



**UNIVERSIDAD DE TALCA
FACULTAD DE INGENIERÍA
ESCUELA DE INGENIERÍA CIVIL EN COMPUTACIÓN**

**Evasión de obstáculos con flujo óptico y redes
neuronales para vehículos aéreos no tripulados**

JORGE GÓMEZ VALDERRAMA

Profesor Guía: MATTHEW BARDEEN

Memoria para optar al título de
Ingeniero Civil en Computación

Curicó – Chile
Agosto, 2017

CONSTANCIA

La Dirección del Sistema de Bibliotecas a través de su encargado Biblioteca Campus Curicó certifica que el autor del siguiente trabajo de titulación ha firmado su autorización para la reproducción en forma total o parcial e ilimitada del mismo.



Curicó, 2019

Dedicado a mis padres

AGRADECIMIENTOS

Ante todo, quiero agradecer a mis padres por todo el apoyo brindado durante todos estos años, por dejarme aprender de cualquier cosa en que mostrara interés, que sin duda fue lo que me permitió llegar hasta esta instancia. Quisiera agradecer a Estefanía por ser mi compañera todos estos años, en este largo camino universitario donde siempre estuvo a mi lado, en todas las circunstancias.

Agradecer a mis viejos amigos, a los que nos conocemos desde la infancia y que hasta el día de hoy seguimos estando, Bastián, Jaime, Matías Y Rolando. Todos han sido parte de largo recorrido que comenzó en las salas del “*Rauquen*”. También a los nuevos que se sumaron en los primeros años de universidad, Patricio Pino y Patricio Valderrama por todas esas jornadas de estudio, cuántas clases y trasnoches juntos. Agradecimientos especiales a Camino y Yanira por toda la ayuda que me brindaron y por ser los que me recordaban que tenía que seguir escribiendo este documento, preocupados hasta el último momento.

Dar las gracias a toda la personas de la universidad de Talca que fueron parte de mi formación profesional, en particular a mi profesor guía Matthew Bardeen.

TABLA DE CONTENIDOS

	página
Dedicatoria	I
Agradecimientos	II
Tabla de Contenidos	III
Índice de Figuras	VI
Índice de Tablas	VIII
Índice de Algoritmos	IX
Resumen	x
1. Introducción	11
1.1. Descripción del contexto	11
1.2. Definición del problema	12
1.3. Trabajo relacionado	13
1.4. Propuesta de solución	16
1.5. Objetivos	16
1.5.1. Objetivo general	17
1.5.2. Objetivos específicos	17
1.6. Alcances	17
2. Marco teórico	19
2.1. Vehículo aéreo no tripulado	19
2.2. Visión por Computador	21
2.3. Flujo óptico	22
2.4. OpenCV	26
2.5. Redes neuronales	27
2.6. Robot omnidireccional	34
2.7. Microcontrolador	36
2.8. Controlador para motores	38

2.9. Sensor óptico de movimiento	40
3. Implementación	43
3.1. Flujo óptico	43
3.1.1. Captura de flujo óptico	44
3.2. Red neuronal	48
3.2.1. Funcionamiento	48
3.2.2. Entrenamiento	50
3.3. Conducción autónoma	52
3.4. Procesamiento de datos	53
3.5. Robot omnidireccional	54
3.5.1. Diseño del robot	54
3.5.2. Control de las ruedas	62
3.5.3. Enlace de radio	65
3.5.4. Movimiento	67
4. Pruebas y Resultados	72
4.1. Pruebas	72
4.2. Obtención de datos	74
4.3. Resultados	75
4.3.1. Evasión de bordes	75
4.3.2. Evasión de obstáculos	79
4.4. Conducción autónoma	83
4.5. Análisis	83
5. Conclusión	88
5.1. Objetivos	88
5.2. Trabajo realizado	90
5.3. Trabajo futuro	92
Glosario	94
Bibliografía	96
Anexos	

