)

Posición de referencia	Filtro de Partículas	Incertidumbre
0	0	0
10	10.481	0.3
20	21.131	0.9
30	30.796	0.6
40	40.41	0.3
50	50.903	0.7
60	61.989	1.6
70	69.76	0.1
80	80.884	0.7
90	92.349	1.9
100	99.963	0.3
110	111.415	1.1
120	119.466	0.4
130	130.326	0.2
140	141.056	0.8

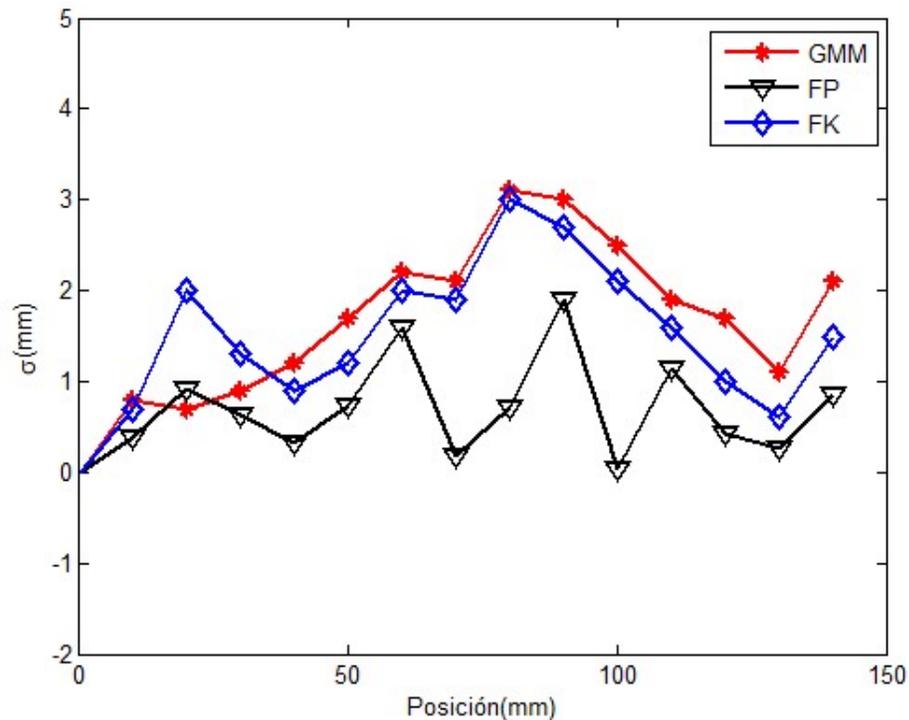


Figura 5.9: Desviaciones de la Mezcla de Gaussianas (GMM), del Filtro de Kalman (FK) y del Filtro de Partículas (FP)

En la Figura 5.9 se presenta la evolución del error para los tres algoritmos implementados. Con los resultados podemos notar como se tiene un valor de error constante, también podemos inferir que bajo las implementaciones del sistema ya no es posible disminuir más el error, debido a que siempre habrá variables como la alineación de los sensores, pérdidas de algunos valores durante las mediciones, fallas en el funcionamiento de los sensores, errores de posicionamiento que añaden ruido al sistema.

5.6. Comparación de los filtros

De las simulaciones de los filtros anteriormente presentados, realizamos una comparativa de las simulaciones con el objetivo de destacar las semejanzas entre las respuesta obtenidas por los filtros. Dado que los resultados de ambos filtros se centran en la estimación del posicionamiento del sistema y se compararon con los datos reales. Se observa que ambos filtros dan resultados muy similares y se comprueba que ambos filtros son una buena alternativa para la estimación de estados de un sistema dinámico lineal.

Los valores promedios de los errores son calculados y presentados en la Tabla 5.5 se muestran los resultados del error obtenido con cada uno de los algoritmos implementados, Filtro de Partículas y Filtro de Kalman. Los resultados muestran que el Filtro de Partículas es el algoritmo obtiene mejores resultados que el Filtro de Kalman, aunque los resultados de ambos filtros presentan impresiones, la desviación estándar es menor en el algoritmo del Filtro de Partículas lo que indica que los resultados son más estables con este método, manteniéndose localizado el sistema de posicionamiento a lo largo de todo el recorrido del sistema.

Cuadro 5.5: Incertidumbres obtenidas de estimaciones de posición discretas (mm)

Incertidumbre	Mezcla de Gaussianas (mm)	Filtro de Kalman (mm)	Filtro de Partículas (mm)
	1.8	1.64	0.73

Por otra parte, entre las ventajas del Filtro de Kalman es que ante la presencia de cambios en el movimiento del sistema el filtro logra estabilizarse y continua calculando las estimaciones de posición, mientras que la desventaja del Filtro de Partículas es que necesita realizar un remuestreo para conseguir buenos resultados. Estos aspectos son importantes a considerar para una implementación objetiva de los métodos y decidir entre ambos filtros cual mejora los resultados.

En este trabajo presentamos un sistema de posicionamiento de visión activa para el escaneo 3D del interior de piezas, para demostrar el desempeño del sistema de posicionamiento, se utilizó un conjunto de datos tridimensionales que conforman la reconstrucción métrica del perfil de un cilindro obtenida a partir de un sistema de visión activo obtenidos por [1] (azul) y el perfil del cilindro utilizando los datos obtenidos por el sistema de posicionamiento (rojo) desarrollado en este trabajo.

La Figura 5.10 representa el escaneo 3D del interior del cilindro, de acuerdo a la Tabla 5.1 y la gráfica 5.2 el sistema de posicionamiento utiliza un cámara endoscópica para capturar imágenes, capaz de realizar una medición a una profundidad de 150 mm con una precisión de 0.1 mm.

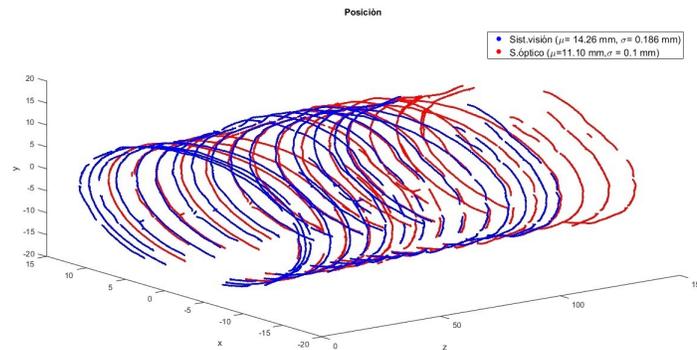


Figura 5.10: Estimación de las posiciones de los perfiles del cilindro con la cámara. Datos obtenidos por el sistema de visión activo (azul) y datos obtenidos por el sistema de posicionamiento (rojo).

La Figura 5.11 representa el escaneo 3D del interior del cilindro, el sensor magnético tiene una precisión de 0.1 mm.

