

**Guido Rafael Torres Llerena** 

TRABAJO FIN DE MASTER

INDUSTRIALES



# TRABAJO FIN DE MASTER

GENERACIÓN AUTOMÁTICA DE MAPAS TÉRMICOS 3-D E IDENTIFICACIÓN INTELIGENTE DE VÍCTIMAS MEDIANTE IMÁGENES TÉRMICAS EN ENTORNOS S.A.R.

TRABAJO FIN DE MASTER PARA LA OBTENCIÓN DEL TÍTULO DE **MASTER EN** INGENIERÍA INDUSTRIAL **JULIO 2021** 

**Guido Rafael Torres Llerena** 

TUTOR DEL TRABAJO FIN DE MASTER: **Antonio Barrientos Cruz** 

**COTUTOR DEL TRABAJO FIN DE MASTER: Christyan Mario Cruz Ulloa** 







José Gutiérrez Abascal, 2. 28006 Madrid Tel.: 91 336 3060 info.industriales@upm.es

www.industriales.upm.es





# Universidad Politécnica de Madrid Escuela Técnica Superior de Ingenieros Industriales Máster Universitario en Automática y Robótica



#### Trabajo Fin de Máster

Generación Automática de Mapas Térmicos 3-D e Identificación Inteligente de Víctimas mediante Imágenes Térmicas en Entornos S.A.R.

Autor: Guido Rafael Torres Llerena

Tutor Académico: Antonio Barrientos

Tutor externo: Christyan Mario Cruz Ulloa

# **Agradecimientos**

En primer lugar, deseo expresar mi reconocimeinto a las personas cuyo apoyo me ha sido muy valioso para la realizar este proyecto

Agradezco mi familia a pesar de la distancia, siempre los he sentido cerca y han sido mi mayor motivación.

Agradezco a Antonio Barrientos, por darme la oportunidad de realizar el trabajo fin de master en el laboratorio Robcib.

Agradezco de manera especial a Christyan Cruz por su paciencia, tiempo y guia durante este trabajo.

Guido Rafael Torres Llerena

## Resumen

La identificación de víctimas en entornos catastroficos, esta compuesto por dos temas principales: localización y mapeo.

La localización se refiere a la identificación de personas en entornos de desatre para lo cual se puede usar una gran variedad de sensore y camaramas, en el siguiente proyecto destacamos la importancia del uso de camaras termicas para dicha aplicacion, teniendo como resultado identificaciones del 98%, en las 3 difententes pruebas realizadas.

El mapeo se refiere al scaneo del entorno en donde se encuentra la victima para asi elaborar tareas de rescate para los rescatistas.

El proyecto parte por la calibracion de la camara termica y la toma de datos entre esta camara y el sensor kinect, una vez logrado dicho objetivo generamos la nube de puntos con dichos datos. La el mapa total del entorno en donde se encuentra la victima lo realizamos mediante el algoritmo ICP, para el cual se obtuvo resultados satisfactorios del 88 %.

El entrenamiento de la red neuronal se realizo apartir de una base de datos en los tres diferentes ecenarios en los cuales se realizaron pruebas, el entrenamiento se realizo con un total de 1750 imagenes para las 7 clases a identificar. Entre ellos: partes del cuerpo del rescatista y partes del cuerpo de la victima . Obteniendo un resultado de presicion superior al  $90\,\%$ .

## **Abstract**

The identification of victims in disaster environments is composed of two main themes: location and mapping.

Location refers to the identification of people in disaster settings for which a wide variety of sensors and cameras can be used, in this project we highlight the importance of the use of thermal cameras for this application, resulting in 98% identifications, in the 3 different tests developed.

Mapping refers to scanning the environment where the victim is to develop rescue tasks for rescuers.

This project starts with the calibration of the thermal camera and the data collection between this camera and the Kinect sensor, once this objective is achieved we generate the point cloud with said data. The total map of the environment where the victim is found was carried out using the ICP algorithm, for which satisfactory results of 88 % were obtained.

The training of the neural network was carried out from a database in the three different scenarios in which tests were carried out, the training was carried out with a total of 1750 images for the 7 classes to be identified. Among them: parts of the rescuer's body and parts of the victim's body. Obtaining a precision result higher than 90 %.

# Resumen Ejecutivo

Los grandes avances tecnológicos de los últimos años han permitido la ubicación y reconocimiento de personas en zonas catastroficas, mediante una gama amplia de sensores 3d y camaras, las ayudan a los rescatistas a tener un mejor entendimiento del area afectada.

Los desarrollos en los campos de la robotica, sensores especificos para medir variables térmicas y de profundidad, han permitido mejorar los procesos de captación de entorno

El auge de las redes enuronales ha permitido generar sisteamas mas robustos para identificación de victimas en entornos de donde se destaque la radiación emitida por las victimas como puede ser en un nevado [2] o en el mar [15].

La principal aportacion de este TFM destaca en la generación automática de mapas térmicos 3D en entornos S.A.R, ya que la revisión del estado del arte en los temas de identificacion de victimas se limita a la identificacion de victimas y rescatistas en zonas de desastre, por otro lado se puede localizar partes del cuerpo como piernas brazos, torso y cabeza de la victima .

Quiza la parte mas robusta de este TFM radica en el uso de imágenes térmicas, debido a que los entornos de desastre tienen condiciones precarias, principalmete no tienen luminosidad adecuada, se han llevado experimentos para validar este método, y los resultados han sido altamente satisfactorios.

Los principales trabajos del estado del arte no abordan este campo de una forma amplia, por lo que este TFM pretende ser un aporte significativo al estado del arte actual en el campo de busqueda y rescate, como en el [16] donde usan sensores lidar para el mapeo del entorno y localizan las victimas pero sin realizar un mapa 3d termico de su entorno. La R1 vemos la camara termica utilizada en el proyecto y el robot al cual se va a montar la camara termica.

Se ha generado un dataset para entrenar la red neuronal, con la finalidad de incrementar la robustez de la red, se ha realizado un data augmentation, aplicando diferentes filtros, y rotaciones al dataset. Para contemplar cualquier percance o perdida de señal al



(a) Cámara térmica Optris (b) Robot Dr. Jaguar dotado de PI 640 instrumentación

Figura R1 Robot e Instrumentación utilizados durante el desarrollo del TFM.

momento de ejecutar la red neuronal, lo cual vemos en R2.

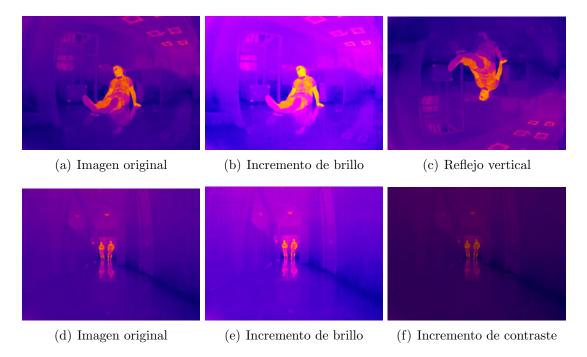


Figura R2 Muestra de la aplicación de data augmentation a una imagen térmica de un rescatista.

Por otra parte, el auge del Deep Leaning que se ha dado en los últimos años, debido a su accesibilidad por ser software libre, ha creado una gran comunidad desarrolladora que ha logrado dar múltiples pasos adelante en el sector, que han permitido generar algoritmos y aplicaciones robustas para diversas aplicaciones.

La Figura 3.10 vemos la integración de una imagen de profundidad con una imagen térmica, por medio de las librerías de open3d.

La 3.10 la generación de una primera nube apartir de los parametros intrínsecos de la camara térmica ya previamente calibrada, y la imagen de profundidad.

El entrenamiento de la red ha mostrado que la exactitud oscila alrededor del 90 % tras

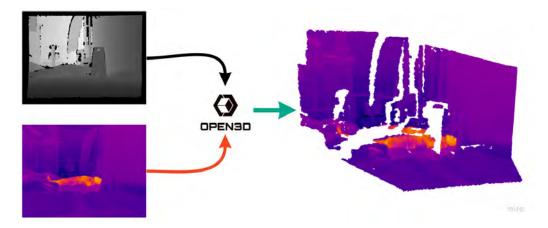


Figura R3 Integracion de imagen termica y de profundidad, para generar un mapa térmico 3d Local

un entrenamiento de 120 epocas, el resultado del entrenamieto muestra un gran procentaje de acierto, por lo que se puede tener una gran fiabilidad del sistema en la localizacion de victimas y rescatistas en zonas de desastre. Las pruebas de validacion se realizaron acorde las normativas [11], en las zonas rojas y naranjas de las pistas propuestas por el NIST en la competencia Robocup, en donde simulan entornos catastroficos con materiales similares a los que se puedan encontrar en una zona catastrofica.

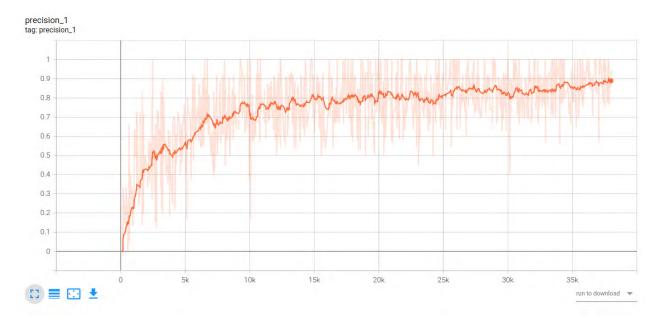
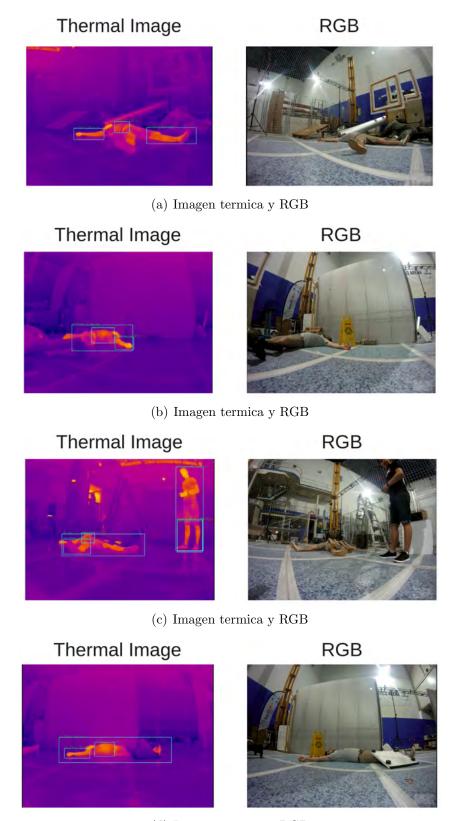


Figura R4 Curva de presicion del entrenamiento de la red neuronal para 110 epocas.

Los resultados de la inferencia de la red neuronal entrenada se muestran en la 4.5. Inferéncia de la imagen térmica junto con la imagen RGB 4.10, que permite identificar la alta eficacia del uso de imágenes térmicas para identificación de víctimas y rescatistas en zonas catastroficas.

A la nube de puntos térmica se ha integrado la información de la red neurona, de tal manera que se puede identificar en el mapa global a la victima, por medio de la



(d) Imagen termica y RGB

**Figura R5** Inferencia de la imagen termica junto con la imagen RGB, que permite identificar la alta eficacia del uso de imágenes térmicas para identificación de personas.

#### x RESUMEN EJECUTIVO

identificacion de personas con la red convolucional y la ubicacion por el mapa termico resultado de la concatenacion de nubes de puntos de cada imagen, como se muestra 5.2 la concatenacion de nubes de puntos del pasillo, la localización de víctimas y rescatistas en dicho entorno.

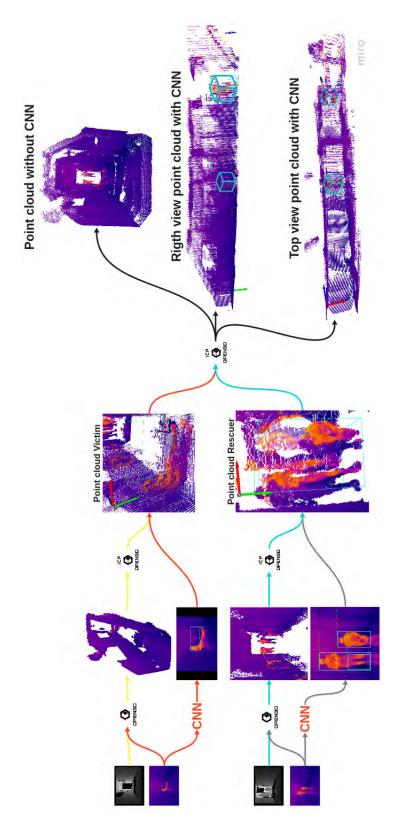


Figura R6 Proceso de generacion de nubes de puntos en pasillo.

Palabras clave : Mapeo térmico, Redes neuronales, Robot móvil, Visión artificial, Búsqueda y rescate, Imagen térmica.

#### Códigos Unesco:

3357 Cibernética

1203 Ciencia de los ordenadores

120304 Inteligencia Artificial

3311 Tecnología de la Instrumentación

331116 Instrumentos de Medida de la Temperatura

3355 Robótica

# Índice

In	dice	de Figuras	xvii
Ín	dice	de Tablas x	viii
Li	sta d	e Símbolos x	viii
Li	sta d	e Acrónimos x	viii
1.	Intr	oducción	1
	1.1.	Antecedentes	1
	1.2.	Justificación e Importancia	2
	1.3.	Objetivos	2
	1.4.	Descripción general del proyecto	2
	1.5.	Estructura del documento	3
2.	Esta	ado del Arte	4
	2.1.	Diferentes tipos de métodos de escaneo 3D	4
	2.2.	Procesamiento de datos tridimensionales	7
		2.2.1. Filtrado de datos	7
		2.2.2. Suavizado de superficies	8
		2.2.3. Alineado	8
		2.2.4. Segmentado	9
	2.3.	Robots moviles para busqueda y rescate	10
	2.4.	Redes neuronales	10
		2.4.1. CNN	10
	2.5.	Entornos de desastre	11
	2.6.	Simulacion de victimas	13
	2.7.	Mapeo 3D de entornos	14

	2.8.	Adquisicion de datos	14
	2.9.	Representación de datos	16
3.	Con	neración Automática de Mapas Térmicos 3D y localización de vícti-	
υ.	mas	-	18
	3.1.	Adquisición de datos de profundidad e imágenes térmicas	
		3.1.1. Calibración de equipos	
		3.1.2. Rectificación de imágenes	
	3.2.	Procesamiento y Transmisión de Imágenes térmica mediante OpenCV y ROS	20
	3.3.	Integración de cámara térmica y de profundidad con ROS	
	3.4.	Requerimientos	24
		3.4.1. Movilidad del Robot	24
		3.4.2. Toma de imagenes	24
	3.5.	Adquisición y Procesamiento de nubes de puntos	24
		3.5.1. Adaptacion del sistema a una plataforma robotica	29
		3.5.2. Resultados de concatenación de nubes de puntos	29
4.	Det	ección de Víctimas mediante Redes Neuronales Convolucionales	48
	4.1.	Deteccion de victimas mediante Redes Neuronales Convolucionales	48
		4.1.1. Entrenamiento de la red neuronal	52
	4.2.	Validación	55
5.	Pru	ebas y Resultados	60
		·	60
		5.1.1. Identificacion de victimas en ambientes catastróficos	60
6.	CO	NCLUSIONES	66
-		Principales conclusiones	66
			67
7.	AN	EXOS	71
		Anexo I: Analisis de la responsabilidad etica, social y profesional del im-	
		· · · · · · · · · · · · · · · · · · ·	71
	7.2.		71
			72
		7.2.2. Estudio económico	74
		Anexo II: Glorario: siglas v abreviaturas	75

# Índice de Figuras

R1.	Robot e Instrumentación utilizados durante el desarrollo del TFM	vii
R2.	Muestra de la aplicación de data augmentation a una imagen térmica de	
	un rescatista.	vii
R3.	Integracion de imagen termica y de profundidad, para generar un mapa	
	térmico 3d Local	viii
R4.	Curva de presicion del entrenamiento de la red neuronal para 110 epocas	viii
R5.	Inferencia de la imagen termica junto con la imagen RGB, que permite	
	identificar la alta eficacia del uso de imágenes térmicas para identificación	
	de personas	ix
R6.	Proceso de generacion de nubes de puntos en pasillo	xi
1.1.	Publicaciones Wos	1
2.1.	Triangulacion Laser	4
2.2.	Escaneo 3D de luz estructurada	5
2.3.	Escaneo 3D por Fotogrametria	5
2.4.	Escaneo 3D por Contacto	6
2.5.	Escaneo 3D Basada en pulsos	7
2.6.	Arena de competencia	11
2.7.	Zona amarilla	12
2.8.	Zona naranja	12
2.9.	Zona roja	13
2.10.	Casos de victima	13
2.11.	Simulacion de victima	14
2.12.	Ejemplo de conjuntos de datos de nubes de puntos que representan objetos	
	de entornos de cocina	14
2.13.	Tecnicas de adquisicion de datos	15
2.14.	Nubes de puntos escala de grises	16