A: Resultados entrenamiento de redes neuronales	100
A.1. Red.1.A	100
A.2. Red.1.B	101
A.3. Red.2.A	102
A.4. Red.2.B	103
B: Arduino UNO rev 2	105
C: Configuración impresora 3D	106

ÍNDICE DE FIGURAS

	página
2.1. Proyección de un punto sobre la imagen.	23
2.2. Captura de flujo óptico.	24
2.3. Representación de un perceptrón.	28
2.4. Representación de una red neuronal.	29
2.5. Función sigmoide.	31
2.6. Función escalonada.	31
2.7. Movimiento rueda omnidireccional.	34
2.8. Movimiento hacia adelante y atrás del robot omnidireccional.	35
2.9. Movimiento hacia la derecha e izquierda del robot omnidireccional.	35
2.10. Movimiento en 45° y 120° del robot omnidireccional	36
2.11. Funcionamiento de un puente H.	39
2.12. Control lógico del controlador L298	40
3.1. Captura flujo óptico.	45
3.2. Captura flujo óptico frente a obstáculo.	46
3.3. Captura del flujo óptico de un <i>frame</i>	47
3.4. Rueda omnidireccional.	55
3.5. Acople entre la rueda y la caja reductora.	55
3.6. Extensión para unir los motores.	56
3.7. Cuerpo principal robot omnidireccional.	57
3.8. Compartimiento de baterías.	57
3.9. Soporte sensor óptico.	58
3.10. Soporte cámara digital.	59
3.11. Ensamble robot omnidireccional.	60
3.12. Robot omnidireccional completo.	61
3.13. Motor con caja reductora del robot omnidireccional.	62
3.14. Control de de los motores.	64
3.15. Ciclo de trabajo de señal <i>PWM</i>	65
3.16. Señal <i>PWM</i> de los canales de radio.	66
3.17. Vector formado por las entradas de radio	67
3.18. Desplazamiento del robot sobre el plano <i>XY</i>	68

3.19. Movimiento de las ruedas del robot omnidireccional.	69
3.20. Suma de los vectores que dan la dirección del robot.	69
3.21. Proyección del vector \vec{d} sobre el eje X e Y	70
4.1. Entrenamiento primera etapa Red.1.A.	76
4.2. Entrenamiento primera etapa Red.1.B.	77
4.3. Efectividad de Red.1.A vs Red.1.B.	78
4.4. Entrenamiento segunda etapa Red.2.A.	80
4.5. Entrenamiento segunda etapa Red.2.A.	81
4.6. Efectividad de Red.2.A vs Red.2.B.	82
4.7. Histograma movimiento robot en el eje X	84
4.8. Histograma movimiento robot entrenamiento v/s validación	85
4.9. Histograma movimiento robot en eje Y	86

ÍNDICE DE TABLAS

	página
2.1. Paquete de datos de movimiento <i>mouse</i> PS/2.	42
3.1. Datos de entrenamiento y validación	51
3.2. Comportamiento de las salidas del controlador L298.	64
4.1. Datos comparativos del entrenamiento en Red.1.A y Red.1.B	78
4.2. Datos comparativos del entrenamiento en Red.2.A y Red.2.B	82
A.1. Datos del entrenamiento realizado a la Red.1.A.	100
A.2. Datos del entrenamiento realizado a la Red.1.B.	101
A.3. Datos del entrenamiento realizado a la Red.2.A.	102
A.4. Datos del entrenamiento realizado a la Red.2.B.	103
B.1. Especificaciones Arduino UNO.	105

ÍNDICE DE ALGORITMOS

	página
1. Calculo Flujo Óptico	44
2. Captura de datos	47
3. Red neuronal	49
4. Entrenamiento	51
5. Conducción autónoma	53

RESUMEN

En este documento se describe el trabajo realizado como memoria de título, el cual busca crear un sistema que permita a los vehículos aéreos no tripulados detectar y evadir obstáculos en vuelos autónomos. Para esto se emplea inteligencia artificial capaz de aprender por medio de mecanismos de aprendizaje supervisado, haciendo uso de redes neuronales las cuales se encargan del procesamiento de datos visuales derivados del flujo óptico capturado del entorno donde se desplaza el vehículo.