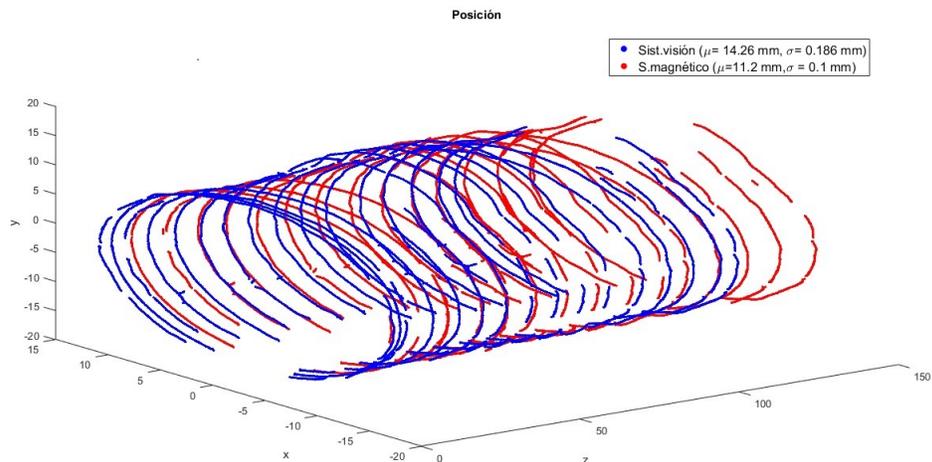


Figura 5.11: Estimación de las posiciones de los perfiles con la escala magnética. Datos obtenidos por el sistema de visión activo (azul) y datos obtenidos por el sistema de posicionamiento (rojo).

El escaneo 3D con el odómetro se presenta en la Figura 5.12. El odómetro con una precisión de medición de 3 mm, y presenta errores de medición en el intervalo de 50 mm y 100 mm de profundidad.

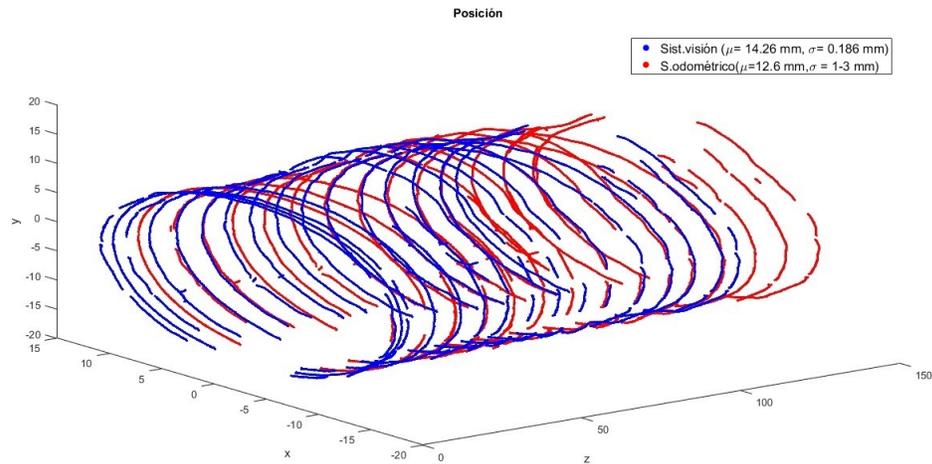


Figura 5.12: Estimación de las posiciones de los perfiles del cilindro con el odómetro. Datos obtenidos por el sistema de visión activo (azul) y datos obtenidos por el sistema de posicionamiento (rojo).

Al comparar los resultados con ambos sistemas, en la Figura 5.13 se muestra cálculo de la posición en cada perfil del cilindro con ambos sistemas, se puede observar que se realiza una mejora al corregir el posicionamiento del sistema en cada intervalo de medición, en base a los resultados mostramos podemos confirmar que se obtienen mejores resultados en la reconstrucción ya que esta depende en gran medida del posicionamiento del sistema, además será posible conocer la forma y dimensiones del interior del objeto con una precisión milimétrica, el sistema propuesto permitirá generar el modelo tridimensional del objeto bajo inspección. La mejora del modelamiento tridimensional de la pieza esta dada principalmente por el ajuste de los datos de posicionamiento mediante la implementación de los Filtros de Kalman y Partículas de acuerdo a los resultados de precisión mostrados en la tabla 5.5 respectivamente logrando de esta forma obtener resultados que permiten mejorar la medición de la posición del sistema.

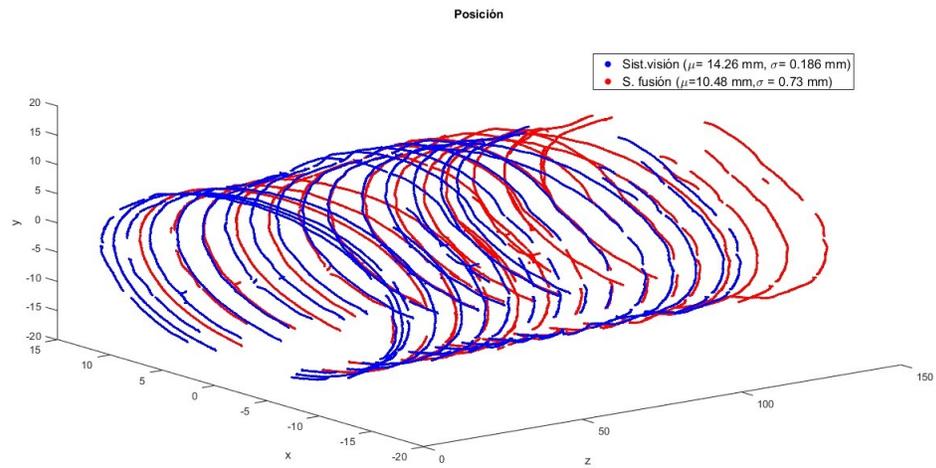


Figura 5.13: Comparación de las posiciones de los perfiles del cilindro con ambos sistemas. Datos obtenidos por el sistema de visión activo (azul) y datos obtenidos por el sistema de posicionamiento (rojo).

Conclusiones y Trabajo Futuro

Conclusiones

En este trabajo se ha presentado un sistema capaz de determinar el posicionamiento en el interior de un objeto, se han descrito de manera general los sensores que componen el sistema (sección 3.2). El objetivo ha sido el implementar un sistema de posicionamiento basado en el análisis de imágenes y que es complementado con sensores de desplazamiento lineal con la idea de realizar la combinación de los resultados obtenidos por cada sensor tal como se explicó en la sección 4.4, de lo cual se concluye que:

- El acoplamiento de los sensores debe estar bien alineado para definir la posición inicial sobre la que se comenzará a realizar las mediciones.
- El alcance de medición del sensor depende del sistema de visión.
- La incertidumbre asociada a las mediciones puede ser reducida con la integración de diferentes fuentes de medición.
- Las características que ofrece cada sensor compensan los errores en la medición.
- En este trabajo se ha desarrollado un sistema basado en medidas de sensores que permiten determinar su posición mediante modelos conocidos .
- Se ha demostrado que los sensores son complementarios para poder estimar los parámetros estadísticos que son de interés para modelar el comportamiento del sistema.
- El sistema de posicionamiento es modelado mediante distribuciones de probabilidad, dichas distribuciones representan al valor de posición asociado a una incertidumbre.
- La asociación de datos se realiza mediante la mezcla de distribuciones, esto nos da una compensación de las mediciones y obtenemos una medición con mayor precisión.