2.15.	Regiones de interés en un conjunto de datos de nube de puntos, represen-	
	tadas mediante diferentes etiquetas de clase y colores	16
2.16.	Representaciones híbridas de modelos de superficie de puntos, creadas ajus-	
	tando primitivas geométricas 3D al conjunto de datos de nube de puntos y	
	triangulando puntos de clúster residuales	17
3.1.	Calibración cámara térmica	20
3.2.	Proceso de calibración	21
3.3.	Adquisición de imágen térmica	21
3.4.	Imagen térmica y profundidad	23
3.5.	Giro del robot para capturar imágenes de profundidad e imágenes térmicas.	25
3.6.	Imágenes de profundidad	26
3.7.	Creacion y Procesamiento Nube de puntos	26
3.8.	Concatenación de nube de puntos	29
3.9.	Montaje de camara termica y kinect en Robot Jaguar V4	30
3.10.	Integracion de imagen termica y de profundidad, para generar un mapa	
	térmico 3d Local	31
3.11.	Imagen termica	31
3.12.	Valores de profundidad	31
3.13.	Valores de profundidad	32
3.14.	Valores de ICP de mapeado del Laboratorio	32
3.15.	Concatenación de nubes de puntos del Laboratorio	35
3.16.	Concatenación de nubes de puntos del Laboratorio Robcib	36
3.17.	Concatenacion de nubes de puntos del Laboratorio	37
3.18.	Valores de ICP de mapeado del pasillo	37
3.19.	Concatenación de nubes de puntos del Pasillo	38
3.20.	Concatenación de nubes de puntos del Pasillo	39
3.21.	Concatenación de nubes de puntos del Pasillo	40
3.22.	Valores de ICP de mapeado de la Nave	40
3.23.	Concatenación de nubes de puntos de la Nave	43
3.24.	Concatenación de nubes de puntos de la Nave	44
3.25.	Concatenación de nubes de puntos de la Nave	45
3.26.	Concatenación de nubes de puntos de la Nave	46
3.27.	Concatenación de nubes de puntos de la Nave	47
4.1.	Adquisicion de imagen termica	51
4.2.	Muestra de la aplicación de data augmentation a una imagen térmica de	
	una víctima	53
4.3.	Muestra de la aplicación de data augmentation a una imagen térmica de	
	un rescatista	53

4.4.	Funcion de perdida	54
4.5.	Presicion con mas entrenamiento	54
4.6.	Val recall	54
4.7.	Valor de presición	55
4.8.	Val call	55
4.9.	Imagenes RGB y Térmicas, se puede validar en este caso una simulación de	
	corte de energía, la cámara RGB deja de aportar información y la térmica	
	muestra su eficacia	56
4.10.	Validación en el CAR Arena de la red neuronal, identifiacción de Víctimas	
	y Rescatista	57
4.11.	Validación Exteriores	57
4.12.	Validación CAR Arena	58
4.13.	Imagen térmica y RGB a diferentes angulos de giro del robot	59
5.1.	Proceso de generación de nubes de puntos en NAVE	61
5.2.	Proceso de generación de nubes de puntos en pasillo	62
5.3.	Proceso de generación de nubes del Laboratorio Robcib	63
5.4.	Test execution and data visualization for localization	64
5.5.	DARPA Subterranean Challenge	65
7.1	Diagrama de Gantt, planificación Temporal	73

# Índice de Tablas

2.1.	Tecnicas de escaneo 3D	7
3.1.	Movilidad del robot.	24
3.2.	Datos de nube total Laboratorio Robcib	33
3.3.	Datos de nube total Pasillo planta baja CAR	34
3.4.	Datos de nube total Nave	41
7.1.	Planificación proyecto	72
7.2.	Coste Proyecto	75

# Introducción

El capítulo recopila los antecedentes, justificación e importancia del presente trabajo. Además de una breve descripción del proyecto y la estructura del documento.

#### 1.1. Antecedentes

Los robots de busqueda y rescate han tenido gran relevancia en los ultimos años, por el hecho que un robot puede entrar donde un rescatista o un perro no y recabar informacion valiosa de su entorno para ayudar en las tareas de salvamento. Los escenarios pos-desastre, resultado de sucesos naturales tales como terremotos, huracanes, o atentados, generan como resultado zonas o ciudades completa-mente debastadas, con edificaciones total o parcialmente colapsadas, escombros, etc.

Producen ademas altas perdidas economicas y lo sobre todo, la muerte de personas atrapadas por las estructuras y escombros generados por estos desastres. Los espacios de acceso reducidos generados como tuneles y las estructuras en riesgo de colapso representan un riesgo muy alto para los socorristas y equipo de primera linea durante las misiones de busqueda y rescate en entornos post-desastre. La 1.1 vemos el aumento de publicaciones en Wos acerca de los robots de busqueda y rescate, los cuales son desde 1999 hasta 2020 teniendo un aumento del 36 % entre cada año. Siendo un tema en augue existen varias



Figura 1.1 Publicaciones Wos.

competencias donde se busca premiar a los mejores metodos de busqueda y rescate mediante robots colaborativos o individuales, mediante una serie de camaras y sensores, para tener una amplia informacion del entorno a buscar. Una de las principales competencias es el DARPA Subterranean Challenge, donde un grupo de robots o robots se interna en una cueva con el fin de localizar a victimas en el entorno a escanear.

#### 1.2. Justificación e Importancia

Como se mensiono en el apartado anterior, los robots de busqueda y rescate tienen el fin de ayudar a las personas y rescatistas luego de un evento catastrofico. Por ejemplo en el el grupon de investigación CRASAR ayudo con robots de busqueda y rescate en el atentado del 11 de septiembre del 2001. El mapeo de ambientes catastroficos es una gran ventaja para los diferentes grupos de rescate para localizar a las diferentes victimas, y con ello se puede adaptar diferentes tipos de sensores o camaras, como camaras rgb, termicas, ultrasonicos, etc. El acoplamiento de distintos sensores y camaras dan mejor resultados para saber el estado de las personas, el mapeo con camaras termicas tienen una ventaja en frente a las demas, por no depender de luz artificial y natural, y cuentan con diferentes tipos de palets para utilizarlos en diferentes aplicaciones.

#### 1.3. Objetivos

El objetivo principal del proyecto consiste en desarrollar un algoritmo capas de crear una nube de puntos la cual abarque el area escaneada y la localización de victimas en dicha area.

- 1. Integración de sistemas sensoriales bajo Ros
- 2. Integración de cámara térmica bajo Ros
- 3. Integracion de nubes de puntos e imagen termica
- 4. Detectar victimas en entornos de catastroficos
- 5. Localización de víctimas en mapa térmico

#### 1.4. Descripción general del proyecto

El presente proyecto consiste en la localización de víctimas en zonas de desastre, para ello se elaboro un mapa 3d por medio de imagenes térmicas y de profundidad. La localización de las victimas se realizo el entrenamiento de una red neuronal con un datashet de varias zonas de desastre como en exteriores e interiores para obtener un mejor

resultado.

La toma de imágenes se realiza mediante una cámara térmica OPTRIS 690 y un sensor Kinect V1, montados en un robot móvil JAGUAR V4, dicho robot fue manupulado de forma remota. El tratamiento y generación de las nubes de puntos se realiza offline, luego de un escaneo completo del area a escanear, se procesa y elige las mejores imáges para realizar el mapa 3d. Una vez elaborado el mapa 3d y con el dato adquirido del entrenamiento de la red neuronal mediante images térmicas obtenemos la ubicación de la víctima en el mapa.

#### 1.5. Estructura del documento

El proyecto se compone de los siguientes capitulos:

- Introducción: en este capítulo se explica la temática global del proyecto, para entender el problema y por ende su justificación. Se detalla los objetivos y una breve descripción del proyecto.
- Estado del Arte: se detalla el estudio teórico para la realización del presente proyecto. Se contemplan investigaciones, proyectos, productos que tengan relación con el tema. De tal manera, se establece una guía para el diseño e implementación.
- Generación de mapas termicos: se explica el algorítmo la programación realizada de la estructura y sus herramientas, la jerarquía entre clases y la interacción entre módulos en función del diseño.
- Entrenamiento de Red: En este apartado se procede al entrenamiento de la red neuronal utilizada para la localización de víctimas y rescatistas en zonas de desastre.
- Resultados y discusión: En este apartado se procede a los resultados obtenidos en las diferentres pruebas hechas para el mapeo 3d con la camara termica.
- Análisis ético y profesional: se realiza un análisis del impacto del trabajo final en el aspecto ético y profesional.
- Conclusiones: en este capítulo se detallan las conclusiones a partir de los resultados finales y sus respectivos análisis tanto técnicos, cómo éticos, Además de las posibles mejoras y cambios que se pueden realizar..
- Anexos: se presenta la planificación del proyecto, el cual se presenta en un diagrama de gant. También, el presupuesto requerido para la realización del proyecto.

# Estado del Arte

#### 2.1. Diferentes tipos de métodos de escaneo 3D

Los principios en los que se basan son los siguientes:

#### 1. Tecnología de escaneo 3D de triangulación LÁSER.

La triangulación trigonométrica para capturar con precisión una forma 3D como millones de puntos. Los escáneres láser funcionan proyectando una línea láser o varias líneas sobre un objeto y luego capturando su reflejo con un solo sensor o varios sensores 2.1. Los sensores están ubicados a una distancia conocida de la fuente del láser. A continuación, se pueden realizar mediciones puntuales precisas calculando el ángulo de reflexión de la luz láser. Incluyen unidades portátiles de mano, rastreadores basados en brazo, basados en CMM, de largo alcance y de un solo punto de largo alcance.[5]

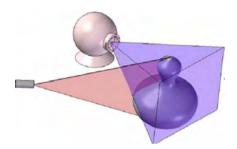
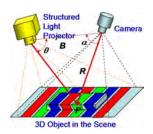


Figura 2.1 Triangulacion Laser [1]

#### 2. Tecnología de escaneo 3D de luz estructurada.

Estos escaneres utilizan luz proyectada LED azul o blanca. Estos escáneres 3D proyectan un patrón de luz que consiste en barras, bloques u otras formas sobre un objeto. El escáner 3D tiene uno o más sensores que miran el borde de esos patrones o formas estructurales para determinar la forma 3D del objeto 2.2. Utilizando el mismo método de triangulación trigonométrica que los escáneres láser, se conoce la distancia entre los sensores y la fuente de luz.[6]



**Figura 2.2** Escaneo 3D de luz estructurada [6]

3. Fotogrametría. La fotogrametria consiste en unir fotografías de un objeto tomadas desde diferentes ángulos 2.3. Las fotos se toman con una cámara o incluso con su teléfono inteligente con configuraciones de cámara específicas, mientras que la unión de esas fotos se realiza mediante un software especial. El software identifica los píxeles que corresponden al mismo punto físico y reúne las imágenes en consecuencia. Los parámetros como la distancia focal de la lente y su distorsión deben ser introducidos en el software por el usuario para crear un modelo preciso.[3]

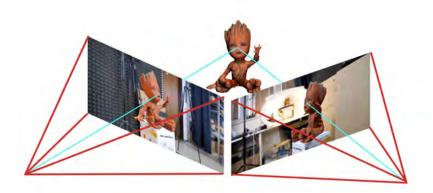


Figura 2.3 Escaneo 3D por Fotogrametria [3]

4. Tecnología de escaneo 3D basada en contacto. Esta tecnologia de escaneo se basa en el contacto físico de una sonda sobre la superficie del objeto que se escanea[10]. Primero, el objeto se sujeta firmemente en su lugar para que no se mueva. Luego, la sonda táctil se mueve por todo el objeto para recopilar los detalles del objeto y toda la información 3D que es necesaria para crear un archivo digital 2.4. A veces, se utiliza un brazo articulado para controlar la sonda táctil y capturar múltiples ángulos / configuraciones con un alto nivel de precisión. Las superficies transparentes y reflectantes se pueden escanear con precisión utilizando este método.

Se utiliza de manera interesante para realizar controles de calidad en la fabricación industrial.



**Figura 2.4** Escaneo 3D por Contacto [10]

5. Tecnología de escaneo 3D basada en pulsos LÁSER. Los escáneres 3D de largo alcance vienen en dos formatos principales: basado en pulsos y cambio de fase, ambos muy adecuados para objetos grandes como edificios, estructuras, aviones y vehículos militares. Los escáneres 3D de cambio de fase también funcionan bien para necesidades de escaneo de rango medio, como automóviles, bombas grandes y equipos industriales.

Basados en pulsos: Los escáneres láser basados en pulsos, también conocidos como escáneres de tiempo de vuelo, se basan en un concepto muy simple: la velocidad de la luz se conoce con mucha precisión. Por lo tanto, si se conoce el tiempo que tarda el láser en alcanzar un objeto y reflejarse en un sensor, se conoce la distancia desde el sensor al objeto. Estos sistemas utilizan circuitos que tienen una precisión de picosegundos para medir el tiempo que tardan millones de pulsos del láser en regresar al sensor y calcular una distancia. Al girar el láser y el sensor (generalmente a través de un espejo), el escáner puede escanear hasta 360 grados completos alrededor de sí mismo.[7]

Desplazamiento de fase: Los sistemas de desplazamiento de fase láser son otro tipo de tecnología de escáner 3D de tiempo de vuelo y funcionan conceptualmente de manera similar a los sistemas basados en pulsos. Estos sistemas también modulan la potencia del rayo láser y el escáner compara la fase del láser enviado y devuelto al sensor. Las mediciones de desplazamiento de fase suelen ser más precisas y silenciosas, pero no son tan flexibles para el escaneo de largo alcance como los escáneres 3D basados en pulsos. Los escáneres 3D basados en pulsos láser pueden escanear objetos a una distancia de hasta 1000 m, mientras que los escáneres de desplazamiento de fase son más adecuados para escanear objetos de hasta 300 o menos.[7]



**Figura 2.5** Escaneo 3D Basada en pulsos [19]

La tabla 2.1 vemos una comparación de los diferentes tipos de tecnicas de escaneo 3d, dependiendo de la aplicación podemos elegir el mejor metodo de escaneo que necesitemos.

No.	Tipo	Hardware	Tiempo requerido	Costo	Presicion/ Resolucion	Aplicaciones
1	Triangulacion laser	Laser,camara , procesador	Alto	Bajo	Medio	Entretenimiento, Arqueoligia
2	Luz Estructurada	Projector, 2 camaras	Bajo	Alto	Alto	Forense, Face Id
3	Fotogrametria	Camara, Procesador	Bajo	Bajo	Bajo	Mapeo topologico, Arqueologia
4	Basada en contacto	Sonda de Medicion	Alto	Alto	Alto	Objetos transparentes y reflectantes
5	Pulso Laser	Laser, Detector Laser	Alto	Bajo	Alto	Objetos Largos, escaneo de area

**Tabla 2.1** Tecnicas de escaneo 3D [4]

#### 2.2. Procesamiento de datos tridimensionales

El procesamiento de los datos tridimensionales es el trabajo que se realiza como tal sobre los mismos con el objetivo de obtener un resultado determinado. Muchas de las técnicas de procesado pueden llevarse a cabo independientemente del origen de los datos y tienen diversos objetivos. Desde la mejora de los datos capturados mediante diversos algoritmos, hasta la obtención de información de relevancia de acuerdo al objetivo. A continuación se realiza un breve repaso sobre algunas de las técnicas más importantes de procesamiento de datos tridimensionales y que son utilizadas durante las pruebas de concepto.

#### 2.2.1. Filtrado de datos

El proceso de filtrado consiste en la selección de un subconjunto de los datos el cual se considera que es el que aportará información relevante respecto al objetivo final. Por lo cual se borra cualquier otro dato fuera del rango deseado reduciendo el conjunto de datos con el que trabajar. Existen múltiples formas de realizar el proceso de filtrado, tanto manuales como semi-automáticas o automáticas. Los criterios de filtrado pueden ser muy diversos y dependen en gran medida de la información que pueda proporcionarnos el dispositivo de captura utilizado. De esta forma, se puede realizar filtrado por posición,

por color o por veracidad de los datos por mencionar algunos. Otro de los procesos de filtrado más importante es el muestreo cuyo objetivo es la selección de los datos más significativos de la muestra independientemente de si se ha realizado ya un proceso de filtrado previo o no. Un ejemplo de filtrado de nubes de puntos es "Deformable Filter Convolution for Point Cloud Reasoning" [20]. El objetivo final del proceso de filtrado es que la cantidad de datos disponible sea la menor posible con la mayor relevancia posible y menor pérdida de información posible.

#### 2.2.2. Suavizado de superficies

El proceso de suavizado es muy importante cuando la nube de puntos obtenida es muy ruidosa o cuando está compuesta de múltiples capturas que no han sido alineadas perfectamente. Cuando una nube de puntos está obtenida de esta forma, las superficies de los objetos capturados suelen presentar defectos por lo que conviene procesarlas de forma que se reduzca el ruido de la captura. [13]

#### 2.2.3. Alineado

El proceso de alineado consiste en unificar bajo un mismo sistema de referencia varias capturas. Por norma general, los algoritmos desarrollados para este proceso suelen trabajar identificando puntos correspondientes entre las diferentes capturas y encontrando la transformación de rotacion y traslacion necesaria que minimiza la distancia entre el conjunto de puntos correspondientes. El proceso suele repetirse hasta que el error es menor que un determinado umbral. Para aumentar la precisión del alineado, suele utilizarse uno o varios elementos marcadores a la hora de capturar la escena de forma que sean fácilmente diferenciables y puedan establecerse con total seguridad como puntos correspondientes entre las diferentes capturas.