Dentro de los objetivos planteados está el diseño y construcción de un robot omnidireccional, el cual imita los movimientos de un cuadricóptero. El cual sirve de plataforma para realizar pruebas experimentales del sistema implementado. Este robot obtendrá el flujo óptico dentro de una pista de pruebas donde tendrá que evadir un obstáculo por medio de una red neuronal.

El proceso necesario para lograr la evasión de obstáculos inicia con la obtención de datos para entrenar la red neuronal, para esto se conduce el robot por una pista de obstáculos con el objetivo de grabar en video los recorridos realizados. De las capturas de videos se extrae el flujo óptico de la escena, con estos datos se entrena la red neuronal. Una vez que la red haya aprendido cómo desplazarse por la pista, se procede con la conducción autónoma de robot, donde se procesa la captura de video en tiempo real entregando el flujo óptico a la red neuronal, la que se encargará de dirigir el robot por la pista de pruebas.

1. Introducción

1.1. Descripción del contexto

La motivación para trabajar en este tema viene de observar que en la naturaleza existe gran variedad de animales que pueden alzar vuelo y de cómo estos tienen total control sobre las maniobras que pueden hacer. Entonces si se comprende cómo logran hacer esto se podría aplicar esos mismos mecanismos a los vehículos aéreos no tripulados.

Una de las formas en que las aves dirigen su vuelo es por medio del flujo óptico, con esto logran extraer información de la escena en que encuentran y así navegar a través de esta. La información es obtenida por medio de la visión la que luego es procesada en el cerebro [13].

Tomando en cuenta esta técnica de la naturaleza es que se pretende hacer un símil del mundo natural, se toma como modelo uno de los mecanismos que tienen las aves para dirigir el vuelo y se traspassa a los vehículos aéreos no tripulados. Para recrear el procesamiento que realizan las aves por medio de las conexiones neuronales de su cerebro se utilizan redes neuronales, estas redes serán las que procesaran la información del entorno, la que es obtenida por medio del flujo óptico.

Cuando se habla de un vehículo aéreo no tripulado (también conocidos como drones) se hace mención a cualquier tipo de aeronave que no tenga un piloto a bordo. Sin embargo en el contexto de este documento se hace referencia a un tipo específico de aeronave los cuadricópteros, los que son un tipo de multirrotor, véase sección 2.1.

En los últimos años este tipo de aeronaves han ganado mucha popularidad, debido al avance de la tecnología, producción a una mayor escala y precios más reducidos. Si bien en un principio eran empleados en áreas militares y técnicas ahora son usados en una gran variedad de campos distintos. La una de las razones principales por lo que ahora los cuadricópteros son usados ampliamente es por uno de sus componentes principales, el controlador de vuelo. El cual tiene como función principal controlar los motores de tal manera que permite mantener a los multirrotores en aire de forma estable.

Estas características permiten que controlar estas aeronaves sea una tarea más sencilla, automatizando varios aspectos del vuelo, permitiendo que ahora cualquier persona pueda volar un cuadricóptero. Pero a pesar de esto hay ámbitos en los cuales todavía tiene que hacerse cargo el piloto, como lo es la reacción ante objetos que se interpongan en la trayectoria de vuelo. Este es un campo en cual todavía se necesita investigación y desarrollo.

1.2. Definición del problema

Los cuadricópteros tienen la capacidad de mantenerse en vuelo sin la intervención de un piloto, ya sea sobre una posición específica o siguiendo una ruta programada, esto es posible gracias al controlador de vuelo que cada multirrotor tiene a bordo. Este controla cada movimiento que realiza y puede llegar a hacer muchas tareas de forma autónoma, como lo es despegar, aterrizar o desplazarse a un punto en específico en el aire.