Esta tesis se ha centrado en dar solución al problema de la estimación de la posición, desarrollando un sistema de posicionamiento que se mueve a lo largo de una trayectoria. Para ello se propuso implementar algoritmos basados en la representación del comportamiento del sistema de posicionamiento empleando un modelo de estado y un modelo de observación para tener un conocimiento de donde está posicionado el sistema y dar una solución al problema. Los algoritmos empleados para este propósito fueron el Filtro de Kalman y el Filtro de Partículas con la implementación de los filtros se concluye:

- La implementación correcta del modelo de sistema es esencial para realizar las estimaciones del posicionamiento.
- Es necesario definir correctamente los parámetros iniciales de estimación de estado y varianzas de los filtros.
- Se puede conocer los valores de posición estimados a través del tiempo.
- La estimación de estados está relacionado con el valor de posición en el instante actual.
- La actualización del estado se realiza mientras exista una medición proporcionada por los sensores.
- Si no se realiza ninguna medición solo se propaga la transición del estado.
- La implementación del Filtro de Kalman dentro de la metodología propuesta tiene la función de trabajar como estimador de posición, a medida que se mueve el sistema, mientras que reduce las incertidumbres asociadas a la posición con respecto a la posición inicial.
- Para resolver un problema de estimación de posición se aplican los Filtros de Kalman y Partículas y se calculan los parámetros de estimación de estado sobre un sistema lineal que se mueve.
- La respuesta del Filtro de Partículas depende del número de partículas empleadas, si la cantidad de partículas es muy pequeña puede ser calculadas estimaciones de posición incorrectas.
- Se pudo comprobar que con el Filtro de Partículas se obtuvieron mejoras en cuanto a la precisión de los resultados de estimación de la posición observándose en la disminución de la varianza de los datos.

- Los resultados obtenidos muestran que el Filtro de Kalman y el Filtro de Partículas son buenos estimadores de estado, sin embargo el Filtro de Partículas es más estable, esto se debe a que al momento de propagar las partículas el filtro considera nuevas mediciones.
- La elección del filtro a utilizar dependerá de la aplicación en la que se quiera utilizar. Se comprueba que los métodos aquí implementados proporcionan una solución bastante aceptable.

Trabajo Futuro

La estimación de la posición de un sistema que se va moviendo a lo largo de una trayectoria, es importante cuando se requiere conocer con gran precisión la posición. En la práctica podemos ver que diferentes factores influyen en los resultados de la estimación. Por ello, siempre surgen mejoras que pueden plantearse como opción para trabajos futuros del trabajo planteado en esta tesis pueden quedar abiertos los siguientes aspectos:

- Es necesario mejorar el proceso de acoplamiento y sincronización de la toma de mediciones entre los diferentes sensores utilizados.
- Analizar el comportamiento del sensor con cambios de trayectorias.
- Queda pendiente la realización de nuevos algoritmos que puedan ser implementados para mejorar la estimación de los valores de posición, mediante la adicción de variables que estén involucradas con el movimiento del sistema como rotaciones, traslaciones en los ejes (x,y).
- Se puede realizar la estimación de la posición agregando marcas dentro de la trayectoria del sistema que sirvan como referencia al posicionamiento del sistema.
- Realizar una adaptación del sistema de posicionamiento para considerar el medir a distancias más grandes.
- Es necesario señalar que los algoritmos implementados no realizan la estimación del posicionamiento del sistema en tiempo real, teniendo en cuenta esto sería bueno el poder implementar un algoritmo sincronizado con la corrección y actualización de las mediciones.

Bibliografía

- [1] O. Icasio-Hernández, J.-J. Gonzalez-Barbosa, J. B. Hurtado-Ramos, and M. Viliesid-Alonso, “3d reconstruction of hollow parts analyzing images acquired by a fiberscope,” *Measurement Science and Technology*, vol. 25, no. 7, p. 075402, 2014.
- [2] J. Santolaria, D. Guillomía, C. Cajal, J. A. Albajez, and J. J. Aguilar, “Modelling and calibration technique of laser triangulation sensors for integration in robot arms and articulated arm coordinate measuring machines,” *Sensors*, vol. 9, no. 9, pp. 7374–7396, 2009.
- [3] C. Rossi and S. Savino, “A robotic system to scan and reproduce object,” *Journal of Robotics*, vol. 2011, 2011.
- [4] T. Borangiu and A. Dumitrache, “Robot arms with 3d vision capabilities,” in *Advances in Robot Manipulators*, InTech, 2010.
- [5] J. Xu, N. Xi, C. Zhang, Q. Shi, and J. Gregory, “Real-time 3d shape inspection system of automotive parts based on structured light pattern,” *Optics & Laser Technology*, vol. 43, no. 1, pp. 1–8, 2011.
- [6] A. Albertazzi, A. C. Hofmann, A. V. Fantin, and J. M. Santos, “An endoscopic optical system for inner cylindrical measurement using fringe projection,” in *Ninth International Symposium on Laser Metrology*, vol. 7155, p. 715514, International Society for Optics and Photonics, 2008.
- [7] W. Liu, Z. Jia, F. Wang, X. Ma, W. Wang, X. Jia, and D. Song, “An improved online dimensional measurement method of large hot cylindrical forging,” *Measurement*, vol. 45, no. 8, pp. 2041–2051, 2012.
- [8] D. Kosmopoulos and T. Varvarigou, “Automated inspection of gaps on the automobile

- production line through stereo vision and specular reflection,” *Computers in Industry*, vol. 46, no. 1, pp. 49–63, 2001.
- [9] H. Kosler, U. Pavlovčič, M. Jezeršek, and J. Možina, “Adaptive robotic deburring of die-cast parts with position and orientation measurements using a 3d laser-triangulation sensor,” *Strojniški vestnik-Journal of Mechanical Engineering*, vol. 62, no. 4, pp. 207–212, 2016.
- [10] M. Yokota, T. Koyama, and K. Takeda, “Digital holographic inspection system for the inner surface of a straight pipe,” *Optics and Lasers in Engineering*, vol. 97, pp. 62–70, 2017.
- [11] T. Yoshizawa and T. Wakayama, “Development of an inner profile measurement instrument using a ring beam device,” in *Optical Metrology and Inspection for Industrial Applications*, vol. 7855, p. 78550B, International Society for Optics and Photonics, 2010.
- [12] H. M. Park and K.-N. Joo, “Endoscopic precise 3d surface profiler based on continuously scanning structured illumination microscopy,” *Current Optics and Photonics*, vol. 2, no. 2, pp. 172–178, 2018.
- [13] L. A. Kahrs, G. S. Blachon, R. Balachandran, J. M. Fitzpatrick, and R. F. Labadie, “Measurement of distances between anatomical structures using a translating stage with mounted endoscope,” in *Medical Imaging 2012: Image-Guided Procedures, Robotic Interventions, and Modeling*, vol. 8316, p. 83160X, International Society for Optics and Photonics, 2012.
- [14] C. Schmalz, F. Forster, A. Schick, and E. Angelopoulou, “An endoscopic 3d scanner based on structured light,” *Medical image analysis*, vol. 16, no. 5, pp. 1063–1072, 2012.
- [15] M. Chan, W. Lin, C. Zhou, and J. Y. Qu, “Miniaturized three-dimensional endoscopic imaging system based on active stereovision,” *Applied optics*, vol. 42, no. 10, pp. 1888–1898, 2003.
- [16] O. Tonet, R. U. Thoranaghatte, G. Megali, and P. Dario, “Tracking endoscopic instruments without a localizer: a shape-analysis-based approach,” *Computer Aided Surgery*, vol. 12, no. 1, pp. 35–42, 2007.