#### **ICP**

Uno de los algoritmos más utilizados es el ICP (Iterative Closest Point) del cual existen multitud de variantes como la descrita en "Evaluation of the ICP Algorithm in 3D PointCloud Registration" [12]. El algoritmo ICP tiene como entrada dos nubes de puntos. Una de ellas es considerada la referencia y se mantiene estática mientras que la otra es transformada para alcanzar el mejor alineamiento con la referencia. Puede incluirse de manera opcional una estimación inicial de la transformación necesaria para alinear las dos nubes de puntos. Por otra parte es necesario incluir una condición de parada para el algoritmo. Hecho esto, la secuencia de ejecución es la que sigue:

 Para cada punto de la nube de referencia, encontrar el punto más cercano en la nube a transformar.

- Estimar la combinación de rotación y traslación necesarias utilizando una función de mínimos cuadrados para calcular el error de forma que la alineación entre los puntos correspondientes encontrados en el paso anterior sea la mejor posible.
- Transformar la nube de puntos. Este proceso se repite hasta que se cumplen los criterios de parada especificados.

#### Odometria

Se denomina odometría visual al proceso de estimación del movimiento del robot rotación y translación con respecto a un marco de referencia mediante la observación de una secuencia de imágenes tomadas de su entorno. Las características de las imágenes se obtienen mediante la detección de esquinas, y posteriormente se buscaba correspondencias a lo largo de las líneasepipolares, utilizando correlación cruzada. Realizaron una investigación basada en el uso de odometría visual en vehículos terrestres que navegaban por entornos al aire libre. [18]

Se represeta el ciclo que realiza continuamente el algoritmo de odometría visual durante el mapeado:

- Adquisición de dos fotografias (RGBD) consecutivos con la cámara del entorno.
- Detectar patrones o características distinguibles de la primera fotografia mediante alguno de los métodos obtención de puntos característicos.
- Relacionar dichas características en la segunda imagen utilizando una correlación cruzada normalizada.
- Cálculo del máximo desplazamiento de píxeles de entre todas las características de ambas fotografias.
- Una vez medido tanto el desplazamiento vertical como el horizontal de los píxeles, se transforman estas coordenadas de imagen en coordenadas de cámara.
- Se trasladan estas coordenadas del plano de la cámara al mapa que se está creando utilizando los parámetros de calibración de la cámara.
- Se estima la posición y distancia del robot (con la cámara incorporada) respecto al mapeado y se vuelve al paso inicial.

#### 2.2.4. Segmentado

El proceso de segmentado consiste en dividir la nube de puntos en diferentes zonas. Los algoritmos de segmentado son especialmente útiles cuando una nube de puntos está compuesta de varias regiones aisladas, casos en los que realizar este proceso permite romper

la nube en sus partes constituyentes que pueden ser procesadas de forma independiente. El caso más habitual de aplicación práctica de esta técnica es el del reconocimiento de objetos.

#### 2.3. Robots moviles para busqueda y rescate

Los robots de rescate se dieron a conocer de forma internacional despues de las 9:15 am, el 11 de Septiembre del 2001 (desplome de las torres gemelas), Lieutenant Colonel John Blintch empezo a organizar un grupo de robots de busqueda y rescate, con la mission de visitar la zona desvastada para buscar sobrevivientes del atentado. El equipo de profesionales lo conformaban Blintch director del Centro de Robots Asistidos de Busqueda y Rescate (CRASAR) en Colorado, Robin Murphy una profesora de ingenieria de la Universidad del Sur de Florida (USF), Foster-Miller y iRobot equipos de produccion de robots y Navy robot lab Space y Naval Warfare Systems Command (SPAWAR).

La combinacion de tecnologia que estos grupos de robotica ofrecian era: iluminacion, sonido, comunicacion eficiente, videos en coloe e infrarojo, posicionamiento global, mapeado y sonal, deteccion biologica y quimica. Con todas estas herramientas y un equipo de voluntarios lograron encontrar mas de 10 personas, mas del 2 porciento de victimas descubiertas.

#### 2.4. Redes neuronales

#### 2.4.1. CNN

La CNN es un tipo de Red Neuronal Artificial con aprendizaje supervisado identifica distintas características en las entradas. Para ello, la CNN contiene varias capas ocultas especializadas y con una jerarquía: esto quiere decir que las primeras capas pueden detectar lineas, curvas y se van especializando hasta llegar a capas más profundas que reconocen formas complejas como un rostro o la silueta de un animal.

Una de las aplicaciones de la red neuronal CNN en tareas de busqueda y rescate, es [15] en el cual usan una CNN para la localización de personas en el mar para taréas de rescate marítimo. Otra aplicacion es de [2] en la cual usan la misma red neuronal para la localizacion de victimas o personas perdidas en la montaña donde las temperaturas con muy bajas. Estas aplicaciones se dan gracias a la implementacion de camaras termicas donde la radiacion termica del cuerpo humano ayuda a destacarlos en ambientes extermos o de poca visibilidad.

#### 2.5. Entornos de desastre

Los entornos mostrados acontinuacion son una recopilacion de las competencias de Rescue Robot como Defense Advanced Research Projects Agency (DARPA), Rescue Robot Competitions at the American Association for Artificial Intelligence (AAAI) y the International Joint Conference on Artificial Intelligence (IJCAI), teniendo al como Institute of Standards and Tecnology (NIST) como entidad reguladora de las arenas de competencia.[8].

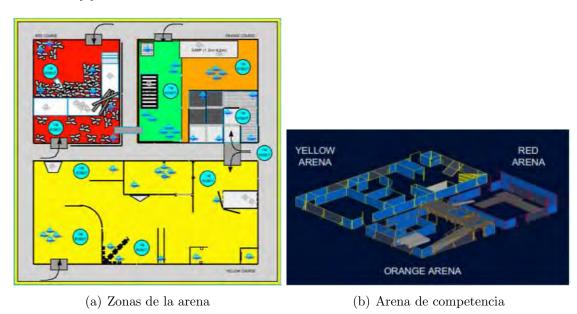


Figura 2.6 Arena de competencia

La figura 2.6 (b) muestra una imagen en 3d de toda la arena y las diferentes secciones de dicha arena 2.6 (a) reguladas por el NIST [21], la arena consiste en tres secciones de dificultad:

- Zona amarilla La arena amarilla es la de mas baja dificultad con puertas, persianas y obstaculos simples de sortear, el laberinto puede reconfigurarse facilmente [8]. Los investigadores utilizan robots no agiles para probar su percepcion sensirial, mapeo o algoritmos de planificacion para explorar la zona amarilla en su totalidad [8]. El laberinto con consiste en una pista plana de un solo material como las oficinas de una empresa [21]. La imagen 2.7 (a) es la zona amarilla estandarizada por NIST en varias competencias y la imagen 2.7 (b) es la zona amarilla de la competencia realizada en el National Museum Emerging Science and Innovation (MeSci) en Japon.
- Zona naranja La arena naranja es de dificultad media con diferentes materiales para el piso. Existe una seccion con piso elevado accesible atravez de rampas o escaleras que requiere una agilidad considerable para maniobrar. Los robots deben mapear en su totalidad el laberinto para trazar la planificar su camino atraves de la



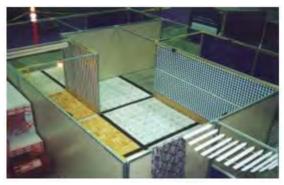


(a) Zona amarilla NIST

(b) Zona amarilla MeScl

Figura 2.7 Zona amarilla [8]

arena [8]. La arena se puede reconfigurar en tiempo real mediante colapsos, puertas y persianas. La diferencia de culturas se puede apreciar en la figura 2.8 (a) por la utilización de persianas, alfombras y baldosas, mientras que en la figura 2.8 (b) tenemos los tipicos tatamis y materiales de pared.



(a) Zona naranja NIST



(b) Zona naranja MeScl

Figura 2.8 Zona naranja [8]

■ Zona roja La arena roja es la arena de mayor dificultad con una estructura menor a las otras arenas y con facilidad de modificar la arena con facilidad simulando un segundo derrumbe. El piso de la arena es inestable y dificil de maniobrar por la diferencia de materiales que existen como: plasticos, varillas de hierro, madera, etc.[21] Los objetos a encontrar se encuentran bajo los escombros de un derrumbe simulado.[21] La diferencias culturales de la arena NIST son los materiales de construccion hechos de hormigon con los materiales de construccion de madera de la arena de MeSci, esto se puede ver en figura 2.9 (a) y la figura 2.9 (b).





(a) Zona roja NIST

(b) Zona roja MeScl

Figura 2.9 Zona roja [8]

#### 2.6. Simulación de victimas

El objetivo de cada robot al recorrer las diferentes arenas es la localizacion de victimas simuladas, cada victima simulada era un maniqui el cual simulava varios rasgos de una persona real como: emision de calor corporal, sonidos(gemidos, gritos, golpes), emision de dioxido de carbono (simulacion de respiracion). La combinacion de de estas firmas sensoriales implica el estado de la victima: inconsiente, semiinconsiente o consciente.[9] La figura 2.10 vemos los diferentes casos de una victima simulada, es colocada en una situacion de rescate particular y distribuida por todo el ambiente en aproximadamente los mismo lugares en terremotos reales con porcentajes: (50 %) superficie, (30 %) ligeramente atrapada, (15 %) vacia 0 (5 %) sepultada.[8]







Figura 2.10 Casos de victima [9]

En las competencias se intodujo etiquetas de identificacion de victimas que generalmente se colocan en areas de dificil acceso alrededor de cada victima y requieren un robot de movilidad avanzada para acceder a identificarlos. Tambien se colocaron etiquetas en posibles lugares donde pueda estar una victima, para inspirar busquedas enfocadas en el area con multiples sensores. [9]

Por lo general, una vez localizada la victima, los robots necesitan determinar la ubicación, situación, estado y etiqueta de identificación de la victima, y luego informar de sus

hallazgos en un mapa legible por humanos.[9]

La figura 2.11 es el maniqui que se usa para la simulación de victimas el cual tiene: un tanque de emisión de C02, un altavoz para simulación de sonidos, brazos y piernas a la vista dependiendo la dificultad de la arena (amarilla, naranja y roja), una bolsa caliente para emisión de calor corporal y la etiqueta de la victima.



Figura 2.11 Simulación de victima [9]

#### 2.7. Mapeo 3D de entornos

La unidad de representación de datos más primitiva en un espacio euclidiano tridimensional es el propio punto 3D. La Figura 2.12 presenta ejemplos de colecciones muy precisas de puntos 3D que representan objetos que se encuentran en ambientes interiores.



Figura 2.12 Ejemplo de conjuntos de datos de nubes de puntos que representan objetos de entornos de cocina

[17]

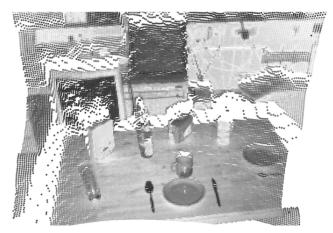
## 2.8. Adquisicion de datos

Las nubes de puntos representan el formato de datos de entrada básico para los sistemas de percepción 3D y proporcionan representaciones discretas pero significativas del mundo circundante. Sin ninguna pérdida de generalidad, las coordenadas  $x_i, y_i, z_i$  de cualquier punto  $p_i \in P$  se dan con respecto a un sistema de coordenadas fijo, que generalmente tiene su origen en el dispositivo sensor utilizado para adquirir los datos. Esto significa que cada punto  $p_i$  representa la distancia en los tres ejes de coordenadas definidos desde el punto de vista de la adquisición hasta la superficie en la que se ha muestreado el punto. [17]

Aunque hay muchas formas de medir distancias y convirtiéndolos en puntos 3D, los dos enfoques más utilizados son:

- Sistemas de tiempo de vuelo (TOF), que miden el retraso hasta que una señal emitida golpea una superficie y regresa al receptor, estimando así la distancia real desde el sensor a la superficie.
- Técnicas de triangulación, que estiman distancias mediante la conexión de correspondencias vistas por dos sensores diferentes al mismo tiempo. Para calcular la distancia a una superficie, los dos sensores deben calibrarse entre sí, es decir, deben conocerse sus propiedades intrínsecas y extrínsecas

La Figura 2.13 a) vemos un ejemplo de la adquisicion de datos por el sistema de tiempo de vuelo y la figura 2.13 b) vemos un ejemplo de la tecnica de triangulacion de un conjunto de datos de nubes de puntos adquiridos con una camara estereo: en un entorno texturizado (izquiera), en un entorno que carece de informacion de textura en ciertas regiones (derecha).



(a) Sistemas de tiempo de vuelo

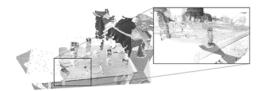


(b) Técnicas de triangulación

**Figura 2.13** Tecnicas de adquisicion de datos [17]

#### 2.9. Representación de datos

Un sistema de mapeo procesa y convierte los datos de la nube de puntos de entrada sin procesar en diferentes representaciones y formatos basados en los requisitos impuestos por cada paso de procesamiento individual. Un aspecto importante cuando se trata de representaciones de nubes de puntos es que pueden almacenar mucha más información que solo las posiciones 3D de los puntos adquiridas del dispositivo sensor de entrada. Por ejemplo, si los datos se han adquirido utilizando un sensor láser 2D, cada medición suele ir acompañada de un valor de remisión de superficie, que cuantifica la intensidad del rayo láser reflejado.[14] La Figura 2.14 presenta un ejemplo de un conjunto de datos de nube de puntos adquirido usando un sensor láser 2D inclinable, mostrado en escala de remisión usando colores monocromáticos.



**Figura 2.14** Nubes de puntos escala de grises [14]

Los pasos de procesamiento, como la segmentación de la nube de puntos y la agrupación en clústeres, pueden funcionar directamente en los datos de la nube de puntos sin procesar y proporcionar propiedades adicionales como salidas para cada punto. Por ejemplo, en el contexto de una aplicación que requiere que los planos de la mesa de apoyo estén segmentados y marcados en la nube de puntos, y los grupos de objetos que se encuentran en estos planos se agrupen en un sentido euclidiano, cada punto  $p_i \in P$  recibirá una propiedad adicional que toma los valores de la nueva clase asignada.[17] La Figura 2.15 presenta un ejemplo de anotaciones de puntos y colorea cada punto según la etiqueta de clase recibida, como tablas con verde claro, grupos de objetos que soportan con un color aleatorio y todos los puntos restantes están marcados con negro.

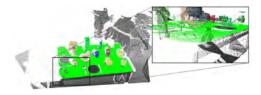


Figura 2.15 Regiones de interés en un conjunto de datos de nube de puntos, representadas mediante diferentes etiquetas de clase y colores.

[17]

Una solución para segmentar superficies geométricas primitivas en P con el fin de proporcionar aproximaciones de datos más suaves, utilizando formas 3D como cilindros,

planos, esferas, conos, etc. Para cada grupo de objetos como los presentados en la Figura 2.16, el sistema Primero puede intentar ajustar una forma geométrica primitiva, luego usar mallas triangulares para modelar los puntos restantes. El resto de los datos en P se pueden dejar como puntos y etiquetar como tales, proporcionando así una verdadera representación híbrida de la escena, utilizando una multitud de formatos: puntos, modelos geométricos y mallas triangulares.

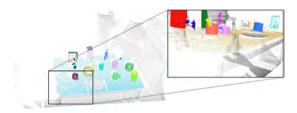


Figura 2.16 Representaciones híbridas de modelos de superficie de puntos, creadas ajustando primitivas geométricas 3D al conjunto de datos de nube de puntos y triangulando puntos de clúster residuales.

[17]

## Generación Automática de Mapas Térmicos 3D y localización de víctimas

## 3.1. Adquisición de datos de profundidad e imágenes térmicas

Previo a la adquisición de datos de profundidad e imágenes térmicas, debemos calibrar la cámara térmica para poder trabajar en video o imagen de dicha cámara.

## 3.1.1. Calibración de equipos

Cámara Térmica: Algunas camaras introducen una distorsión significativa en las imagenes. Dos tipos principales de distorsión radial y la distorsión tangencial.