Las prestaciones mencionadas son realizadas por la adición de dispositivos al controlador de vuelo, estos le entregan información en distintos ámbitos, la que puede ser la posición georreferenciada mediante GPS, la altura por la medición barométrica, los movimientos que realiza el cuadricóptero con sensores de aceleración lineal y angular (acelerómetros y giroscopios), entre otros.

Con las características ya mencionadas de los controladores de vuelo, es posible realizar vuelos de forma completamente autónoma, sin embargo, estos no tienen la

información completa del entorno por donde se desplazan, esto se debe a que en la mayoría de las veces la autonomía se desarrolla por medio de trayectorias ya definidas que por puntos georeferenciados los que el dron va siguiendo de forma secuencial.

Es por esto que se necesita incorporar a los drones mecanismos adicionales que sean capaces de detener y evadir obstáculos, por ejemplo, agregar computadores a bordo que se dediquen exclusivamente a obtener datos del entorno por medio de sensores, como pueden ser cámaras, sensores de proximidad, entre otros. De esta forma se es posible indicar al controlador de vuelo acciones adicionales para corregir la trayectoria, ante los objetos que son detectados y evitar posibles colisiones.

1.3. Trabajo relacionado

Actualmente existen distintos mecanismos para la detección y evasión obstáculos, los cuales basan su funcionamiento en la captura información del entorno en el que se encuentran por medio de distintos sensores, los datos obtenidos son procesados permitiendo a los vehículos aéreos no tripulados detectar obstáculos y tomar acciones frente a estos. Las cuales pueden consistir en detenerse frente a un obstáculo o calcular una nueva ruta y evitarlo.

Uno de los recursos utilizados para realizar estas tareas es *fusión de sensores* (Del inglés: *Sensor fusion*), el que consiste en la utilización de múltiples sensores, ya sea posicionado el mismo tipo de sensor en distintas partes o utilizando diferentes tipos de sensores, para disponer de distintas mediciones en situaciones distintas, poder pensar una mayor área, por ejemplo: disponer sensores al frente y en la parte posterior de un dron para detectar obstáculos cuando este avance tanto hacia adelante como hacia atrás, o utilizar distintos tipos de sensores para poder hacer correcciones comparando distintas mediciones.[18]

Estos son algunos de los sensores utilizados para la captura de datos del entorno:

- Stereo Vision
- Ultrasonic Sonar

- Time-of-Flight
- Lidar
- Monocular Vision

Para esto se implementan distintas tecnologías, las que conforman sistemas complejos utilizando múltiples sensores de distintos tipos, *software* que incluye modelos matemáticos, algoritmos, machine learning y aspectos de tecnologías *SLAM* (mapeo y localización simultáneos, del inglés: simultaneous localization and mapping).

Tecnología SLAM

SLAM es usado transversalmente en drones, vehículos y todo tipo de robot. Consiste en el robot crear un mapa de su entorno y ubicarse dentro de este mapa en tiempo real. Este proceso comienza con la construcción de un mapa preexistente del entorno. El robot o dron utiliza este mapa, el cual es refinado a medida que este se desplaza por el entorno. El desafío es contar con precisión, se debe hacer una constante medición a medida que se realiza el desplazamiento y hay que considerar el ruido producido por el movimiento además de la inexactitud de la medición en sí. [6]

Sensores de visión estereoscópica

La visión estereoscópica funciona de una forma similar a la percepción tridimensional del humano. El cálculo de la profundidad es realizado por medio dos imágenes bidimensionales, las que provienen a su vez de dos cámaras con puntos de vista ligeramente diferentes.[3]

Este cálculo se realiza identificando pixeles de las dos imágenes de un mismo punto físico en la imagen, la ubicación tridimensional de este punto en el espacio se calcula mediante triangulación usando la información de cada cámara.