- [17] T. Wu, S. Lu, and Y. Tang, “An in-pipe internal defects inspection system based on the active stereo omnidirectional vision sensor,” in *Fuzzy Systems and Knowledge Discovery (FSKD), 2015 12th International Conference on*, pp. 2637–2641, IEEE, 2015.
- [18] Z. Király, G. S. Springer, and J. Van Dam, “Stereoscopic vision system,” *optical Engineering*, vol. 45, no. 4, p. 043006, 2006.
- [19] A. Sophian, W. Sediono, M. R. Salahudin, M. S. M. Shamsuli, and D. Q. A. Zaaba, “Evaluation of 3d distance measurement accuracy of stereo vision systems,” *International Journal of Applied Engineering Research*, vol. 12, no. 16, pp. 5946–5951, 2017.
- [20] H. Aoki, R. Furukawa, M. Aoyama, S. Hiura, N. Asada, R. Sagawa, H. Kawasaki, S. Tanaka, S. Yoshida, and Y. Sanomura, “Proposal on 3-d endoscope by using grid-based active stereo,” in *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE*, pp. 5694–5697, IEEE, 2013.
- [21] T. Koishi, M. Sasaki, T. Nakaguchi, N. Tsumura, and Y. Miyake, “Endoscopy system for length measurement by manual pointing with an electromagnetic tracking sensor,” *Optical review*, vol. 17, no. 2, pp. 54–60, 2010.
- [22] K. Höller, A. Schneider, J. Gutierrez, Wittenberg, J. Hornegger, and H. Feussner, “Enhanced endoscopic engineering,” *Pattern Recognition in Medical and Health Engineering*, p. 61, 2008.
- [23] H.-C. Lee, C.-W. Jung, and H. C. Kim, “Real-time endoscopic image orientation correction system using an accelerometer and gyrosensor,” *PloS one*, vol. 12, no. 11, p. e0186691, 2017.
- [24] C. Du, X. Chen, Y. Wang, J. Li, and D. Yu, “An adaptive 6-dof tracking method by hybrid sensing for ultrasonic endoscopes,” *Sensors*, vol. 14, no. 6, pp. 9961–9983, 2014.
- [25] T. Kulatunga, R. Ranasinghe, R. Ranathunga, R. Ratnayake, and N. D. Nanayakkara, “Real time endoscope trajectory tracking in the 3d space using mems sensors,” in *Industrial and Information Systems (ICIIS), 2013 8th IEEE International Conference on*, pp. 605–609, IEEE, 2013.
- [26] D. Zheng, H. Tan, and F. Zhou, “A design of endoscopic imaging system for hyper long pipeline based on wheeled pipe robot,” in *AIP Conference Proceedings*, vol. 1820, p. 060001, AIP Publishing, 2017.

- [27] W. Ying and Z. Rui, "In-pipe surface circular structured light 3d vision inspection system," *Infrared and Laser Engineering*, vol. 43, no. 3, pp. 891–896, 2014.
- [28] G. Biegelbauer and M. Vincze, "3D Vision-Guided Bore Inspection System," in *Fourth IEEE International Conference on Computer Vision Systems (ICVS'06)*, no. IcvS, pp. 22–22, Ieee, 2006.
- [29] Y. Gong, R. S. Johnston, C. D. Melville, and E. J. Seibel, "Axial-stereo 3-d optical metrology for inner profile of pipes using a scanning laser endoscope," *International journal of optomechatronics*, vol. 9, no. 3, pp. 238–247, 2015.
- [30] D. Yang, Z. Liu, F. Sun, J. Zhang, H. Liu, and S. Wang, "Recursive depth parametrization of monocular visual navigation: Observability analysis and performance evaluation," *Information Sciences*, vol. 287, pp. 38–49, 2014.
- [31] P. Alizadeh and M. Zeinali, "A real-time object distance measurement using a monocular camera," *25-27April, 2017 Kuala Lumpur. Universiti Utara Malaysia (<http://www.uum.edu.my>), 2013.*
- [32] Z. Zhang, Y. Han, Y. Zhou, and M. Dai, "A novel absolute localization estimation of a target with monocular vision," *Optik-International Journal for Light and Electron Optics*, vol. 124, no. 12, pp. 1218–1223, 2013.
- [33] Z. Laskar, S. Huttunen, D. Herrera, E. Rahtu, and J. Kannala, "Robust loop closures for scene reconstruction by combining odometry and visual correspondences," in *Image Processing (ICIP), 2016 IEEE International Conference on*, pp. 2603–2607, IEEE, 2016.
- [34] A. Assa and F. Janabi-Sharifi, "Virtual visual servoing for multicamera pose estimation," *IEEE/ASME Transactions on Mechatronics*, vol. 20, no. 2, pp. 789–798, 2015.
- [35] G. H. Lee, B. Li, M. Pollefeys, and F. Fraundorfer, "Minimal solutions for pose estimation of a multi-camera system," in *Robotics Research*, pp. 521–538, Springer, 2016.
- [36] S. Dinc, F. Fahimi, and R. Aygun, "Vision-based trajectory tracking for mobile robots using mirage pose estimation method," *IET Computer Vision*, vol. 10, no. 5, pp. 450–458, 2016.

- [37] G. Hee Lee, M. Pollefeys, and F. Fraundorfer, “Relative pose estimation for a multi-camera system with known vertical direction,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 540–547, 2014.
- [38] L. Kneip and H. Li, “Efficient computation of relative pose for multi-camera systems,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 446–453, 2014.
- [39] J. Li, J. A. Besada, A. M. Bernardos, P. Tarrío, and J. R. Casar, “A novel system for object pose estimation using fused vision and inertial data,” *Information Fusion*, vol. 33, pp. 15–28, 2017.
- [40] G. Perez-Paina, C. Paz, M. Kulich, M. Saska, and G. Araguás, “Fusion of monocular visual-inertial measurements for three dimensional pose estimation,” in *International Workshop on Modelling and Simulation for Autonomous Systems*, pp. 242–260, Springer, 2016.
- [41] M. Li and A. Mourikis, “Real-time pose estimation system using inertial and feature measurements,” 10 2016. US Patent App. 15/179,631.
- [42] M. Kok, J. D. Hol, and T. B. Schön, “Using inertial sensors for position and orientation estimation,” *arXiv preprint arXiv:1704.06053*, 2017.
- [43] J. M. O’Kane, “Global localization using odometry,” in *Robotics and Automation, 2006. ICRA 2006. Proceedings 2006 IEEE International Conference on*, pp. 37–42, IEEE, 2006.
- [44] X.-b. Zhang, C.-y. Wang, Y.-c. Fang, and K.-x. Xing, “An extended kalman filter-based robot pose estimation approach with vision and odometry,” in *Wearable Sensors and Robots*, pp. 539–552, Springer, 2017.
- [45] D. Tian, X. He, L. Zhang, J. Lian, and X. Hu, “A design of odometer-aided visual inertial integrated navigation algorithm based on multiple view geometry constraints,” in *Intelligent Human-Machine Systems and Cybernetics (IHMSC), 2017 9th International Conference on*, vol. 1, pp. 161–166, IEEE, 2017.
- [46] T. Bratland, D. Wan, and H. S. P. M. S. Design, “Linear position sensing using magnetoresistive sensors,” *Honeywell Solid State Electronics Center*, pp. 4–5, 2002.