La distorsión radial hace que las líneas rectas parezcan curvas. La distorsión radial aumenta a medida que se alejan los puntos del centro de la imagen.

$$x_{distorcion} = x(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) (3.1)$$

$$y_{distorcion} = x(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) (3.2)$$

De manera similar, la distorsión tangencial se produce porque la lente que toma de imágenes no está alineada perfectamente paralela al plano de imagen. Por lo tanto, es posible que algunas áreas de la imagen parezcan más cercanas de lo esperado. La cantidad de distorsión tangencial se puede representar de la siguiente manera:

$$x_{distorcion} = x + [2p_1xy + p_2(r^2 + 2x^2)]$$
(3.3)

$$y_{distorcion} = y + [p_1(r^2 + 2x^2) + 2p_2xy]$$
(3.4)

En resumen, necesitamos encontrar cinco parámetros, conocidos como coeficientes de distorsión dados por:

$$Distortion coefficients = (k1, k2, p1, p2, k3)$$

$$(3.5)$$

Además de esto, necesitamos alguna otra información, como los parámetros intrínsecos y extrínsecos de la cámara. Los parámetros intrínsecos son específicos de una cámara. Incluyen información como la distancia focal (fx, fy) y los centros ópticos (cx, cy). La distancia focal y los centros ópticos se pueden usar para crear una matriz de cámara, que se puede usar para eliminar la distorsión debida a las lentes de una cámara específica. La matriz de la cámara es única para una cámara específica, por lo que una vez calculada, puede reutilizarse en otras imágenes tomadas por la misma cámara. Se expresa como una matriz de 3x3:

$$\begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix}$$
 (3.6)

La calibración de la cámara térmica Optris de uso el método de [23] el cual consiste en registrar las esquinas de un tablero de ajedrez y mediante código, obtener las variables de matriz fundamental 3.6, vectores de traslación y rotación 3.5, antes explicadas, para ello se calento unas hojas de papel con perforaciones en forma de tablero de ajedrez, y se ajusto la cámara térmica en el palet White-Hot, con el fin de registrar los puntos caracteristicos de cada esquina del tablero de ajedrez. Una vez desarrollado el codigo de calibración obtenemos los valores deseados, la figura 3.1 muestra los bordes del obtejo a calibrar (tablero de ajedrez), la matriz fundamental de la camara termica 3.7, vector de distorsión 3.8, matriz de rotación 3.9, y la matriz de traslación 3.10 dicha calibración se obtuvo un error de distorsión del 0.38487294716991416

$$\begin{bmatrix} f_x = 458,41626958 & 0 & c_x = 327,15150492 \\ 0 & f_y = 457,27416629 & c_y = 213,86162691 \\ 0 & 0 & 1 \end{bmatrix}$$
(3.7)

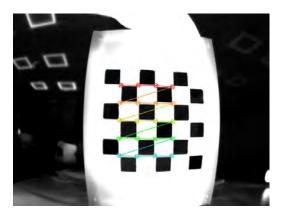


Figura 3.1 Calibración cámara térmica.

$$\begin{bmatrix} -0.63118568 & 0.89263329 & 0.02207553 & -0.00361449 & -1.11144398 \end{bmatrix}$$
 (3.8)

$$\begin{bmatrix}
-0.01884591 \\
0.05737353 \\
-0.40815257
\end{bmatrix}
\begin{bmatrix}
-0.14199782 \\
-0.02233268 \\
0.02366859
\end{bmatrix}$$
(3.9)

$$\begin{bmatrix}
-2,68330769 \\
-1,10260326 \\
12,13103857
\end{bmatrix}
\begin{bmatrix}
-0,92708789 \\
-1,36752316 \\
9,63877082
\end{bmatrix}$$
(3.10)

## 3.1.2. Rectificación de imágenes

Luego de obtener la matríz fundamental, vector de distorsión, traslación y corrección, obtenemos la nueva matríz de corrección con la libreria cv2.getOptimalNewCameraMatrix apartir de dicho proceso sacamos el mapa de distorsión para rectificación de la imagen con cv2.initUndistortRectifyMap con la nueva matríz de rectificación y la matríz fundamental de la calibración. Una vez obtenido el mapa de distorsión provectamos dicho mapa con una imágen de prueba con cv2.remap.

# 3.2. Procesamiento y Transmisión de Imágenes térmica mediante OpenCV y ROS

- Instalación de drivers y complementos de ROS y optris
- Generación de parametros iniciales generiz.xml
- Habilitación de puerto usb para camara termica sudo rmmod uvevideo; sudo modprobe uvevideo nodrop=1

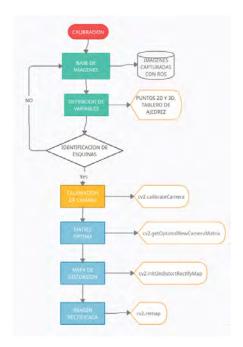


Figura 3.2 Proceso de calibración.

- Lanzamiento de nodo con parámetros genericos rosrun optris drivers optris imager node
  - xmlConfig:=/home/guido/catkin ws/src/optris drivers/config/generic.xml
- Obtención de video de cámara térmica con Palette Hot heat, sin autoregulación de temperatura, temperatura minima de 20 y máxima de 40 (rosrun optris drivers optris colorconvert node palette:=6 paletteScaling:=1 temperatureMin:=20 temperatureMax:=40)

La figura 3.3 muestra la adquisición de imáges térmicas.



Figura 3.3 Adquisición de imágen térmica.

# 3.3. Integración de cámara térmica y de profundidad con ROS

La adquisición de imágenes para la creación de nube de puntos se realizo mediante ros.

A continuación se detalla el proceso para efectuarlo:

## Lanzamiento de nodos para Cámara térmica

- sudo rmmod uvcvideo; sudo modprobe uvcvideo nodrop=1
   Subscribir el puerto serial de camara termica al COM 1
- rosrun optris.drivers optris.imager.node .xmlConfig:=
   /home/guido/catkin.ws/src/optris.drivers/config/generic.xml
   Corremos los parametros genericos de calibracion de la camara termica generados
   en la instalacion generic.xml
- 3. rosrun optris.drivers optris.colorconvert.node .palette:=6 .paletteScaling:=1 .temperatureMin:=20 .temperatureMax:=40 Corrermos el nodo de camara termica con el palette 6 (Iron heat), descativando el auto escalado de temperatura (paletteSaling:=1), temperatura minima de 20 (.temperatureMin:=20) y tempratura maxima de 40 (.temperatureMax:=40)

#### Lanzamientos de sensor Kinect

 roslaunch freenect.launch depth.registration:=true
 Lanzamos el nodo freenect del sensor Kinect y activando los diferentes registros de la imagen de profundidad.

Una vez lanzados los nodos para la adquisición de imágen térmica y de profundidad, procedemos con la adquisición de imágenes.

## 1. Subscripción de nodos:

rospy.wait.for.message ('/thermal.image.view', Image) nodo de cámara térmica rospy.wait.for.message('/camera/depth.registered/hw.registered/image.rect.raw', Image) nodo de camara de profundidad rectificada.

#### 2. CV.BRIDGE:

Para el punte entre Ros y el procesamiento de imagenes usamos cv.bridge, para las imágenes térmicas usamos el formato RGB y para imagenes de profundidad pasthrought (Sin conversion de imagen).

## 3. Procesamiento de Imagenes de profundidad:

## Declaración de imagen como flotante

Declaramos las imagenes adquiridas como flotante para el post procesamiento (np.array(Imagen.profundidad, dtype=np.float))

## Normalización de imágenes de profundidad

Normalizamos las imagenes de 0 a 255 para la generación de nubes de puntos cv2.normalize(image.profundidad, image.profundidad, 0,255, cv2.NORM.MINMAX)

## 4. Procesamiento de Imagenes térmicas:

#### Nueva Matriz de camara

Obtener nueva matriz óptima de cámara térmica, mediante la matríz fundamental y rotación de la cámara térmica obtenidos dichos valores en la calibración de la cámara y las dimensiones de la imagen (ancho y alto), cv2.getOptimalNewCamera

## Mapa rectificado sin distorsion

El nuevo mapa sin distorsión lo obtenemos mediante cv2.initUndistortRectifyMap, por medio de la antigua matriz fundamental y la nueva matriz obtenida anterior mente, el mismo proceso lo realizamos con el vector de rotación.

#### Remaping de imagen

El remapin de la imagen es la proyección de la imagen rectificada mediante el mapa rectificado sin distorsión (cv2.remap)

## 5. Guardar Imagenes:

Guardamos las imágenes procesadas de camara térmica y camara de profundidad, mediante cv2.imwrite (ubicacion donde guardar las imagenes, el tipo de imagen a guardar)

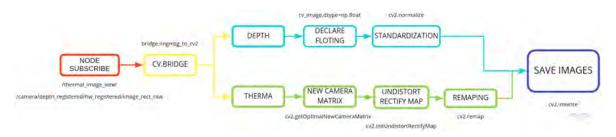


Figura 3.4 Imagen térmica y profundidad.

Tabla 3.1 Movilidad del robot.

Ángulo de giro	Velocidad angular	Velocidad lineal	
Aligulo de giro	(rad/seg)	(ms)	
30	0.15	0.2	

## 3.4. Requerimientos

Para llevar a cabo el mapeo automático, se requieren establecer los siguientes parámetros, de tal manera que se minimice el error al generar mapas locales y el mapa global, a continuación se muestran los requerimentos establecidos en base a la experimentación:

## 3.4.1. Movilidad del Robot

La tabla 3.1 describe la velocidad lineal y ángular, ángulo de giro en el cual el robot se movilizaba

## Ángulo de giro del robot

El ángulo de giro minimo del robot es 30 grados, en la figura 3.5 vemos la adquisicion de imagenes de la cámara térmica mientras gira el robot.

## 3.4.2. Toma de imagenes

## Fallo de imagen

La adquisición de imagenes de profundidad tienen ciertas limitantes:

- Velocidad de toma de imágen
- Perdida de imágen
- Variación de imágenes en distintas posiciones

Las imagenes se tomaron cada segundo y se normalizo de 0-255, pero por la velocidad de procesamiento de la imagen tenemos perdida de datos en cada imágen, la solución fue elegir la mejor imagen de cada posición y procesarla para realizar el trabajo, como observamos en la figura ??.

## 3.5. Adquisición y Procesamiento de nubes de puntos

La generación de nubes de puntos se da atraves de la libreria open3d [22], con los parametros intrínsecos obtenidos de la calibración de la camara termica, imagen de profundidad de la kinect v1 y la imagen de la rectificada de la camara termica.

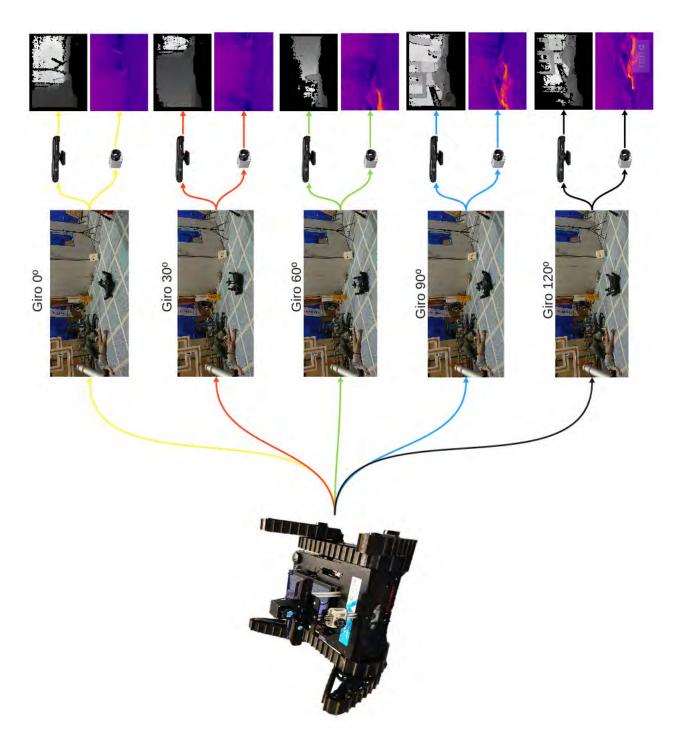


Figura 3.5 Giro del robot para capturar imágenes de profundidad e imágenes térmicas.



Figura 3.6 Imágenes de profundidad.

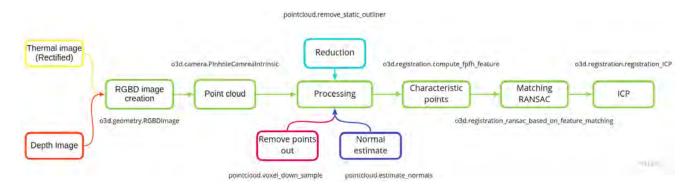


Figura 3.7 Creacion y Procesamiento Nube de puntos.

La figura 3.7 vemos el proceso de creación y procesamiento de la nube de puntos, la base es la imágen térmica rectificada, la imagen de profundidad y los parámetros intrínsecos de la cámara térmica.

Acontinuación detallamos los pasos de la figura 3.7:

## 1. Crear de imagen RGBD:

La libreria a usar es open3d.geometry.RGBDImage.create.from.color.and.depth, cuyas entradas son (imagen de profundidad y imagen termica)

## 2. Crear de Nube de puntos

La libreria a usar es o3d.camera.PinholeCameraIntrinsic, cuyas entradas son (imagen RGBD y los parametros intirnsecos de la camara (matriz fundamental obtenida de la calibración stereo))

Los pasos anteriores se refieren a la creación de la nube de puntos.

Acontinuación vamos a detallar el procesamiento de dichas nubes y el proceso para ICP

## 1. Remover puntos:

Este proceso es para eliminar los puntos fuera de la nube de puntos mediante la libreria pointcloud.remove.statical.outliner, cuyas entradas son (selección de vecinos cercanos y un radio minimo)

## 2. Reducción de nube de puntos:

Reducimos la nube de puntos para manejar nubes del mismo tamaño, con pointcloud.voxel.down.sample con la entrada (el valor a reducir la nube de puntos)

### 3. Estimación de las normales:

Necesitamos estimar las normales para obtener los puntos característicos de cada nube de puntos, para ello usamos pointcloud.estimate.normals con las siguientes entradas (el metodo a usar en nuestro caso fue

open3d.geometry.KDTreeSearchParamthhibrid (con el cual nombramos el radio de busqueda y el máximo de vecinos a buscar))

## 4. Puntos caracteristicos:

Los puntos característicos los usamos para hacer matching con el metodo de RAN-SAC y ocupamos la libreria

open3d.registration.compute.fpfh.feature con las entradas (nube de puntos, radio de busqueda y el máximo de vecinos)

## 5. Emparejamiento de puntos característicos:

Para el emparejamiento de los puntos característicos de dos nubes de puntos usamos

el metodo de RANSAC para ello usamos la librería open3d.registration.registration.ransac.based.on.feature.matching con las siguentes entradas:

- Nubebase.voxel.down nube base reducida
- Nubebase.fpfh puntos característicos de nube base
- Nubetarget.voxel.down nube target reducida o segunda nube
- Nubetarget.fpfh puntos característicos de nube target
- Threshold maxima distancia entre nubes
- Método de estimación
- Fit.ransac
- Criteria de emparejamiento (maxima.iteración y maxima.validación)

### 6. **ICP**:

El ICP lo realizamos con la libreria open3d.registration.registration.ICP con los siguiente parametros de entrada

- Nube base
- Nube a la que nos acoplamos
- Threshold umbral de rango de movimiento
- Matriz resultante de Emparejamiento de puntos característicos
- Tipo de estimación (PointtopPoint,PointtopPlane)

## Concatenación de nube de puntos

La figura 3.8 observamos el proceso de concatenación de nube de puntos, el cual describimos acontinuación.

- 1. Una vez obtenida la matriz ICP aplicamos transformación a la nube de target (target.transformation(ipc.transformation))
- 2. Almacenamos la nueb de puntos target con ICP y la nube base
- 3. Aplicamos los pasos anteriores para el procesamiento de la nueva nube de puntos Comb y aplicamos ICP entre la nube Comb y el nuevo target
- 4. Aplicamos la matriz de transformación al nuevo target
- 5. Almacenamos en una nueva matriz la nube Comb y new.target transformado, el proceso se repite hasta la ultima nube de puntos a obtener.

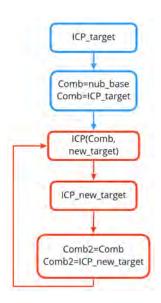


Figura 3.8 Concatenación de nube de puntos.

## 3.5.1. Adaptación del sistema a una plataforma robotica

La plataforma robótica (Jaguar V4) junto con la instrumentación: la cámara tármica, la kinect y el computador principal, se detallan en la figura 3.9, siguiendo los siguientes pasos:

## 3.5.2. Resultados de concatenación de nubes de puntos

La Figura 3.10 vemos la integracion de una imagen de profundidad con una imagen termica, por medio de las librerias de open3d.

Parametros de la imagen termica los podemos ver en la Figura 3.11, en los cuales tenemos una temperatura minima de 20 grados centigrados y una maxima de 40 grados centigrados, mejor representados al lado derecho de dicha imagen.

Los valores de profundidad maxima y minima de persepcion del sensor Kinect en la nube de puntos, lo vemos en la Figura 3.12, en la cual etiquetamos con puntos del 1 al 10, con un valor de 28 mm minimo y 83 mm de maximo de datos de profundidad, como vemos en la figura 4.5.

La tabla 3.2 describe los resultados del número de puntos en cada nube de puntos, el porcentaje de ICP entre cada nube de puntos y el mínimo y máximo de las coordenadas X,Y,Z de cada concatenación de nubes de puntos, la primera nube de puntos es el primer icp de dos nuebes de puntos.

La figura 3.14 es el resultado de la concatenación de nube de puntos y el ICP entre cada concatenación.