Sensores Ultrasónicos

Los sensores ultrasónicos envían un pulso sonoro de alta frecuencia, estos escuchan el eco producido por el pulso midiendo el tiempo que tarda este en ser detectado. Ya que la velocidad del sonido es conocida se puede determinar a qué distancia se encuentra el objeto que reflejó el pulso sonoro. La mayoría de los drones utilizan este tipo de sensores en la parte de abajo para medir la distancia con respecto al suelo, ya que estos sensores no entregan una definición de objeto que detectan.[1]

Sensores Time-of-Flight (ToF)

Los sistemas Time-of-Flight cuentan con una cámara y una fuente de luz, es capaz de determinar la información de la profundidad y la intensidad de cada píxel del sensor de la cámara simultáneamente, haciendo extremadamente rápido y a un alto *frame rate* (cuadros por segundos).

La cámara ToF ilumina la escena completa incluyendo los objetos con un pulso o una fuente constante de luz y captura la luz reflejada. Mide el *Tiempo de Vuelo* (Del inglés: Time of Flight) del pulso de luz desde la fuente hacia el objeto y de vuelta después de ser reflejado. Ya que la velocidad de la luz es conocida la distancia hacia el objeto es fácilmente calculable.[22]

Sensores Lidar

Un sensor Lidar detecta objetos y la distancia de estos midiendo el tiempo que toma un corto pulso láser en viajar desde el sensor al objeto y volver, calculando la distancia desde la velocidad conocida la de luz.

Los sensores Lidar más sofisticados combinan múltiples sensores en uno solo, los que les permite capturar millones de datos por segundo.[2]

Monocular Vision

Monocular Vision (Del inglés: Vision Monocular) consiste en utilizar solo una cámara para la captura de imágenes, las que posteriormente son procesadas por medio de software para hacer una reconstrucción tridimensional, esta reconstrucción utiliza *depth cues* (Del inglés: pistas de profundidad) como por ejemplo: perspectiva, tamaños relativos, profundidad de campo entre otros.

De esta forma utilizando estos mecanismos se puede determinar la posición y la distancia de los obstáculos en una imagen.[5]

1.4. Propuesta de solución

Como solución se propone implementar un sistema que permita la detección de obstáculos y la evasión de estos, de esta forma agregar al cuadricóptero una herramienta que le permita enfrentar este tipo de problemáticas.

La información de objetos será capturada por medio de una cámara digital, el video entregado por esta se procesará para obtener el flujo óptico presente en las imágenes, véase sección 2.3, éste permite rescatar datos de donde se encuentran los objetos dentro de la imagen.

Una vez que se obtenga el flujo óptico, será entregado a una red neuronal, véase sección 2.5, la que dará como salida la dirección a la cual se debe hacer un movimiento para evadir un obstáculo.

1.5. Objetivos

En esta sección se describe los elementos que son necesarios desarrollar para poder dar solución al problema. Se menciona el objetivo general y que se necesita para este se pueda satisfacer, además de dar a conocer las limitaciones del sistema a implementar.

1.5.1. Objetivo general

Implementar un sistema, que cuente con el software necesario para procesar la información obtenida del entorno para detectar obstáculos y a partir de esto tomar las decisiones que permitan evadirlos, mediante la utilización de flujo óptico y redes neuronales.

1.5.2. Objetivos específicos

- Definir herramientas que permitan la obtención de flujo óptico desde la captura de video.
- Implementación de una red neuronal que permita el procesamiento del flujo óptico.
- Entrenamiento de una red neuronal para que sea capaz de aprender cómo evadir obstáculos.
- Implementación de un robot omnidireccional que permite la obtención de datos para entrenar la red neuronal.
- Realizar pruebas con el robot para evaluar el comportamiento de la red neuronal ante obstáculos.

1.6. Alcances

- El sistema será probado con un robot omnidireccional que solo puede moverse en un plano de dos ejes.
- La evasión de obstáculos solo se realizará en un eje.
- Solo se evadirán objetos estáticos y de uno a la vez.
- Las pruebas serán realizada en una pista diseñada con este fin bajo condiciones controladas.