- [47] D. I. Wallace, A. L. Baker, and W. Krajewski, "System and method for using magnetic sensors to track the position of an object," 27 2012. US Patent 8,321,173.
- [48] A. Voss, A. Meisenberg, and A. Bartos, "Modern scale based magneto resistive sensors systems,"
- [49] V. Carbone, M. Carocci, E. Savio, G. Sansoni, and L. De Chiffre *The International Journal of Advanced Manufacturing Technology*, no. 4, pp. 263–271.
- [50] V. Chan, C. Bradley, and G. Vickers, "A multi-sensor approach to automating coordinate measuring machine-based reverse engineering," *Computers in Industry*, vol. 44, no. 2, pp. 105–115, 2001.
- [51] F. S. Cheng and X. Chen, "Integrating 3d vision measurements into industrial robot applications,"
- [52] C. N. MacLeod, R. Summan, G. Dobie, and S. G. Pierce, "Quantifying and improving laser range data when scanning industrial materials," *IEEE Sensors Journal*, vol. 16, no. 22, pp. 7999–8009, 2016.
- [53] G. Dobie, R. Summan, S. G. Pierce, W. Galbraith, and G. Hayward, "A noncontact ultrasonic platform for structural inspection," *IEEE Sensors Journal*, vol. 11, no. 10, pp. 2458–2468, 2011.
- [54] A. Crispin and V. Rankov, "Automated inspection of pcb components using a genetic algorithm template-matching approach," *The International Journal of Advanced Manufacturing Technology*, vol. 35, no. 3-4, pp. 293–300, 2007.
- [55] Z. GronosTAjski, M. Hawryluk, M. Kaszuba, and J. Ziemia, "Application of a measuring arm with an integrated laser scanner in the analysis of the shape changes of forging instrumentation during production," *Eksploatacja i Niezawodność*, vol. 18, no. 2, 2016.
- [56] I. Gentilini and K. Shimada, "Predicting and evaluating the post-assembly shape of thin-walled components via 3d laser digitization and fea simulation of the assembly process," *Computer-aided design*, vol. 43, no. 3, pp. 316–328, 2011.
- [57] S. Malassiotis and M. G. Strintzis, "Stereo vision system for precision dimensional inspection of 3d holes," *Machine Vision and Applications*, vol. 15, no. 2, pp. 101–113, 2003.

- [58] R. Xiang, W. He, X. Zhang, D. Wang, and Y. Shan, “Size measurement based on a two-camera machine vision system for the bayonets of automobile brake pads,” *Measurement*, vol. 122, pp. 106–116, 2018.
- [59] X. Wang, M. Q.-H. Meng, and C. Hu, “A localization method using 3-axis magnetoresistive sensors for tracking of capsule endoscope,” in *Engineering in Medicine and Biology Society, 2006. EMBS’06. 28th Annual International Conference of the IEEE*, pp. 2522–2525, IEEE, 2006.
- [60] H. V. Dao and T. Komeda, “Estimating endoscopic orientation in static and dynamic states with inertial sensors,” *Journal of Medical Devices*, vol. 10, no. 4, p. 041003, 2016.
- [61] W. Liu, J. Hu, Y. Fang, Q. Shao, K. Zheng, and G.-N. Zhu, “Real time pose estimation based on extended kalman filter for binocular camera,” in *Intelligent Robot Systems (ACIRS), Asia-Pacific Conference on*, pp. 142–146, IEEE, 2016.
- [62] R. T. Marriott, A. Paschevich, and R. Horaud, “Plane-extraction from depth-data using a gaussian mixture regression model,” *arXiv preprint arXiv:1710.01925*, 2017.
- [63] T. Naseer, B. Suger, M. Ruhnke, and W. Burgard, “Vision-based markov localization for long-term autonomy,” *Robotics and Autonomous Systems*, vol. 89, pp. 147–157, 2017.
- [64] H. Zhang, H.-J. Hendricks-Franssen, X. Han, J. Vrugt, and H. Vereecken, “Joint state and parameter estimation of two land surface models using the ensemble kalman filter and particle filter,” *Hydrol. Earth Syst. Sci. Discuss*, pp. 1–39, 2016.
- [65] M. B. Alatise and G. P. Hancke, “Pose estimation of a mobile robot based on fusion of imu data and vision data using an extended kalman filter,” *Sensors*, vol. 17, no. 10, p. 2164, 2017.
- [66] P. Eberhard and Q. Tang, “Sensor data fusion for the localization and position control of one kind of omnidirectional mobile robots,” in *Multibody system dynamics, robotics and control*, pp. 45–73, Springer, 2013.
- [67] H. Chu, Z. Xie, D. Juan, R. Zhang, and F. Liu, “The study of improved particle filtering target tracking algorithm based on multi-features fusion,” in *Computer Science On-line Conference*, pp. 20–32, Springer, 2017.

- [68] Z. Yaoming, W. Chengdong, Z. Yunzhou, and F. Sheng, "Realization of moving object detection and tracking algorithm based on frame difference method and particle filter algorithm," in *Control And Decision Conference (CCDC), 2017 29th Chinese*, pp. 161–166, IEEE, 2017.
- [69] I. A. Iswanto and B. Li, "Visual object tracking based on mean-shift and particle-kalman filter," *Procedia Computer Science*, vol. 116, pp. 587–595, 2017.
- [70] C. Pirchheim, D. Schmalstieg, and G. Reitmayr, "Monocular visual slam with general and panorama camera movements," 6 2017. US Patent 9,674,507.
- [71] P. Vadakkepat and L. Jing, "Improved particle filter in sensor fusion for tracking randomly moving object," *IEEE Transactions on Instrumentation and Measurement*, vol. 55, no. 5, pp. 1823–1832, 2006.
- [72] C. Yuan, M. Lianchuan, and W. Ma, "Mobile target tracking based on hybrid open-loop monocular vision motion control strategy," *Discrete Dynamics in Nature and Society*, vol. 2015, 2015. Cited By :1.
- [73] Z. Boukhers, K. Shirahama, F. Li, and M. Grzegorzec, "Object detection and depth estimation for 3d trajectory extraction," in *Content-Based Multimedia Indexing (CBMI), 2015 13th International Workshop on*, pp. 1–6, IEEE, 2015.
- [74] S. S. Sakharkar, S. Kamble, and A. Khobragade, "Object detection and tracking using particle filtering,"
- [75] T. Reichl, J. Gardiazabal, and N. Navab, "Electromagnetic servoing a new tracking paradigm," *IEEE transactions on medical imaging*, vol. 32, no. 8, pp. 1526–1535, 2013.
- [76] K. Mori, D. Deguchi, K. Akiyama, T. Kitasaka, C. R. Maurer, Y. Suenaga, H. Takabatake, M. Mori, and H. Natori, "Hybrid bronchoscope tracking using a magnetic tracking sensor and image registration," in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pp. 543–550, Springer, 2005.
- [77] S.-F. Yang, H.-Y. Lin, and M.-L. Wang, "3d instrument localization and tracking with the integration of image-based and electromagnetic techniques," in *Industrial Electronics (ISIE), 2014 IEEE 23rd International Symposium on*, pp. 1150–1155, IEEE, 2014.

- [78] X. Luo and K. Mori, “Robust endoscope motion estimation via an animated particle filter for electromagnetically navigated endoscopy,” *IEEE Transactions on Biomedical Engineering*, vol. 61, no. 1, pp. 85–95, 2014.
- [79] H. Dai, W. Yang, X. Xia, S. Su, and K. Ma, “A three-axis magnetic sensor array system for permanent magnet tracking,” in *Multisensor Fusion and Integration for Intelligent Systems (MFI), 2016 IEEE International Conference on*, pp. 476–480, IEEE, 2016.
- [80] A. Alangari, B. Thompson, and W. Whitehorn, “Pid control demo,” 2015.
- [81] T. Bertrand, K. Kaczmarek, and L. Wilen, “Musical acoustics & instrument design: When engineering meets music,” in *ICMC*, 2015.
- [82] L. M. Deas and L. M. Wilcox, “Perceptual grouping via binocular disparity: the impact of stereoscopic good continuation,” *Journal of vision*, vol. 15, no. 11, pp. 11–11, 2015.
- [83] A. O. Baturone, *Robótica: manipuladores y robots móviles*. Marcombo, 2005.
- [84] J. A. Valencia, A. Montoya, and L. H. Rios, “Modelo cinemático de un robot móvil tipo diferencial y navegación a partir de la estimación odométrica,” *Scientia et technica*, vol. 15, no. 41, pp. 191–196, 2009.
- [85] T. Buratowski, B. Dabrowski, T. Uhl, and J. Kwosek, “The precise odometry navigation for the group of robots,” *Schedae Informaticae*, vol. 19, pp. 99–111, 2015.
- [86] A. Bemporad, M. Di Marco, and A. Tesi, “Wall-following controllers for sonar-based mobile robots,” in *Decision and Control, 1997., Proceedings of the 36th IEEE Conference on*, vol. 3, pp. 3063–3068, IEEE, 1997.
- [87] J. Borenstein and L. Feng, “Correction of systematic odometry errors in mobile robots,” in *Intelligent Robots and Systems 95. Human Robot Interaction and Cooperative Robots*, *Proceedings. 1995 IEEE/RSJ International Conference on*, vol. 3, pp. 569–574, IEEE, 1995.
- [88] J. Seong, D. Jung, and W. Chung, “Odometry calibration for car-like mobile robots,” in *Ubiquitous Robots and Ambient Intelligence (URAI), 2017 14th International Conference on*, pp. 889–890, IEEE, 2017.
- [89] A. Martinelli and R. Siegwart, “Estimating the odometry error of a mobile robot during navigation,” in *None*, no. LSA-CONF-2003-005, 2003.