Las figura 3.15, 3.16 y 3.17 describe las imagenes de entrada para la creación de nubes de puntos y la concatenación entre ellas, una vez obtenida la nube concatenada o

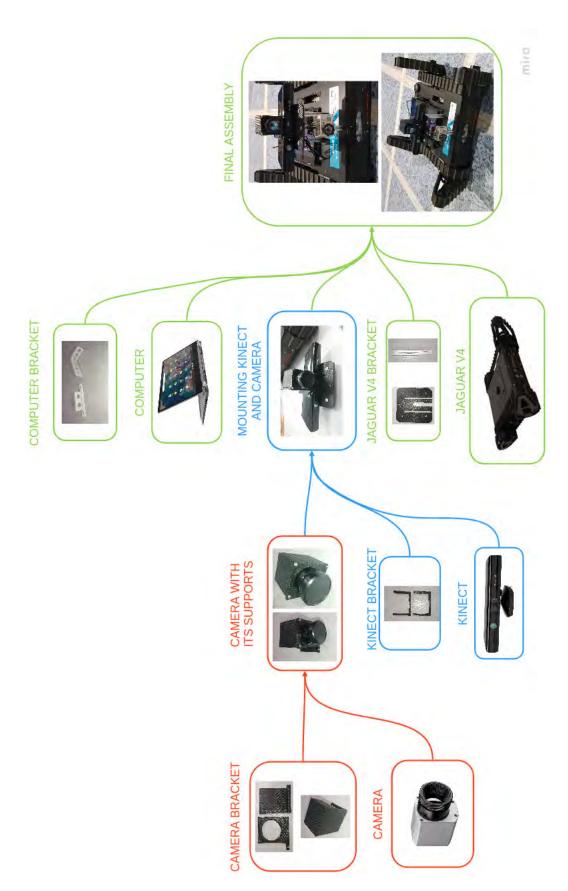


Figura 3.9 Montaje de camara termica y kinect en Robot Jaguar V4.

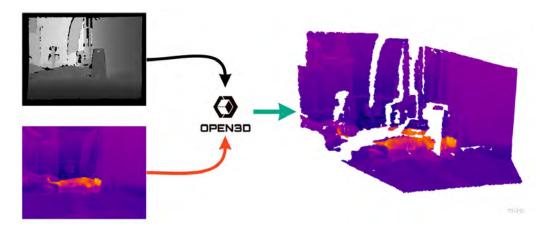


Figura 3.10 Integracion de imagen termica y de profundidad, para generar un mapa térmico 3d Local

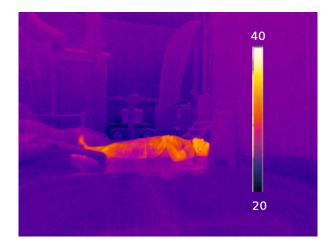


Figura 3.11 Imagen termica.

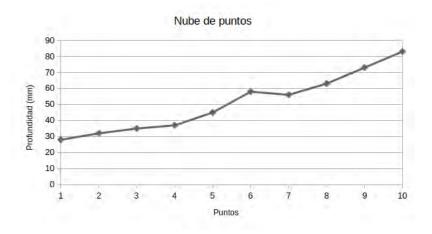


Figura 3.12 Valores de profundidad.

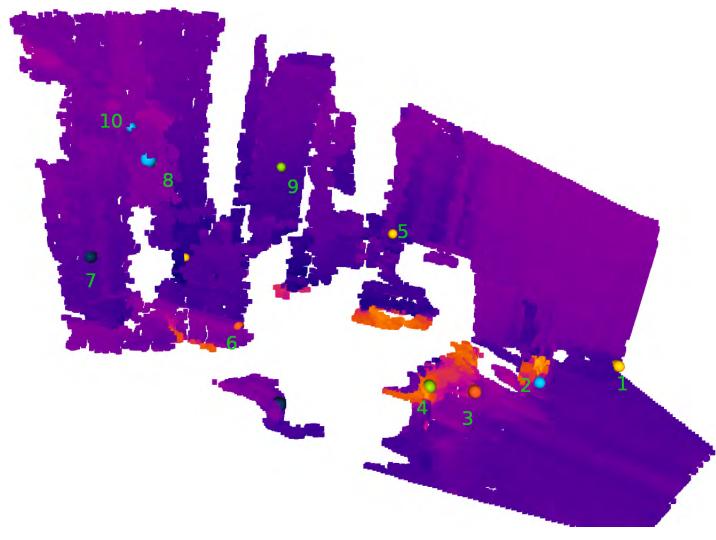


Figura 3.13 Valores de profundidad.

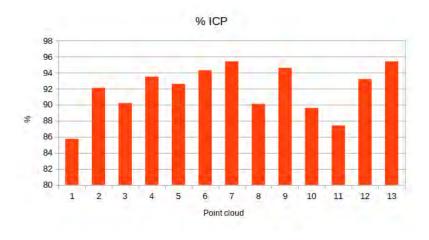


Figura 3.14 Valores de ICP de mapeado del Laboratorio.

Tabla 3.2 Datos de nube total Laboratorio Robcib.

Point cloud	Images	Points	% ICP	X,Y,Z (min,max)		
				X	Y	$\mathbf{Z}$
1	2	385868	85.74	(-0.22578875, 0.04596534)	(-0.10453029, 0.052261363)	(0.03945444, 0.31503266)
2	3	586889	92.1	(-0.2826026082, 0.04596534743)	(-0.1122396439, 0.05226136371)	(0.02035032, 0.31503266)
3	4	794060	90.2	(-0.2826026082, 0.0459653474)	(-0.11223964, 0.05437704)	(-0.043887581, 0.315032690)
4	5	1015257	93.5	(-0.282602608, 0.0459653474)	(-0.112239643, 0.054377041)	(-0.101530328, 0.315032690)
5	6	1218043	92.6	(-0.282602608, 0.045965347)	(-0.112239643, 0.054377041)	(-0.129639074, 0.31503269)
6	7	1431371	94.3	(-0.2826026082, 0.04596534743)	(-0.1122396439, 0.0543770417)	(-0.1296390742, 0.315032690)
7	8	1638043	95.4	(-0.282602608, 0.0459653474)	(-0.112239643, 0.054377041)	(-0.13511006, 0.31503269)
8	9	1846780	90.1	(-0.282602608, 0.0459653474)	(-0.112239643, 0.054377041)	(-0.13511006, 0.31503269)
9	10	2069730	94.6	(-0.282602608, 0.0527163445)	(-0.112239643, 0.054377041)	(-0.13511006, 0.31503269)
10	11	2264878	89.6	(-0.282602608, 0.0527163445)	(-0.112239643, 0.054377041)	(-0.13511006, 0.31503269)
11	12	2250620	87.4	(-0.282602608, 0.069837734)	(-0.112239643, 0.054377041)	(-0.13511006, 0.31503269)
12	13	2416492	93.2	(-0.282602608, 0.081097111)	(-0.112239643, 0.054377041)	(-0.13511006, 0.31503269)
13	14	2624830	95.4	(-0.282602608, 0.084412157)	(-0.112239643, 0.054377041)	(-0.13511006, 0.31503269)

combinada se saca el histograma de dicha nube de puntos en X,Y,Z.

La tabla 3.3 describe los resultados del número de puntos en cada nube de puntos, el porcentaje de ICP entre cada nube de puntos (figura 3.18) y el mínimo y máximo de las coordenadas X,Y,Z de cada concatenación de nubes de puntos, la primera nube de puntos es el primer icp de dos nuebes de puntos.

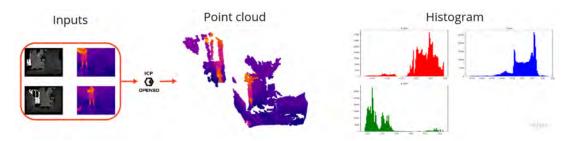
Point cloud	Images	Points	ICP	X,Y,Z (min,max)		
				X	Y	Z
1	9	270000	89.6	(-0.06634136,	(-0.08500213,	(0.031372550,
1	2	378082		0.06230792)	0.05201542)	0.35433334)
2	3	544300	90.1	(-0.06634136,	(-0.08500213,	(0.031372550,
2	)			0.07108443)	0.05387873)	0.37833333)
3	4	749050	88.5	(-0.06634136,	(-0.08500213,	(0.03137255,
3	4	742958		0.08383847)	0.05791484)	0.439578320
4	5	051274	02.6	(-0.06634136,	(-0.08500213,	(0.03137255,
4	9	951374	92.6	0.08579088)	0.05791484)	0.43957832)
5	6	1166216	94.5	(-0.06634136,	(-0.08500213,	(0.03137255,
3	О			0.08983149)	0.05791484)	0.45987343)
6	7	1374863	96.3	(-0.06634136,	(-0.08500213,	(0.03137255,
0	(			0.09196367)	0.06032590)	0.52262699)
7	8	1573516	88.4	(-0.06634136,	(-0.08500213,	(0.03137255,
'	8			0.09668313)	0.06563842)	0.54729110)
8	9	1767555	89.6	(-0.06634136,	(-0.08500213,	(0.03137255,
0	9			0.09668313)	0.06563842)	0.57035315)
9	10	1931435	87.4	(-0.06634136,	(-0.08500213,	(0.03137255,
9				0.09668313)	0.06563842)	0.57035315)
10	11	2133969	90.3	(-0.06634136,	(-0.08500213,	(0.03137255,
10	11			0.10481704)	0.06563842)	0.57035315)
11	12	2335496	92.5	(-0.06634136,	(-0.08500213,	(0.03137255,
11				0.10481704)	0.06563842)	0.57035315)
12	13	2539902	93.5	(-0.06634136,	(-0.08500213,	(0.03137255,
				0.10481704)	0.07374579)	0.62858891)

Tabla 3.3 Datos de nube total Pasillo planta baja CAR.

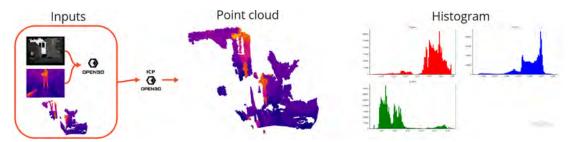
Las figura 3.19, 3.20 y 3.21 describe las imagenes de entrada para la creación de nubes de puntos y la concatenación entre ellas, una vez obtenida la nube concatenada o combinada se saca el histograma de dicha nube de puntos en X,Y,Z.

La tabla 3.4 describe los resultados del número de puntos en cada nube de puntos, el porcentaje de ICP entre cada nube de puntos (figura 3.22) y el mínimo y máximo de las coordenadas X,Y,Z de cada concatenación de nubes de puntos, la primera nube de puntos es el primer icp de dos nuebes de puntos.

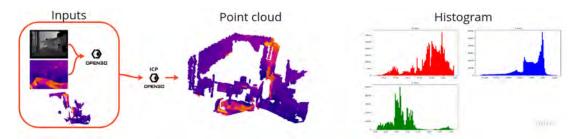
Las figura 3.23, 3.24 y 3.25 describe las imagenes de entrada para la creación de nubes de puntos y la concatenación entre ellas, una vez obtenida la nube concatenada o



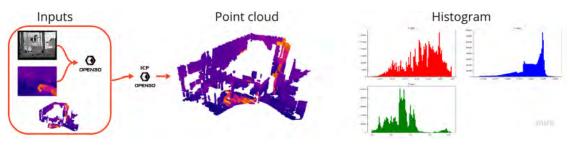
(a) Concatenación de nubes Laboratorio Robcib 1



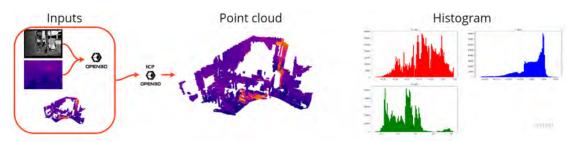
(b) Concatenación de nubes Laboratorio Robcib 2



(c) Concatenación de nubes Laboratorio Robcib 3

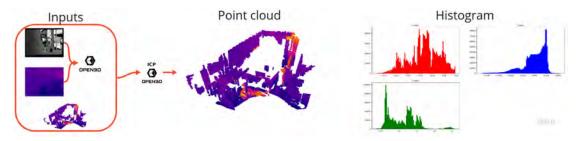


(d) Concatenación de nubes Laboratorio Robcib 4

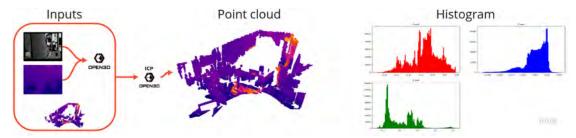


(e) Concatenación de nubes Laboratorio Robcib 5

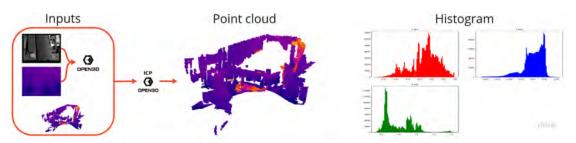
Figura 3.15 Concatenación de nubes de puntos del Laboratorio.



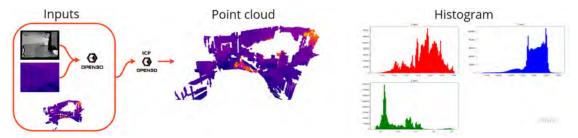
(a) Concatenación de nubes Laboratorio Robcib 6



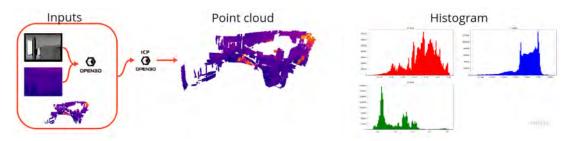
(b) Concatenación de nubes Laboratorio Robcib 7



(c) Concatenación de nubes Laboratorio Robcib 8



(d) Concatenación de nubes Laboratorio Robcib 9



(e) Concatenación de nubes Laboratorio Robcib 10

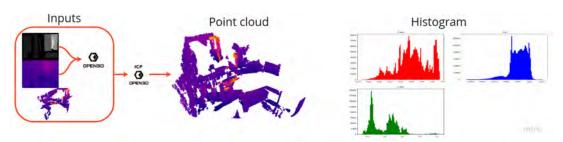
Figura 3.16 Concatenación de nubes de puntos del Laboratorio Robcib.



(a) Concatenacion de nubes Laboratorio Robcib 11



(b) Concatenacion de nubes Laboratorio Robcib 12



(c) Concatenacion de nubes Laboratorio Robcib 13

Figura 3.17 Concatenacion de nubes de puntos del Laboratorio.

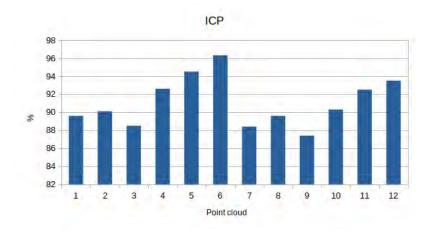


Figura 3.18 Valores de ICP de mapeado del pasillo.

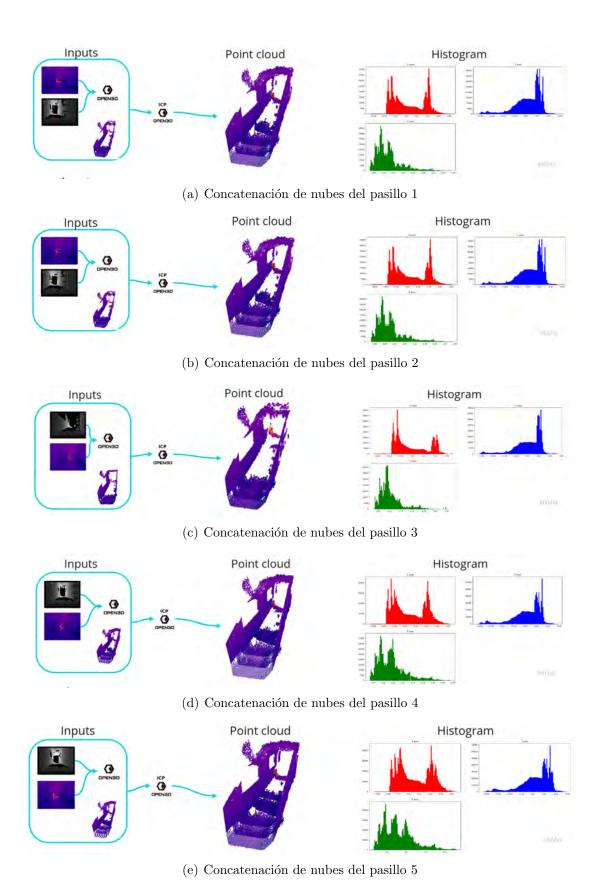


Figura 3.19 Concatenación de nubes de puntos del Pasillo.

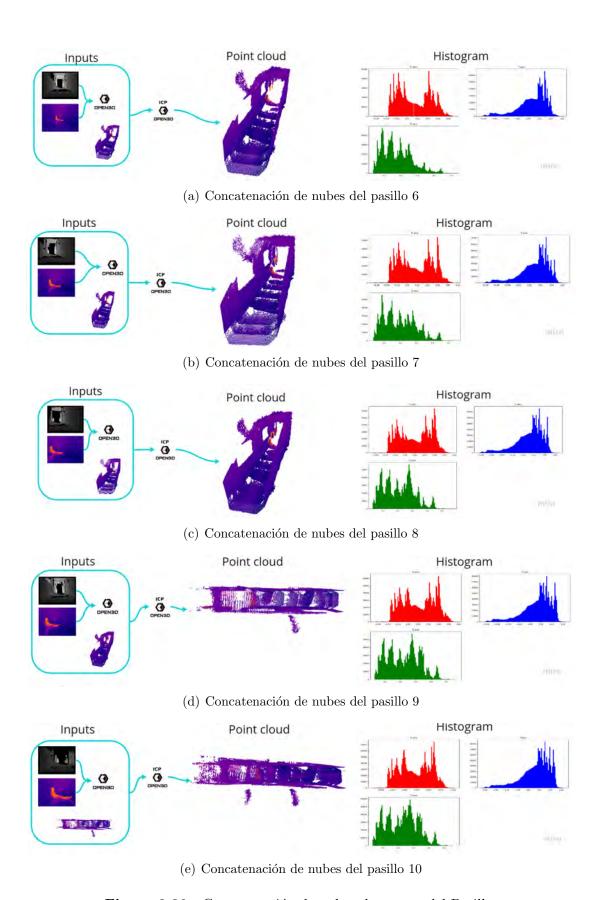


Figura 3.20 Concatenación de nubes de puntos del Pasillo.