En este capítulo se describió las razones por las que se aborda esta temática, mencionando el interés que se tiene de imitar los mecanismos que se encuentran en la naturaleza para dirigir el vuelo y utilizarlos en los vehículos aéreos no tripulados.

También se definió la problemática y como se pretende solucionar, en particular la detección y posterior evasión de obstáculos por medio del flujo óptico y redes neuronales. Además de describir los objetivos que se necesitan cumplir para dar con la solución.

2. Marco teórico

En este apartado se describen elementos que son necesarios para la comprensión del problema y la implementación de la solución. Se detalla que es un cuadricóptero, como este se mueve en el aire y por qué es importante para la implementación. Se profundiza en la teoría del software a utilizar, lo que abarca: visión por computador; flujo óptico, su definición y cómo es posible calcularlo; redes neuronales, que son, como funcionan y aprenden. Se describen los elementos de hardware que son necesarios para la implementación de la solución, se introduce a los robots omnidireccionales y algunos elementos que se utilizan en la construcción de este, que son: microcontrolador, controlador de motores y el sensor óptico de movimiento.

2.1. Vehículo aéreo no tripulado

La problemática descrita fue obtenida de los vehículos aéreos no tripulados, por lo que es importante describir que son y qué elementos de estos son importantes para a tomar en cuenta en la solución propuesta.

Un vehículo aéreo no tripulado, UAV (por sus siglas del inglés: *unmanned aerial vehicle*) o dron, es cualquier aeronave que no cuente con un piloto o tripulación a bordo, por lo que ésta puede volar de forma autónoma por medio de un computador a bordo o ser controlada remotamente por un humano [30].

Dentro de los vehículos aéreos no tripulados se encuentran los multirrotores o multicópteros, estas son aeronaves que generan sustentación por medio del giro de

alas o hélices sobre un eje, siendo este conjunto llamado rotor. La Organización de Aviación Civil Internacional (CIAO por sus siglas del inglés: *International Civil Aviation Organization*) los define como aeronaves que se mantienen en vuelo por las reacción del aire en uno o más rotores. En el caso de los multirrotores estos están compuestos por dos o más rotores, se diferencian de los helicópteros en la forma que logran el control y la estabilidad, estos tienen mecanismos que varían el paso de las hélices modificando su ángulo de ataque, en cambio los multirrotores lo hacen por medio del cambio de velocidad relativa de cada rotor, produciendo cambios en el empuje y torque.

Un tipo de mutirrotores son los cuadricópteros los cuales tienen dos pares de rotores con hélices iguales y paso fijo, dos giran en sentido horario y los otros dos en sentido antihorario, esta configuración permite que el torque de cada rotor se anule con el rotor correspondiente que gira en sentido contrario, de esta forma el cuadricóptero se estabiliza y no gira sobre su propio eje [7].

Se describe este tipo de UAV porque la solución a entregar va enfocada a este grupo de aeronaves, principalmente a los cuadricópteros que bordean los 250 mm de diámetro.

Como se mencionó anteriormente los movimientos de los multirrotores se logran variando la velocidad de cada rotor independientemente, referencia a la imagen, con esto el cuadricóptero puede moverse sobre 3 ejes perpendiculares, por medio de los movimientos de *pitch*, *roll* y *yaw*, además de desplazarse por el eje Z variando su altitud.

Con el movimiento *pitch* el cuadricóptero rota sobre el eje X y se desplaza hacia adelante o atrás por el eje Y , cuando ejecuta el movimiento de *roll* rota sobre el eje Y y se desplaza de izquierda a derecha sobre el eje X y gira sobre el eje Z con el movimiento de *yaw*. Con esto se logra tener control sobre 4 grados de libertad.