- [90] F. Espinosa, C. Santos, M. Marrón-Romera, D. Pizarro, F. Valdés, and J. Dongil, “Odometry and laser scanner fusion based on a discrete extended kalman filter for robotic platooning guidance,” *Sensors*, vol. 11, no. 9, pp. 8339–8357, 2011.
- [91] A. Pozo-Ruz, M. García-Alegre, A. Ribeiro, E. I. d. Vicente, and J. Plaza, “Localización de vehículos fusion de medidas gps y odometría,” *Mundo Electrónico*, pp. 46–54, 2000.
- [92] A. Korodi and T. L. Dragomir, “Correcting odometry errors for mobile robots using image processing,” in *Proceedings of the International MultiConference of Engineers and Computer Scientists*, vol. 2, pp. 17–19, 2010.
- [93] J. Toledo, J. D. Piñeiro, R. Arnay, D. Acosta, and L. Acosta, “Improving odometric accuracy for an autonomous electric cart,” *Sensors*, vol. 18, no. 1, p. 200, 2018.
- [94] M. polo Sauza Aguirre, *Desarrollo de instrumentación para un sistema de reconstrucción 3D del interior de ductos de bajo calibre*. PhD thesis, 2015.
- [95] Y. Jiang, T. Lu, Y. Zhang, and S. Ai, “Monocular visual odometry-based 3d-2d motion estimation,” in *Society of Photo-Optical Instrumentation Engineers (SPIE) Conference Series*, vol. 10608, 2018.
- [96] B. Guan, P. Vasseur, C. Demonceaux, and F. Fraundorfer, “Visual odometry using a homography formulation with decoupled rotation and translation estimation using minimal solutions,” in *International Conference on Robotics and Automation-ICRA*, 2018.
- [97] L. Miao, M. Li, and S. Hong, “Autonomous navigation using visual odometry,” 17 2018. US Patent 9,946,264.
- [98] T. Qin, P. Li, and S. Shen, “Vins-mono: A robust and versatile monocular visual-inertial state estimator,” *arXiv preprint arXiv:1708.03852*, 2017.
- [99] V. Usenko, J. Engel, J. Stückler, and D. Cremers, “Direct visual-inertial odometry with stereo cameras,” in *Robotics and Automation (ICRA), 2016 IEEE International Conference on*, pp. 1885–1892, IEEE, 2016.
- [100] M. T. Rahman, T. Karamat, S. Givigi, and A. Noureldin, “Improving multisensor positioning of land vehicles with integrated visual odometry for next-generation self-driving cars,” *Journal of Advanced Transportation*, vol. 2018, 2018.

- [101] M. Birem, R. Kleihorst, and N. El-Ghouthi, “Visual odometry based on the fourier transform using a monocular ground-facing camera,” *Journal of Real-Time Image Processing*, vol. 14, no. 3, pp. 637–646, 2018.
- [102] D. Schubert, T. Goll, N. Demmel, V. Usenko, J. Stückler, and D. Cremers, “The tum vi benchmark for evaluating visual-inertial odometry,” *arXiv preprint arXiv:1804.06120*, 2018.
- [103] J.-C. Piao and S.-D. Kim, “Adaptive monocular visual–inertial slam for real-time augmented reality applications in mobile devices,” *Sensors*, vol. 17, no. 11, p. 2567, 2017.
- [104] M. Ramezani, K. Khoshelham, and C. Fraser, “Pose estimation by omnidirectional visual-inertial odometry,” *Robotics and Autonomous Systems*, vol. 105, pp. 26–37, 2018.
- [105] R. Hartley and A. Zisserman, *Multiple view geometry in computer vision*. Cambridge university press, 2003.
- [106] J.-Y. Bouguet, “Camera calibration toolbox for matlab,” 2015.
- [107] Q.-T. Luong and O. D. Faugeras, “Camera calibration, scene motion and structure recovery from point correspondences and fundamental matrices,” *IJCV*, vol. 22, no. 3, pp. 261–289, 1997.
- [108] Z. Yang, F. Chen, J. Zhao, and H. Zhao, “A novel camera calibration method based on genetic algorithm,” in *Industrial Electronics and Applications, 2008. ICIEA 2008. 3rd IEEE Conference on*, pp. 2222–2227, IEEE, 2008.
- [109] J. Lafferty, A. McCallum, and F. C. Pereira, “Conditional random fields: Probabilistic models for segmenting and labeling sequence data,” 2001.
- [110] Y. Wang, A. Kucukelbir, and D. M. Blei, “Robust probabilistic modeling with Bayesian data reweighting,” in *Proceedings of the 34th International Conference on Machine Learning* (D. Precup and Y. W. Teh, eds.), vol. 70 of *Proceedings of Machine Learning Research*, (International Convention Centre, Sydney, Australia), pp. 3646–3655, PMLR, 06–11 Aug 2017.
- [111] P. Senellart, “Probabilistic models for uncertain data,” in *Proceedings of the Fourth Symposium on Information and Communication Technology*, SoICT ’13, (New York, NY, USA), pp. 10–10, ACM, 2013.

- [112] W. Zhang, X. Lin, J. Pei, and Y. Zhang, "Managing uncertain data: Probabilistic approaches," in *Web-Age Information Management, 2008. WAIM'08. The Ninth International Conference on*, pp. 405–412, IEEE, 2008.
- [113] J. L. Beck and K.-V. Yuen, "Model selection using response measurements: Bayesian probabilistic approach," *Journal of Engineering Mechanics*, vol. 130, no. 2, pp. 192–203, 2004.
- [114] S. Thrun, "Probabilistic algorithms in robotics," *Ai Magazine*, vol. 21, no. 4, p. 93, 2000.
- [115] Q. Zhou, S. Kar, L. Huie, and S. Cui, "Distributed estimation in sensor networks with imperfect model information: An adaptive learning-based approach," in *Acoustics, Speech and Signal Processing (ICASSP), 2012 IEEE International Conference on*, pp. 3109–3112, IEEE, 2012.
- [116] A. P. Dempster, N. M. Laird, and D. B. Rubin, "Maximum likelihood from incomplete data via the em algorithm," *Maximum Likelihood from Incomplete Data Via the EM Algorithm*, pp. 1–38, 1977. Cited By :60.
- [117] S. S. Pereira, R. Lopez-Valcarce, and A. Pagès-Zamora, "A diffusion-based em algorithm for distributed estimation in unreliable sensor networks," *IEEE Signal Processing Letters*, vol. 20, no. 6, pp. 595–598, 2013.
- [118] W. Zhang, Y. Yang, and Q. Wang, "Using bayesian regression and em algorithm with missing handling for software effort prediction," *Information and software technology*, vol. 58, pp. 58–70, 2015.
- [119] W. Dou, J. George, L. Kaplan, R. W. Osborne, and Y. Bar-Shalom, "Assignment and em approaches for passive localization of multiple transient emitters," in *Signal Processing, Sensor/Information Fusion, and Target Recognition XXV*, vol. 9842, p. 984206, International Society for Optics and Photonics, 2016.
- [120] M.-A. Sato and S. Ishii, "On-line em algorithm for the normalized gaussian network," *Neural computation*, vol. 12, no. 2, pp. 407–432, 2000.
- [121] D. Gu, "Distributed em algorithm for gaussian mixtures in sensor networks," *IEEE Transactions on Neural Networks*, vol. 19, no. 7, pp. 1154–1166, 2008.