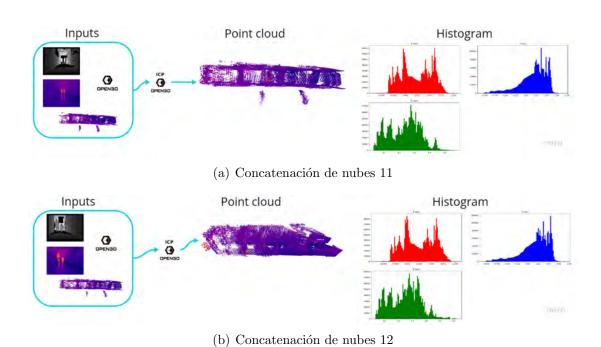


Figura 3.21 Concatenación de nubes de puntos del Pasillo.

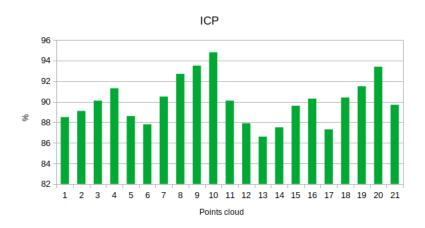


Figura 3.22 Valores de ICP de mapeado de la Nave.

Tabla 3.4 Datos de nube total Nave.

Point cloud	Images	Points	% ICP	X,Y,Z (min,max)		
				X	Y	Z
1	2	432516	88.5	(-0.11567910,	(-0.12189946,	(0.04323747,
1		452510	00.0	0.31308051)	0.04621907)	0.27114847)
2	3	609894	89.1	(-0.11567910,	(-0.12189946,	(0.02801179,
2	3	003034		0.31308051)	0.04920207)	0.27114847)
3	4	846777	90.1	(-0.11567910,	(-0.12769378,	(0.01406533,
3	4	040111		0.31308051)	0.04920207)	0.29103320)
4	5	1072094	91.3	(-0.11567910,	(-0.12769378,	(0.01174412,
	0	1012034	31.0	0.31308051)	0.05085112)	0.29504513)
5	6	1307255	88.6	(-0.11567910,	(-0.12769378,	(0.01174412,
	U	1001200	00.0	0.31308051)	0.05085112)	0.29504513)
6	7	1511905	87.8	(-0.11567910,	(-0.12769378,	(0.00853401,
	'	1011500	01.0	0.31308051)	0.05085112)	0.29504513)
7	8	1683523	90.5	(-0.11567910,	(-0.12769378,	(0.00853401,
		1000020	00.0	0.31308051)	0.05085112)	0.295045137)
8	9	9 1924684	92.7	(-0.11567910,	(-0.12769378,	(0.00853401,
		1021001	02.1	0.31308051)	0.05085112)	0.29504513)
9	10	2161782	93.5	(-0.11567910,	(-0.12769378,	(0.00853401,
	10	2101702	90.0	0.31308051)	0.05085112)	0.29504513)
10	11	2401940	94.8	(-0.11567910,	(-0.12769378,	(0.00853401,
		_101010		0.40739381)	0.05085112)	0.29504513)
11	12	2645056	90.1	(-0.11567910,	(-0.12769378,	(0.00853401,
		2010000	00.1	0.40739381)	0.05085112)	0.29504513)
12	13	2865852	87.9	(-0.11567910,	(-0.14489141,	(0.00853401,
			01.0	0.40739381)	0.05085112)	0.29504513)
13	14	3095092	86.6	(-0.11567910,	(-0.14489141,	(0.00853401,
				0.40739381)	0.05085112)	0.31122952)
14	15	15 3338212	87.5	(-0.11567910,	(-0.14489141,	(0.00853401,
				0.40739381)	0.05085112)	0.34215891)
15	16	3581818	89.6	(-0.11567910,	(-0.14489141,	(0.00853401,
				0.43033820)	0.05085112)	0.3586665)
16	17	3747882	90.3	(-0.11567910,	(-0.14489141,	(0.00853401, 0.35866665)
	18			0.45019200) (-0.11567910,	0.05085112) (-0.14489141,	(0.00853401)
17		3982299	87.3	0.50247442	0.05085112)	0.36616790
	19	4226592	90.4	(-0.11567910,	(-0.14489141,	(0.00853401)
18				0.53304231)	0.05085112)	0.36616790)
	20	4441642	91.5	(-0.11567910,	(-0.14489141,	(-0.12534587,
19				0.59267616	0.05085112	0.36616790)
	21	4642145	93.4	(-0.11567910,	(-0.15411624,	(-0.18678677,
20				0.62411952	0.05085112	0.36616790)
				(-0.11567910,	(-0.15411624,	(-0.20614857,
21	22	4813992	89.7	0.66031938)	0.05085112	0.36616790)
				0.00091990)	0.00000112)	0.90010190)

TRABAJO FINAL DE MÁSTER GENERACIÓN AUTOMÁTICA DE MAPAS TÉRMICOS 3-D E IDENTIFICACIÓN INTELIGENTE DE VÍCTIMAS MEDIANTE IMÁGENES TÉRMICAS EN ENTORNOS S.A.R. - GUIDO RAFAEL TORRES LLERENA

combinada se saca el histograma de dicha nube de puntos en X,Y,Z.

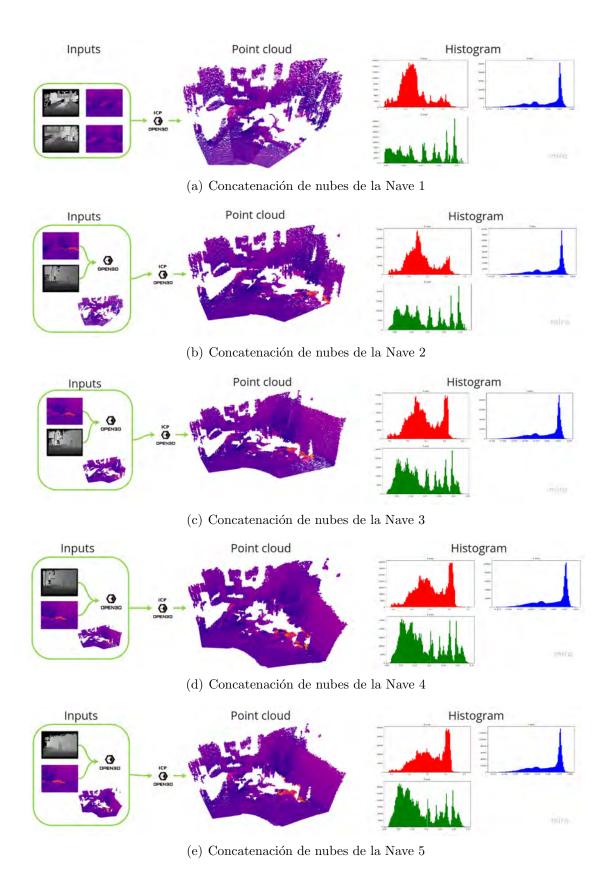


Figura 3.23 Concatenación de nubes de puntos de la Nave.

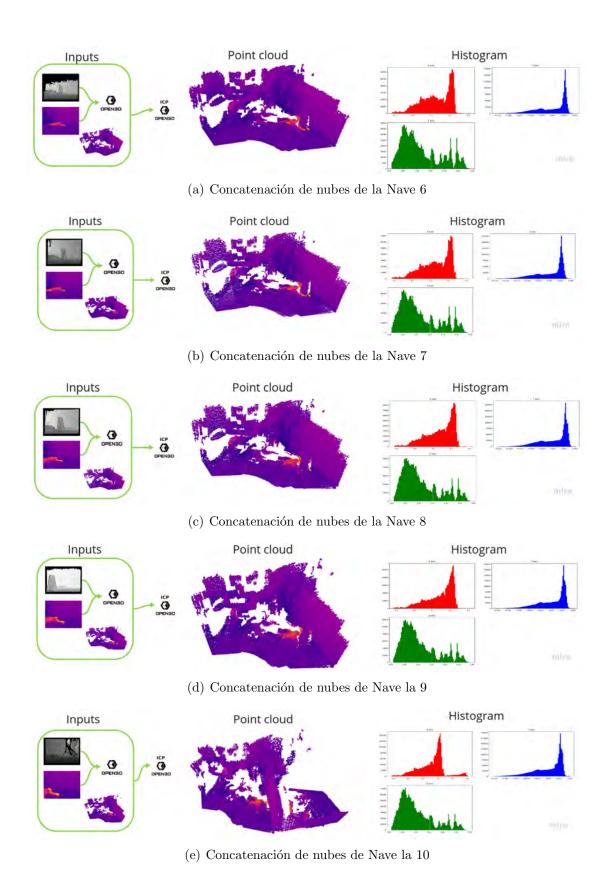


Figura 3.24 Concatenación de nubes de puntos de la Nave.

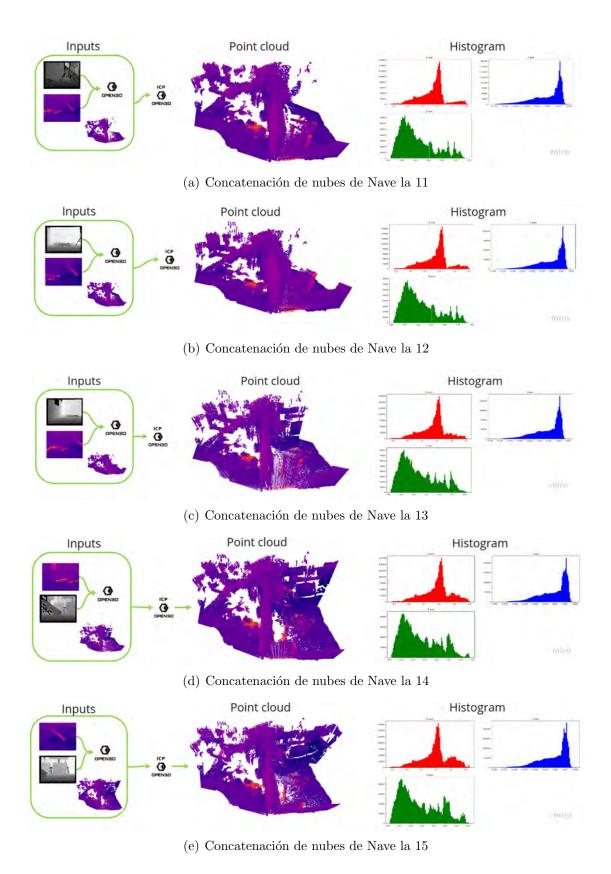


Figura 3.25 Concatenación de nubes de puntos de la Nave.

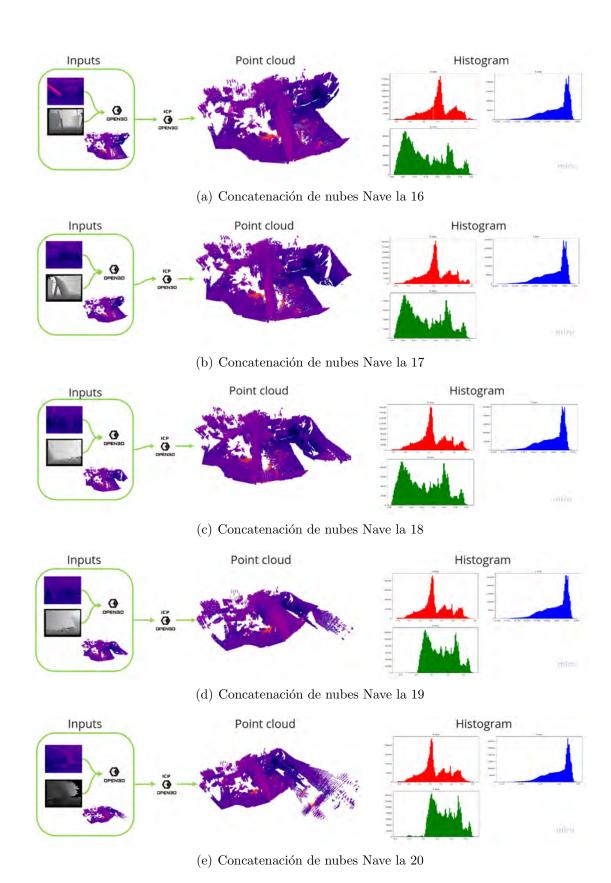
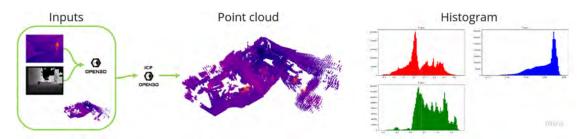


Figura 3.26 Concatenación de nubes de puntos de la Nave.



(a) Concatenación de nubes Nave la 21

Figura 3.27 Concatenación de nubes de puntos de la Nave.

## Detección de Víctimas mediante Redes Neuronales Convolucionales

## 4.1. Deteccion de victimas mediante Redes Neuronales Convolucionales

Una de las principales aportaciones de este trabajo destaca en la capacidad de detectar víctimas en un entorno de desastre mediante la red previamente entrenada, mediante la inspección de entorno utilizando un robot en campo con capacidad transmitir imágenes hacia una estación remota (E.R.O - Estación Remota del Operador), el robot en esta fase de experimentación del sistema es tele-operado desde una estación remota por un operador o rescatista previamente capacitado.

La transmisión de imágenes y el procesamiento se realizan en tiempo real en la E.R.O, de tal manera que el operador o rescatista puede saber a priori si existe una victima (pudiendo ser una persona totalmente inconsciente o atrapada entre escombros) que necesite de asistencia primaria) y su ubicación dentro del entorno en base a la posición del robot.

Esta implementación ha sido desarrollada bajo ROS (Robot Operating System), el cual se ha utilizado por su gran versatilidad y capacidad de integrar diferentes sistemas sensoriales, robots y llevar a cabo procesos en múltiples ordenadores, a través de su arquitectura de comunicaciones de nodos y tópicos.

El Robot utilizado para la exploración en el entorno de desastre ha sido el Jaguar V4, dotado de la cámara térmica y un sensor Kinect, en el robot esta montado los siguientes componentes:

- El ordenador a Lenovo Flex 5.
- Camara termica optris 640

### ■ Sensor kinect V1

El control de movimientos del robot en el entorno se ejecuta mediante la publicación de comandos de velocidad lineal y angular, mediante el tópico /cmd\_vel, por su parte el robot retransmite su posición dentro del entorno mediante el tópico /position. El flujo de estos datos se muestra en la figura 4.1. La estructura de los tópicos publicados es:

■ Transmisión de comandos de velocidad al robot:

```
/cmd_vel (geometry_msgs/Twist)
linear:
x: 0.1 (vel_lin)
y: 0.0
z: 0.0
angular:
x: 0.0
y: 0.0
z: 0.1 (vel_ang)
```

• Recepción de posición del robot:

```
/pose (geometry_msgs/Twist)
geometry_msgs/Vector3 linear
float64 x (Posición x)
float64 y (Posición y)
float64 z

geometry_msgs/Vector3 angular float64 x
float64 y
float64 z (Orientación)
```

Para la captación y posterior transmisión de imágenes térmicas y de profundidad desde la cámara y sensor kinect integradas en el robot se han instalado los drivers para ROS (en el ordenador Lenovo Flex) desarrollados por el fabricante y disponibles en: http://wiki.ros.org/optris\_drivers. La imagen se transmite mediante el tópico /image\_compressed, se ha utilizado la imagen comprimida, debido a que incrementa la taza de transmisión de fps y la pérdida de información no es significativa para el desarrollo del proceso.

La estructura del tópico de la imagen termica es:

• Recepción de imagen térmica:

/image\_compressed (sensor\_msgs/Image Message)

uint32 height uint32 width string encoding (Contiene los píxeles y canales de la imagen) uint8 is\_bigendian uint32 step uint8[] data

Para el procesamiento en tiempo real de la imagen recibida en la E.R.O, se ha instalado previamente en el ambiente de anaconda los paquetes de ROS de tal manera que con la red ya entrenada se pueda realizar la inferencia y detección de personas dentro en la imagen recibida como se muestra en la figura 4.1.

Para ello se ha desarrollado un algoritmo que recibe como entrada la imagen transmitida por el robot, a través de la suscripción al tópico correspondiente de ROS, se procesa mediante OpenCV para aplicar las respectivas correcciones a la imagen, operaciones de erosión, dilatación y eliminación de ruido. Finalmente se realiza la inferencia con la red entrenada y se establece si existe o no una víctima en la zona que inspecciona el robot. Este proceso se ejecuta de manera cíclica durante toda la inspección del entorno.