- [122] F. H. Bursal, “On interpolating between probability distributions,” *Applied Mathematics and Computation*, vol. 77, no. 2, pp. 213–244, 1996.
- [123] A. Assa and F. Janabi-Sharifi, “A robust vision-based sensor fusion approach for real-time pose estimation,” *IEEE transactions on cybernetics*, vol. 44, no. 2, pp. 217–227, 2014.
- [124] H. Cho, Y.-W. Seo, B. V. Kumar, and R. R. Rajkumar, “A multi-sensor fusion system for moving object detection and tracking in urban driving environments,” in *Robotics and Automation (ICRA), 2014 IEEE International Conference on*, pp. 1836–1843, IEEE, 2014.
- [125] B. Liu, F. Zhang, and X. Qu, “A method for improving the pose accuracy of a robot manipulator based on multi-sensor combined measurement and data fusion,” *Sensors*, vol. 15, no. 4, pp. 7933–7952, 2015.
- [126] C. M. Martinez, F. Zhang, D. Clarke, G. Hinz, and D. Cao, “Feature uncertainty estimation in sensor fusion applied to autonomous vehicle location,” in *Information Fusion (Fusion), 2017 20th International Conference on*, pp. 1–7, IEEE, 2017.
- [127] A. S. Huang, A. Bachrach, P. Henry, M. Krainin, D. Maturana, D. Fox, and N. Roy, “Visual odometry and mapping for autonomous flight using an rgb-d camera,” in *Robotics Research*, pp. 235–252, Springer, 2017.
- [128] S. Chakraborty, H. Laware, D. Castanon, and S. R. Zekavat, “High precision localization for autonomous vehicles via multiple sensors, data fusion and novel wireless technologies,” in *Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON), IEEE Annual*, pp. 1–9, IEEE, 2016.
- [129] M. Gangawane, R. Awate, P. R. Suryawanshi, and R. Joshi, “Obstacle detection and object size measurement for autonomous mobile robot using sensor,” in *Control Applications (CCA), 2013 IEEE International Conference on*, 2013.
- [130] J.-r. Xue, D. Wang, S.-y. Du, D.-x. Cui, Y. Huang, and N.-n. Zheng, “A vision-centered multi-sensor fusing approach to self-localization and obstacle perception for robotic cars,” *Frontiers of Information Technology & Electronic Engineering*, vol. 18, no. 1, pp. 122–138, 2017.

- [131] J. Yuan, H. Chen, F. Sun, and Y. Huang, "Multisensor information fusion for people tracking with a mobile robot: A particle filtering approach," *IEEE transactions on Instrumentation and Measurement*, vol. 64, no. 9, pp. 2427–2442, 2015.
- [132] T. Helten, M. Muller, H.-P. Seidel, and C. Theobalt, "Real-time body tracking with one depth camera and inertial sensors," in *Proceedings of the IEEE International Conference on Computer Vision*, pp. 1105–1112, 2013.
- [133] I. Pires, N. M. Garcia, N. Pombo, and F. Florez-Revulta, "From data acquisition to data fusion: a comprehensive review and a roadmap for the identification of activities of daily living using mobile devices," *Sensors*, vol. 0, pp. 0–0, January 2016.
- [134] A. Hannachi, S. Kohler, A. Lallement, and E. Hirsch, "Multi-sensor data fusion for realistic and accurate 3d reconstruction," in *Visual Information Processing (EUVIP), 2014 5th European Workshop on*, pp. 1–6, IEEE, 2014.
- [135] K. Lu and W. Wang, "A multi-sensor approach for rapid and precise digitization of free-form surface in reverse engineering.," *International Journal of Advanced Manufacturing Technology*, vol. 79, 2015.
- [136] F. Li, A. P. Longstaff, S. Fletcher, and A. Myers, "Rapid and accurate reverse engineering of geometry based on a multi-sensor system," *The International Journal of Advanced Manufacturing Technology*, vol. 74, no. 1-4, pp. 369–382, 2014.
- [137] X. Wang, R. Hoseinnezhad, A. K. Gostar, T. Rathnayake, B. Xu, and A. Bab-Hadiashar, "Statistical information fusion for multiple-view sensor data in multi-object tracking," *arXiv preprint arXiv:1702.08641*, 2017.
- [138] K. Panta, B.-N. Vo, and S. Singh, "Novel data association schemes for the probability hypothesis density filter," *IEEE Transactions on Aerospace and Electronic Systems*, vol. 43, no. 2, 2007.
- [139] D. Y. Kim and M. Jeon, "Data fusion of radar and image measurements for multi-object tracking via kalman filtering," *Information Sciences*, vol. 278, pp. 641–652, 2014.
- [140] S. Rawat and S. Rawat, "Multi-sensor data fusion by a hybrid methodology—a comparative study," *Computers in Industry*, vol. 75, pp. 27–34, 2016.

- [141] M. Turan, Y. Almalioglu, H. Araujo, T. Cemgil, and M. Sitti, “Endosensorfusion: Particle filtering-based multi-sensory data fusion with switching state-space model for endoscopic capsule robots using recurrent neural network kinematics,” *arXiv preprint arXiv:1709.03401*, 2017.
- [142] H. B. Mitchell, *Multi-sensor data fusion: an introduction*. Springer Science & Business Media, 2007.
- [143] F. Pernkopf and D. Bouchaffra, “Genetic-based em algorithm for learning gaussian mixture models,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 27, no. 8, pp. 1344–1348, 2005.
- [144] G. Tian, Y. Xia, Y. Zhang, and D. Feng, “Hybrid genetic and variational expectation-maximization algorithm for gaussian-mixture-model-based brain mr image segmentation,” *IEEE transactions on information technology in biomedicine*, vol. 15, no. 3, pp. 373–380, 2011.
- [145] X. Lu, Y. Huang, and Y. Zhu, “Finite mixture of nonlinear mixed-effects joint models in the presence of missing and mismeasured covariate, with application to aids studies,” *Computational Statistics & Data Analysis*, vol. 93, pp. 119–130, 2016.
- [146] S. Michael and V. Melnykov, “An effective strategy for initializing the em algorithm in finite mixture models,” *Advances in Data Analysis and Classification*, vol. 10, no. 4, pp. 563–583, 2016.
- [147] C. Cigla, R. Brockers, and L. Matthies, “Gaussian mixture models for temporal depth fusion,” in *Applications of Computer Vision (WACV), 2017 IEEE Winter Conference on*, pp. 889–897, IEEE, 2017.
- [148] H. Zhu, K. Guo, and S. Chen, “Fusion of gaussian mixture models for maneuvering target tracking in the presence of unknown cross-correlation,” *Chinese Journal of Electronics*, vol. 25, no. 2, pp. 270–276, 2016.
- [149] S. Gensler, “Finite mixture models,” *Handbook of Market Research*, pp. 1–14, 2017.
- [150] T. Pfeifer, P. Weissig, S. Lange, and P. Protzel, “Robust factor graph optimization—a comparison for sensor fusion applications,” in *Emerging Technologies and Factory Automation (ETFA), 2016 IEEE 21st International Conference on*, pp. 1–4, IEEE, 2016.