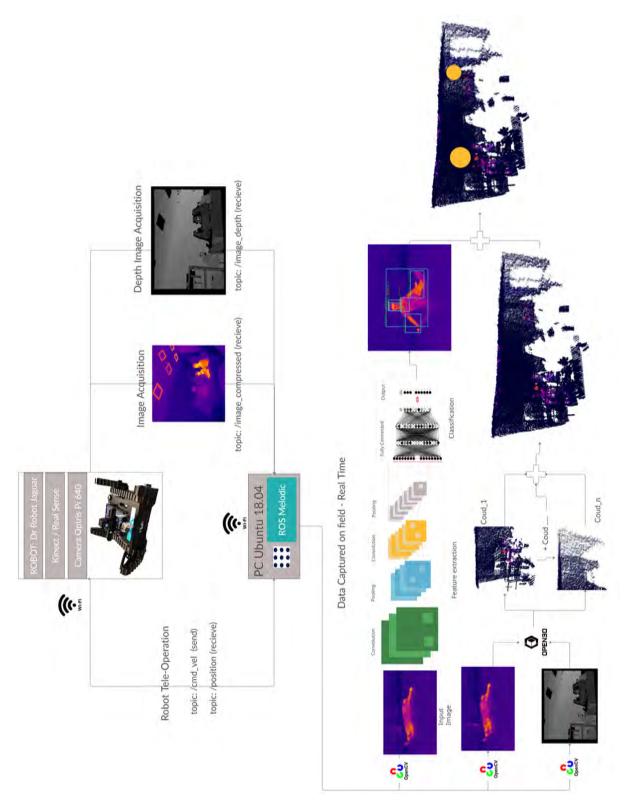


Figura 4.1 Adquisicion de imagen termica.

## 4.1.1. Entrenamiento de la red neuronal

### Generacion de datasets

La generacion de dataset se dio apartir de una toma de imagenes con ros en ambientes similares a [8], eligiendo las imagenes en donde existan victimas y rescatistas. La base de datos para el entrenamiento es de 1747 imagenes, con 7 etiquetas:

- Rescatista cuerpo
- Rescatista piernas
- Victima cuerpo
- Victima brazo
- Victima torso
- Victima piernas

La validación de la red se dio mediante una serie de imágenes tomadas posteriormente al entrenamiento de la red, con 2000 imagenes.

### Data Augmentation para incrementar la robustez de la Red

Para incrementar la robuzted de la red se aplico una serie de tratamientos a dichas imagenes como Ruido Gaussiano, Incremento de brillo, Reflejo Horizontal e Incremento de contraste, como lo vemos en las figuras 4.2 asi aumentamos nuestra base de datos y el reconocimiento de víctimas puede ser en entornos con diferentes ambientes, dichaa imagen fue tomada en el Laboratorio Robcib.

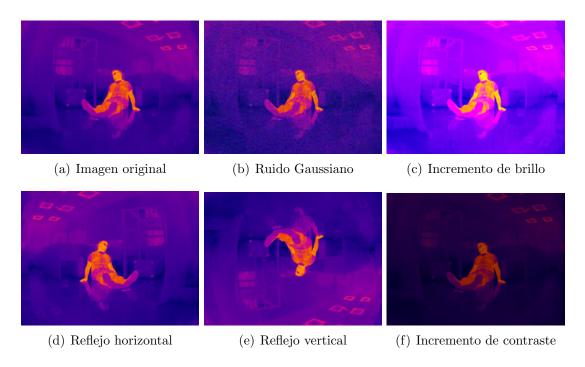
Como en la 4.2, la 4.3 se observa un par de rescatistas, para lo cual se realiza el mismo porcedimiento de tratamiento de imagen para aumentar la base de datos y asi mejorar, la validación del trabajo en distintos ambientes.

## Selección de los hiperparametros

El numero de epocas realizadas fueron de 120. La 4.4 representa la función de perdida o loss funtion. Esta permite saber como de alejadas estan las predicciones de un modelo y de sus etiquetas. Cada vez que decrece mejora su rendimiento.

La 4.5 muestra la curva de presición de nuestro modelo, la cual aumenta conforme sigue el tiempo de entrenamiento.

La 4.6 muestra la medida de nuestro modelo que identifica correctamente los verdaderos positivos, en cada epoca como resultado tenemos un recall=0.98.



**Figura 4.2** Muestra de la aplicación de data augmentation a una imagen térmica de una víctima.

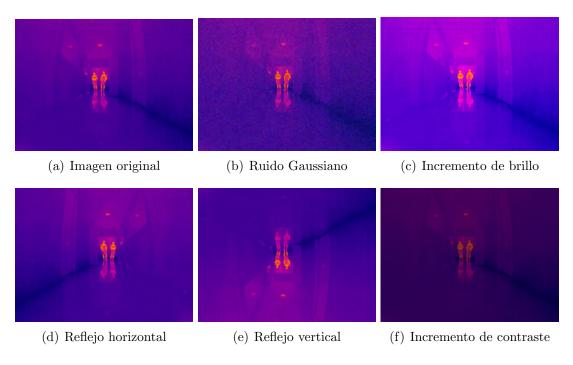


Figura 4.3 Muestra de la aplicación de data augmentation a una imagen térmica de un rescatista.

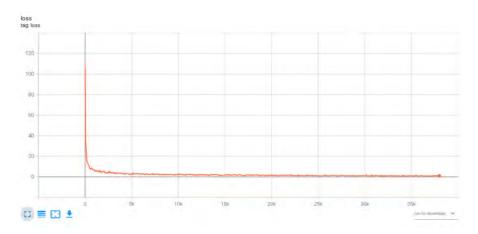


Figura 4.4 Funcion de perdida.



Figura 4.5 Presicion con mas entrenamiento.

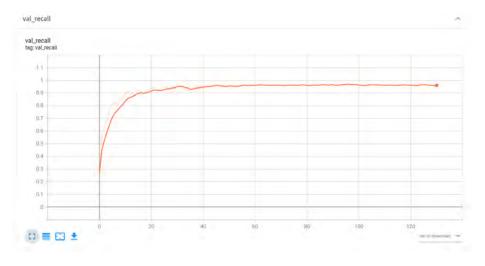


Figura 4.6 Val recall.

La 4.7 representa el valor final de la presición del entrenamiento de nuestro modelo el cual fue de un 98 % aproximadamente.

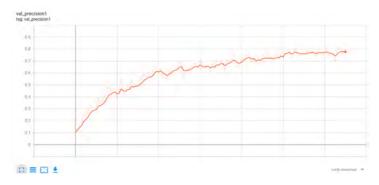


Figura 4.7 Valor de presición.

### 4.2. Validación

La 4.8 observamos una secuencia de imagenes termicas y RGB, en donde se simulo un corte de energia, en el cual vemos que las imagenes RGB pierden de vista en su totalidad cualquier datos de la imagen, mientras que en las imagenes termicas no influyen la luz artificial o natural.

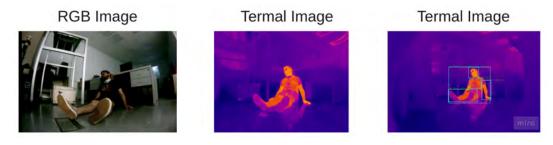


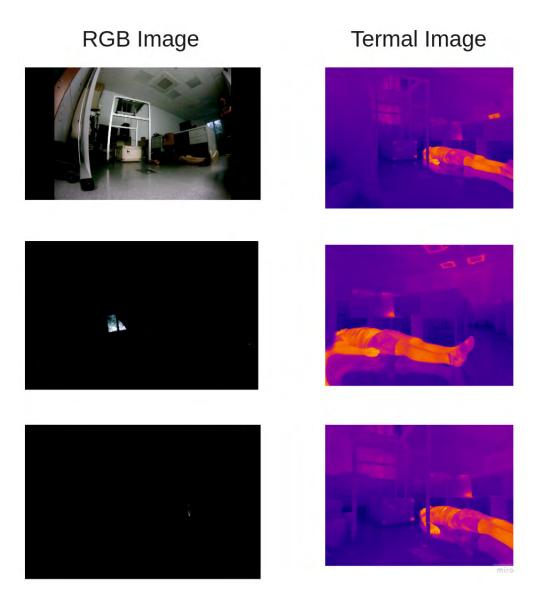
Figura 4.8 Val call.

La figura 4.10 describe la validación del entrenamiento de la red neuronal en el entorno de la nave, captando a victimas y rescatistas con una presicion de un  $98\,\%$ .

Las figura 4.11 se observa la detección de victimas en exteriores, con una presición del  $90\,\%$ 

La figura 4.12 describe la validación de víctimas y rescatitas en el pasillo de la planta baja del edificio del CAR

Las figuras 4.13 vemos una serie de imágenes termicas a la izquiera e imágenes RGB a la derecha, viendo asi la diferencia entre imágenes RGB y térmicas. Las imágenes térmicas tienen implementado la red neuronal para identificación de victimas.



**Figura 4.9** Imagenes RGB y Térmicas, se puede validar en este caso una simulación de corte de energía, la cámara RGB deja de aportar información y la térmica muestra su eficacia.

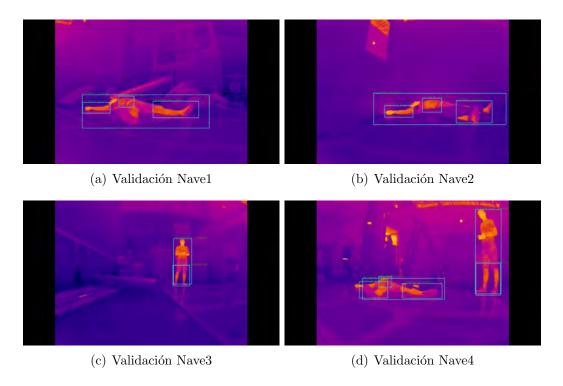


Figura 4.10 Validación en el CAR Arena de la red neuronal, identifiacción de Víctimas y Rescatista.

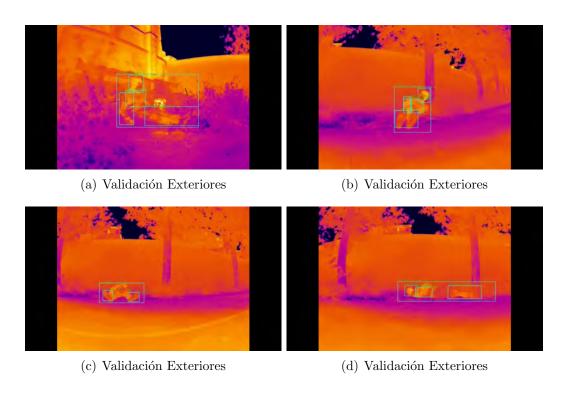


Figura 4.11 Validación Exteriores.

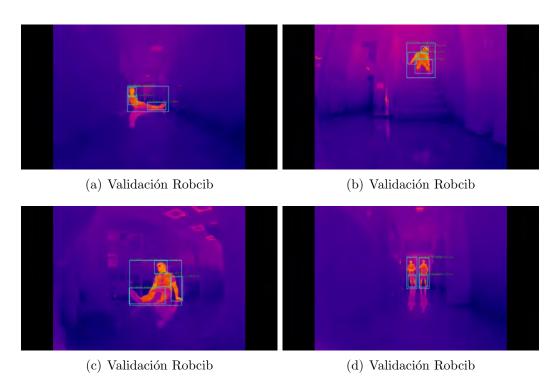


Figura 4.12 Validación CAR Arena.

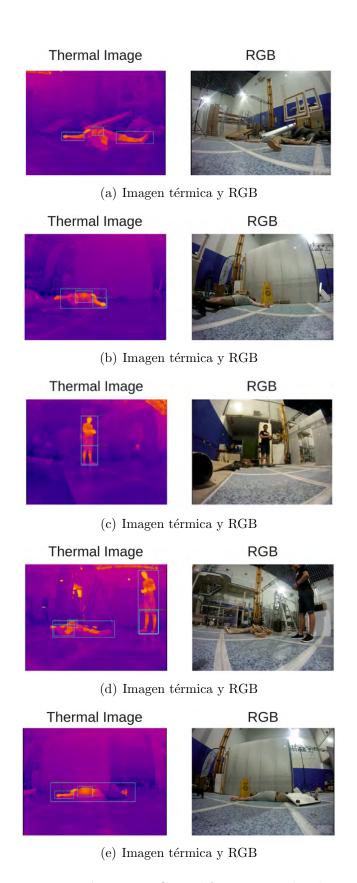


Figura 4.13 Imagen térmica y RGB a diferentes angulos de giro del robot.

# Pruebas y Resultados

# 5.1. Detección de víctimas mediante Redes Neuronales Convolucionales

### 5.1.1. Identificación de victimas en ambientes catastróficos

La 5.1 observamos el proceso general y detallado anteriormente de la generación del mapa térmico y la localización de victimas por medio de la red neuronal convolucional en las imagenes térmicas. Teniendo asi una localización de 2 víctimas en diferentes posiciones y un rescatista, el mapa varia en cuanto a la obtención de imagenes de profundidad, dado que dicho sensor Kinect no funciona de manera adecuada en exteriores.

La 5.2, como la anterior detalla el proceso, el resultado de la obtencion y localización de víctimas en el laboratorio Pasillo de la planta baja del Edificio del CAR, se ubico la víctima en medio del pasillo y los rescatistas al final del mismo.

La 5.3 muestra el laboratorio Robcib de la primera planta en el cual se ubica una víctima y un rescatista en el mismo, dicho ambiente semejante a la arena amarilla de la competición Robocup tanto por su limitación de espacio y ubicación del mismo.

#### Validacion de arena

La figura 5.4 vemos al lado izquierdo imagenes de la arena usada en la competencia Robocup, en la cual existe un apartado de localizacion de victimas en zonas de desastre, al lado derecho tenemos un ambiente similar al de la competencia robocup en los cuales en la figura 5.4 (a), es la zona roja de la competencia y la localizacion se realiza en su mayoria con camaras RGB, las 5.4 (b) 5.4 (c) dan mas relevancia a los materiales usados en cada ambiente simulado, como el uso de palets, ladrillos o cartones, los materiales que se podrian encontrar en un ambiente catastrofico.

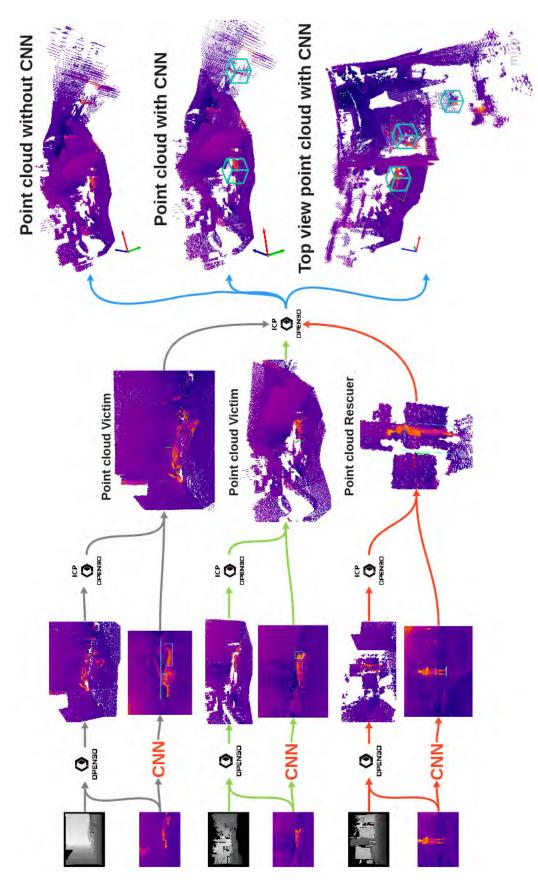


Figura 5.1 Proceso de generación de nubes de puntos en NAVE.

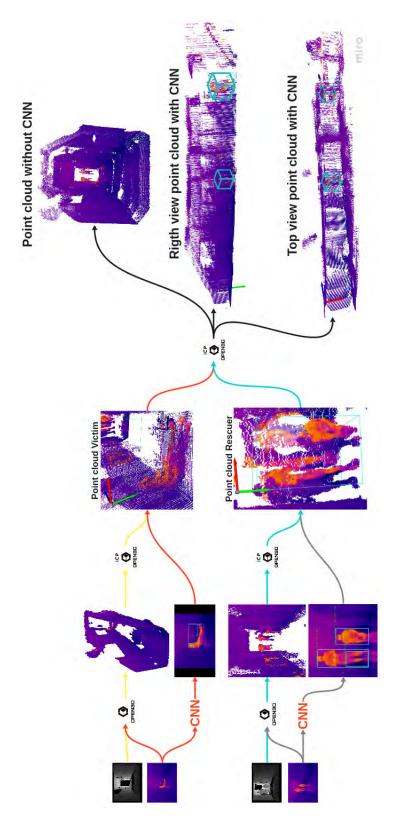


Figura 5.2 Proceso de generación de nubes de puntos en pasillo.

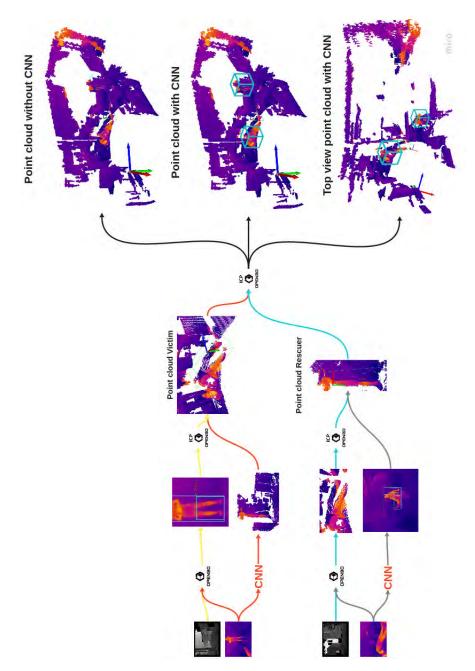


Figura 5.3 Proceso de generación de nubes del Laboratorio Robcib.



Figura 5.4 Test execution and data visualization for localization.

Otra competencia refente hacia los robots de rescate es DARPA Subterranean Challenge: Tunnel Circuit Preview, en la cual se realiza en un tunel subterraneo con el fin de localizar víctimas en su trayecto y la colaboración entre robots, lo que destacamos de dicha competencia es la utilización de cámaras térmicas para la localización de víctimas o personas en zonas de desastre como podemos observar en la 5.5 (a) al lado izquierdo vemos una figura de fondo una imagen rgb y en la parte inferior imagenes de profundidad y térmicas del robot todo ello para la localización de victimas y el mapeo del entorno en donde se mueve, la 5.5 (b) observamos al lado izquierdo una víctima en tunnel circuit DARPA en donde usan varios palets de una camara térmica para verificar el estado de la víctima y al lado derecho vemos la localización de la víctima en nuestro ambiente simulado.

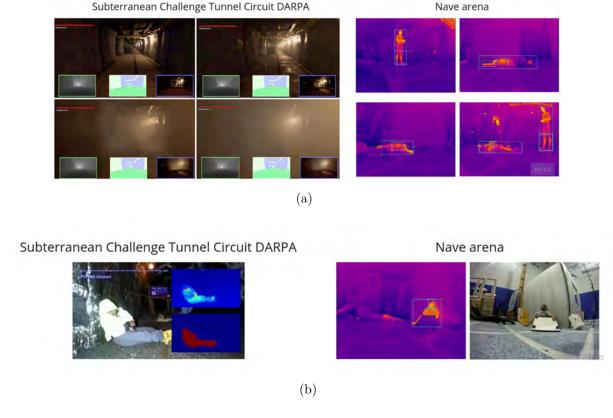


Figura 5.5 DARPA Subterranean Challenge.

# **CONCLUSIONES**

## 6.1. Principales conclusiones

- Se desarrollo e implanto un algorítmo para la creación de un mapa térmico o concatenación de nubes de puntos, mediante el método de icp.
- Previamente se realizó la calibración de la camara térmica y la integración de dicha camara con el senor Kinect, cuyo resultado da la creación de nubes de puntos.
- Los principales aspectos a tomar en cuenta fueron la toma de datos (imagenes), la normalización de imagenes de profundidad, la rectificación de imagenes térmicas y los parametros intrínsecos de la camára térmica, obtenidos apartir de la calibración de dicha camara.
- El procesamiento de las nubes de puntos partio desde el refinamiento del mismo y la eliminación de puntos fuera de cierto rango (80 vecinos en un radio de 4), apartir de ello encontramos los puntos caracteristicos de cada nueva nube y realizamos un emparejamiento mediante el método de RANSAC. El proceso anterior se lo llama registro de variables globales, el resultado de dicho proceso es la matriz de rotación y traslacion de cada nube de puntos, la cual aplicamos al ICP, y obtenemos la integración de las nubes de puntos.
- El entrenamiento de la red neuronal CNN se dio apartir de la creación de un entorno similar a la zona amarilla y roja de la competición Robocup la cual esta estandarizada por el NIST, en dichos entornos adquirimos las imágenes para crear el dataset, para el entrenamiento de las nubes de puntos. La presición del entrenamiento de la red fue de un 98 %

### 6.2. Lineas futuras

El objetivo principal del proyecto fue la localización de víctimas en entornos de desastre 3d, para lo cual se cumplio el objetivo, pero las limitantes del sensor kinect al no trabajar en ambientes exteriores, da pie a plantear otro tipo de sensor para la adquisición de imagenes de profundidad. Otra alternativa a la generación de nubes de puntos seria utilizar sensores 3d como: lidar, velodine, etc. En cuanto a los metodo para la concatenación de nubes de puntos podria ser por odometria entre imagenes RGBD, y analizar el resultado frente al presente proyecto. Para la localización de víctimas se podria optar por deep learning.

En resumen, los trabajos futuros para la continuación del desarrollo del proyecto son: localización de víctimas en entornos de desastre mediante deep learnig con velodine.

# Bibliografía

- [1] D. Acosta, O. Garcia y J. Aponte. "Laser Triangulation for Shape Acquisition in a 3D Scanner Plus Scan". En: *Electronics, Robotics and Automotive Mechanics Conference (CERMA'06)*. Vol. 2. 2006, págs. 14-19. DOI: 10.1109/CERMA.2006.54.
- [2] C. C. Andrea, J. Q. Byron, P. I. Jorge, T. C. Inti y W. G. Aguilar. "Geolocation and counting of people with aerial thermal imaging for rescue purposes". En: *International Conference on Augmented Reality, Virtual Reality and Computer Graphics*. Springer. 2018, págs. 171-182.
- [3] S. G. Barsanti, F. Remondino y D. Visintini. "Photogrammetry and Laser Scanning for archaeological site 3D modeling—Some critical issues". En: *Proc. of the 2nd Workshop on'The New Technologies for Aquileia'*, V. Roberto, L. Fozzati. Citeseer. 2012.
- [4] V. Chougule, H. Gosavi, M. Dharwadkar y A. Gaind. "Review of Different 3D Scanners and Scanning Techniques". En: *IOSR J Eng* (2018), págs. 41-44.
- [5] M. A.-B. Ebrahim. "3D laser scanners' techniques overview". En: Int J Sci Res 4.10 (2015), págs. 323-331.
- [6] J. Geng. "Structured-light 3D surface imaging: a tutorial". En: Advances in Optics and Photonics 3.2 (2011), págs. 128-160.
- [7] F. L. und Geomatik. "Improved Meshing Pipeline for 3D-data Generated from Terrestrial Laserscans". Tesis doct. Hochschule Neubrandenburg, 2017.
- [8] A. Jacoff, E. Messina, B. A. Weiss, S. Tadokoro e Y. Nakagawa. "Test arenas and performance metrics for urban search and rescue robots". En: Proceedings 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003)(Cat. No. 03CH37453). Vol. 4. IEEE. 2003, págs. 3396-3403.
- [9] A. Jacoff, B. Weiss y E. Messina. Evolution of a performance metric for urban search and rescue robots (2003). Inf. téc. NATIONAL INST OF STANDARDS y TECH-NOLOGY GAITHERSBURG MD, 2003.

- [10] S. Judek y L. Jarzebowicz. "Algorithm for automatic wear estimation of railway contact strips based on 3D scanning results". En: 2014 international conference and exposition on Electrical and Power Engineering (EPE). IEEE. 2014, págs. 724-729.
- [11] M. Lewis, K. Sycara e I. Nourbakhsh. "Developing a testbed for studying humanrobot interaction in urban search and rescue". En: *Proceedings of the 10th International Conference on Human Computer Interaction (HCII'03)*. 2019, págs. 270-274.
- [12] P. Li, R. Wang, Y. Wang y W. Tao. "Evaluation of the ICP Algorithm in 3D Point Cloud Registration". En: *IEEE Access* 8 (2020), págs. 68030-68048.
- [13] C. Mineo, S. G. Pierce y R. Summan. "Novel algorithms for 3D surface point cloud boundary detection and edge reconstruction". En: *Journal of Computational Design and Engineering* 6.1 (2019), págs. 81-91.
- [14] W.-D. Rase. "Creating physical 3D maps using rapid prototyping techniques". En: True-3D in Cartography. Springer, 2011, págs. 119-134.
- [15] C. D. Rodin, L. N. de Lima, F. A. de Alcantara Andrade, D. B. Haddad, T. A. Johansen y R. Storvold. "Object classification in thermal images using convolutional neural networks for search and rescue missions with unmanned aerial systems". En: 2018 International Joint Conference on Neural Networks (IJCNN). IEEE. 2018, págs. 1-8.
- [16] T. Rouček, M. Pecka, P. Čížek, T. Petříček, J. Bayer, V. Šalanský, D. Heřt, M. Petrlík, T. Báča, V. Spurný y otros. "Darpa subterranean challenge: Multi-robotic exploration of underground environments". En: *International Conference on Modelling and Simulation for Autonomous Systesm.* Springer. 2019, págs. 274-290.
- [17] R. B. Rusu. Semantic 3D object maps for everyday robot manipulation. Springer, 2013.
- [18] D. Scaramuzza y Z. Zhang. "Visual-inertial odometry of aerial robots". En: arXiv preprint arXiv:1906.03289 (2019).
- [19] F. Wu, J. Zhang, Y. Chen y D. Guo. "Precise measurement of the micron-scale spot of ultrashort laser pulse based on film scanning". En: *Chinese Optics Letters* 6.4 (2008), págs. 258-260.
- [20] Y. Xiong, M. Ren, R. Liao, K. Wong y R. Urtasun. "Deformable filter convolution for point cloud reasoning". En: arXiv preprint arXiv:1907.13079 (2019).
- [21] H. A. Yanco, J. L. Drury y J. Scholtz. "Beyond usability evaluation: Analysis of human-robot interaction at a major robotics competition". En: *Human-Computer Interaction* 19.1-2 (2004), págs. 117-149.
- [22] J. Yang, Z. Cao y Q. Zhang. "A fast and robust local descriptor for 3D point cloud registration". En: *Information Sciences* 346 (2016), págs. 163-179.

S. Zhang, F. Huang, B. Liu, H. Zhong, G. Li, Y. Chen y Z. Wang. "Optimized [23]calibration method for ultra-field dual bands cameras based on thermal radiation checkerboard". En: Infrared Physics & Technology 108 (2020), pág. 103346.

## **ANEXOS**

# 7.1. Anexo I: Analisis de la responsabilidad etica, social y profesional del impacto del proyecto

El obejtivo del proyecto es la localización de víctimas en un mapa térmico 3d. El cual abarca una serie de aplicaciones en las que se podria analizar la responsabilidad ética, social y profesional por cada una. En el aspecto ético: el proyecto tiene el fin de ayudar a los rescatistas mediante la localización de victimas para asi organizar tareas de rescate, mediante el análisis del entorno en el cual se encuentre la víctima.

En el aspecto social el proyeto tendria varias aplicaciones como la detección de bombas, por medio de la radiación que eviten dichos aparatos, se tendira que re eestructurar el entrenamiento de la red neuronal, pero se utilizaria el algoritmo para el mapeo de la zona. En el ambito profesional existen varias empresas dedicatas al tema de busqueda y rescate en ambientes catastroficos los cuales buscan mejorar los métodos de localización de sus robots, como la competencia de DARPA Subterranean Challenge en la cual se desarrollan nuevas técnicas de colaboracion de robots, localización de víctimas y manejo autonomo de los mismos.

## 7.2. Anexo I: Planicación y costes

#### 7.2.1. Planificación temporal

La planificación temporal se detalla el tiempo implementado para el desarrollo del tema propuesto. El trabajo de fin de Máster tiene 12 créditos, y cada crédito representa entre 25 y 30 horas. En total las horas empleadas son 360, las cuales se dividen en actividades que se muestran en la Tabla ??. Es importante mencionar que varias de las actividades se pueden realizar en paralelo, por lo que el total de horas sobre pasa el requerido, el detalle de las horas se refleja en la 7.1.

Tabla 7.1 Planificación proyecto

Actividades	Número de horas
Análisis e inicio del proyecto	
Explicación y comprensión del proyecto	6
Obtención de requerimientos	10
Inicio del proyecto	5
Estudio del estado del arte	
Estudio de conceptos generales	12
Análisis de desafios en temas similares	12
Análisis de software y herramientas para resolver el problema	13
Generacion de nubes de puntos	
Instalación software	12
Calibración de camara termica	20
Integración de imágenes termicas y profundidad con ROS	10
Diseño de soporte para camara	10
Adquisicion de imagenes termicas y de profundidad	12
Generación de nubes de puntos	10
Algoritmo ICP	20
Concatenación de nuebes de puntos	22
Afinamiento de concatenación	25
Red neuronal	
Generacion de dataset	30
Procesamiento dataset	48
Entrenamiento de red	8
Validación de red	20
Resultados	
Concatenación de nubes de puntos Robcib	10
Concatenación de nubes de puntos Pasillo	10
Concatenación de nubes de puntos Nave	10
Integracion de nubes de puntos con Red neuronal	25

ANEXO I: PLANICACIÓN Y COSTES

En la Figura 7.1, se puede observar la planificación temporal de todas las actividades, algunas de las cuales se podían realizar en paralelo. La parte del proyecto que mayor tiempo representa es la generación de nubes de puntos, ya que consta de varios puntos fundamentales del proyecto. Adicionalmente, para validar el proyecto se realizo pruebas en varios entornos para su correcto funcionamiento.

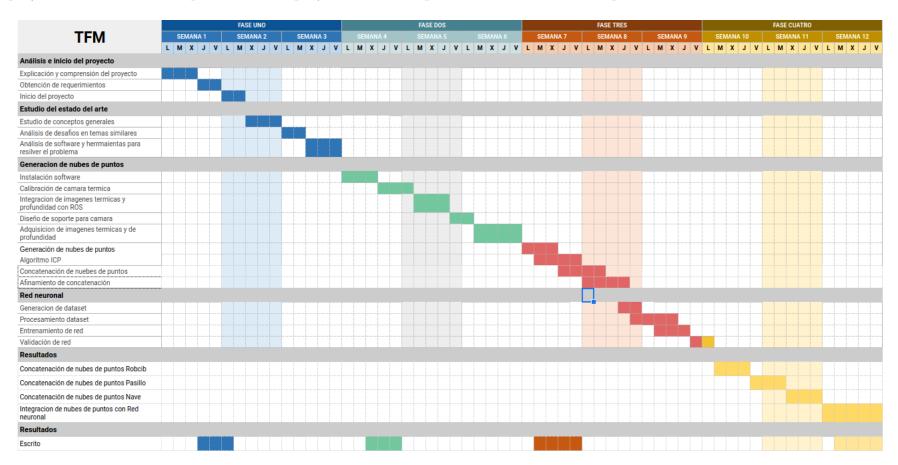


Figura 7.1 Diagrama de Gantt, planificación Temporal

UNIVERSIDAD POLITÉCNICA DE MADRID ESCUELA TÉCNICA SUPERIOR DE INGENIEROS INDUSTRIALES

### 7.2.2. Estudio económico

A continuación se presenta el estudio económico realizada para este trabajo.

### Costes personal

El coste personal se obtiene a partir de las horas empleadas en este proyecto y del coste por horas de un master recién egresado. El Trabajo Fin de Master en el Master de Automática y Robótica en Tecnologías Industriales de la UPM son 12 créditos ECTS. Cada crédito equivale a 25 horas de trabajo, luego se tiene una dedicación de 300 horas. El salario estimado de un master en automática y robotica recién egresado se estima alrededor de los 20500 al año a jornada completa. Hay 217 días laborales al año, y para la jornada completa de 8 horas da un total de 1736 horas anuales. Así se obtiene un coste por hora de  $25 \in /h$ . Multiplicando el coste por horas por las horas empleadas en el proyecto se obtiene un coste personal de  $9000 \in .$ 

### Costes del software

El software empleado en este proyecto es software libre, luego no genera ningún coste en el proyecto.

### Costes de amortización del material

En cuanto al coste material, los materiales usados para este proyecto fueron la cámara infrarroja y un ordenador portatil.

La cámara tiene un coste de 2299€ y suponiendo un periodo de vida útil estimado de 10 años, al aplicar el coeficiente de amortización lineal se obtiene que el coste de amortización del mismo en un año es de 229.90€.

Para el caso del ordenador, con un coste de  $2000 \in y$  una vida útil de 5 años, al aplicar el coeficiente de amortización lineal se obtiene que el coste de amortización del mismo en un año es de  $400 \in \mathbb{N}$ . Para el kinect v1, con un coste de  $250 \in \mathbb{N}$  una vida util de 5 años, al aplicar el coeficiente de amortización lineal se obtiene que el coste de amortización del mismo en un año es de  $250 \in \mathbb{N}$ .

Para el robot Jaguar V4, con un coste de 16,500€y una vida util de 5 años, al aplicar el coeficiente de amortización lineal se obtiene que el coste de amortización del mismo en un año es de 3300€.

De esta manera se obtiene el presupuesto global del proyecto, lo refleja en la 7.2.

Tabla 7.2 Coste Proyecto

Partida	Partida	Gasto
	Coste del trabajo del alumno	9000
	Coste del trabajo del tutor	380,18
Personal	Total Personal	9380,18
	Sistema operativo Linux	0
Software	Total Software	0
	Cámara infrarroja	229,90
	Ordenador	400
	Kinect V1	250
	Jaguar V4	3300
Amortización	Total Amortización	4179.9
Total	TOTAL PROYECTO	13560.08

## 7.3. Anexo II: Glorario: siglas y abreviaturas

NIR Near-Infrared

FIR Far Infrared

RGB Reg - Green - Blue

PIR Passive InfraRed sensors

MNIST Modified National Institute of Standards and Technology

NN Neural Network

CNN Convolutional Neural Network

R-CNN Region-based Convolutional Neural Network

RoI Region of Interest

RPN Region Proposal Network

SSD Single Shot MultiBox Detector

YOLO You Only Look Once

CUDA Compute Unified Device Architecture

CPU Central Processing Unit

GPU Graphics processing unit

API Application Programming Interface

COCO Common Objects in Context

mAP mean average precision

fps frames per second

ROS Robot Operating System

SAR Rescue and Search