- [151] W. Yuan, Z. Cao, Y. Zhang, and M. Tan, “A robot pose estimation approach based on object tracking in monitoring scenes,” *International Journal of Robotics and Automation*, vol. 32, no. 3, 2017.
- [152] S. E. Li, G. Li, J. Yu, C. Liu, B. Cheng, J. Wang, and K. Li, “Kalman filter-based tracking of moving objects using linear ultrasonic sensor array for road vehicles,” *Mechanical Systems and Signal Processing*, vol. 98, pp. 173–189, 2018.
- [153] Y. Aizawa, T. Suzuki, and K. Kobayashi, “Improvement of robot’s self-localization by using observer view positional information,” 2017.
- [154] S. Thrun, W. Burgard, and D. Fox, “Probabilistic robotics. 2005,” *CURRICULUM VITAE*, 2005.
- [155] W. Liu, X. Wang, and Z. Deng, “Robust centralized and weighted measurement fusion kalman estimators for multisensor systems with multiplicative and uncertain-covariance linearly correlated white noises,” *Journal of the Franklin Institute*, vol. 354, no. 4, pp. 1992–2031, 2017.
- [156] Q. Gan and C. J. Harris, “Comparison of two measurement fusion methods for kalman-filter-based multisensor data fusion,” *IEEE Transactions on Aerospace and Electronic systems*, vol. 37, no. 1, pp. 273–279, 2001.
- [157] K. Kim and H. Sohn, “Dynamic displacement estimation by fusing ldv and lidar measurements via smoothing based kalman filtering,” *Mechanical Systems and Signal Processing*, vol. 82, pp. 339–355, 2017.
- [158] B. Friedland, “Optimum steady-state position and velocity estimation using noisy sampled position data,” *IEEE transactions on Aerospace and Electronic Systems*, no. 6, pp. 906–911, 1973.
- [159] I. Virgala, M. Kelemen, A. Gmitterko, and T. Lipták, “Control of stepper motor by microcontroller,” *Journal of Automation and Control*, vol. 3, no. 3, pp. 131–134, 2015.

ANEXOS

Anexo A

Características de los sensores

Sensor magnético Soft Pot

Las especificaciones técnicas proporcionadas para este sensor son:

- Resistencia estándar: $10K \Omega$.
- Tolerancia de la resistencia $\pm 20 \%$.
- Distancia efectiva 8 a 2000 mm.
- Linealidad $\pm 1 \%$.
- Potencia 1 Watt.
- Temperatura 25°
- Ciclo de vida 1 millon
- Ancho: 0.51 mm

Sensor Odométrico

Para el funcionamiento del sensor se utiliza un sistema electrónico, cuya función se encuentra explicada a mayor detalle en el trabajo [94]

Las características principales son:

- Micro controlador STM32F429ZIT6 de 2MB de memoria Flash.

- Memoria RAM 256 KB .
- Puerto de comunicación USB.
- Fuente de alimentación 3V a 5V.
- LCD VGA 2.4 pulg .
- Sensor de movimiento MEMS L3GD20.
- SDRAM de 64Mb.
- Led LD1 para comunicación USB, led LD2 para encender.

La relación de cálculo de la distancia lineal con los pulsos del encoder se muestra en la Tabla A.1 :

Cuadro A.1: Relación de los pulsos con la distancia

Distancia de referencia	Pulsos
0	0
10	22
20	43
30	65
40	86
50	108
60	129
70	150
80	172
90	193
100	215
110	237
120	258
130	279
140	300



Figura A.1: Tarjeta de adquisición de datos

Sensor óptico

El patrón de calibración del sensor óptico es una matriz led de 8x8, modelo 1588AS, los diodos que conforman la matriz de Leds se conectan hacia el ánodo común.



Figura A.2: Matriz de led

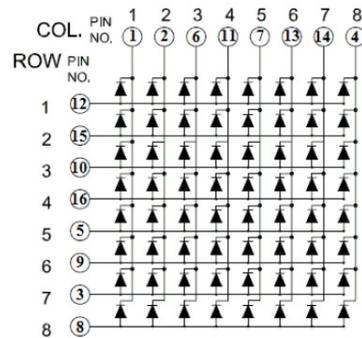


Figura A.3: Circuito interno de la matriz de led

Las características de la matriz de led son:

- Fuente de alimentación 2 a 2.5 V.
- Corriente 20 mA .
- Diámetro de cada led 0.8 pulg.
- Color emitido rojo.
- Tamaño 33.32 x 33.32 x 8 mm.

Cámara endoscópica

El endoscopio modelo N005 supereyes utiliza tecnología optoelectrónica para inspeccionar áreas de difícil acceso. Las especificaciones técnicas del endoscopio son:

- Interface USB .
- Distancia focal 20 a 80 mm.
- Diámetro de la cámara 0.7 mm.
- Dimensiones 510.54 x 7.62 x 7.62 mm.
- Tubo flexible 1.4 m, se adapta a diferentes formas.
- 0.3 MP CMOS sensor.
- Función de auto brillo.

- Ángulo de vista 60°.
- Resolución de la imagen 640 x 480 pixeles(JPEG).
- Cuadros por segundo: 30 FPS
- Luz led ajustable en la punta de la cámara para iluminar la zona de inspección

Mesa de precisión deslizable

La mesa de deslizamiento lineal trabaja con dos motores a pasos usando un microcontrolador de movimiento LSKZA,



Figura A.4: Mesa deslizable y control de posición

Las especificaciones técnicas son:

- Interface USB y DB9.
- Fuente de alimentación 180 a 240 V.
- Dimensiones 348 x 300 x 140 mm.
- Pantalla LCD.
- Selección de eje de movimiento X, Y o Z .
- Distancia de desplazamiento: número de pasos de motor .
- Velocidad de movimiento 100 a 3000 (pulsos/seg).
- Motor a pasos 1.8° modelo 42BYGHM607B
- Torque máximo 0.4 NM

- Suministro de corriente 1.7 A

- Precisión de posición $\pm 5\%$



Figura A.5: Motor de pasos de mesa de desplazamiento

El motor gira hacia una posición específica mediante el ángulo de paso de cada motor, de acuerdo con [159] las relaciones del motor a paso son:

$$spr = \frac{2 * \pi}{\alpha} \quad (\text{A.1})$$

donde α es el ángulo de paso del motor, spr es el número de pasos por vuelta.

Para medir la posición del motor se calcula mediante:

$$\theta(mm) = n * \alpha \quad (\text{A.2})$$

θ es la posición, n es el número de pasos.

Durante la experimentación se obtuvo la relación manual de las conversiones de pasos del motor a milímetros. La Tabla A.2 muestra los datos:

Cuadro A.2: Tabla de conversiones mm a spr

Distancia de referencia	Pasos del motor
0	0
10	4000
20	8000
30	12000
40	16000
50	20000
60	24000
70	28000
80	32000
90	36000
100	40000
110	44000
120	48000
130	52000
140	56000