Es necesario saber cómo son capaces de moverse los cuadricópteros, ya que en las pruebas a realizar se busca imitar los movimientos que estos realizan. De esta forma al capturar video se tenga una visión muy cercana a la que se tendría al hacerlo

desde un cuadricóptero. Con la limitación de que la cantidad de movimientos que puede hacer el robot omnidireccional es menor a de un quadricoptero, este último tiene la capacidad de realizar movimientos en tres dimensiones, desplazándose en el aire, en cambio el robot sólo puede hacerlo en dos dimensiones sobre una superficie, véase sección 2.6.

2.2. Visión por Computador

Computer Vision (visión por computador) es una disciplina que busca que los computadores puedan tener una comprensión de alto nivel sobre imágenes o videos digitales, por ejemplo, con el objetivo de automatizar tareas que el sistema visual humano ya puede hacer[11, 36, 34].

Dentro de las tareas de la visión por computador están: la adquisición, procesamiento, análisis, el entendimiento de imágenes digitales y la extracción de información multi dimensional del mundo real, para producir información numérica o simbólica [26, 32, 27, 21].

Dado que nosotros percibimos el mundo principalmente por medio de la vista, parecería sencillo traspasar nuestra experiencia a la visión por computador, pero en realidad es una tarea muy difícil, debido a la complejidad de cómo funciona nuestro cerebro. Contamos con múltiples sistemas que reciben distinta información segmentada desde el sistema visual e incluso otros sistemas, pero en el caso de la visión por computación solo contamos con una imagen (en el caso de video una secuencia de imágenes) y esto es todo lo el computador puede "ver".

Cuando hablamos de una imagen nos estamos refiriendo a la información que nos es capaz de entregar la luz que es recibida desde el entorno o una escena. Esta información varia dependiendo del contexto en que se hable, si nos referimos a un marco biológico la luz incidirá en un ojo y las células en la retina generaran las señales eléctricas que el cerebro interpretará como imágenes, si hablamos de una cámara la imagen se formará en una película fotográfica o en un sensor digital [14].

Dado el ámbito de este documento, es preciso profundizar en las imágenes digitales, esta puede ser definida como la integración y muestreo de información analógica (luz incidiendo en un sensor fotográfico) en un dominio espacial. Esta consiste en un arreglo rectangular de pixeles (x, y, u) , cada uno contiene una ubicación $(x, y) \in \mathbb{Z}^2$ y un valor u , muestreado en una ubicación (x, y) . \mathbb{Z} es conjunto de puntos (x, y) del arreglo rectangular [26]. Entonces podemos definir una imagen como:

$$I = \{(x, y) : 1 \leq x \leq N_{cols} \wedge 1 \leq y \leq N_{rows}\} \subset \mathbb{Z}^2 \quad (2.1)$$

2.3. Flujo óptico

El flujo óptico es uno de los elementos centrales en este documento. Es obtenido por medio del procesamiento de imágenes, con el fin de obtener información de la escena circundante. Esta información es la que será utilizada por la red neuronal posteriormente. En esta sección se describe que es el flujo óptico y como es calculado.

El flujo óptico es definido como el cambio de la estructura de la luz en una imagen, por ejemplo, en la retina de un ojo o en el sensor de una cámara, debido a movimiento relativo del observador y escena. Cuando los objetos se mueven frente a una cámara o esta se mueve en un entorno fijo, existe un cambio correspondiente a los movimientos en la imagen, estos cambios pueden utilizarse para recuperar información relativa al movimiento de las formas y los objetos.

Podemos definir un campo de movimiento, en el cual asignamos un vector de velocidad a cada punto de la imagen. En un instante en particular, un punto P_i en la imagen corresponde con algún punto P_0 en la superficie de un objeto. Los dos puntos son conectados por la ecuación de proyección. Si consideramos una proyección de perspectiva, una línea se extiende de un punto en la imagen, pasa por el centro de la lente (en el caso de tratarse de una cámara), hasta un punto en la superficie de la escena.




Figura 2.1: Proyección de un punto P_0 con movimiento v_0 en la escena a un punto P_i con movimiento v_i sobre la imagen.

El punto P_0 tiene una velocidad v_0 relativa a la cámara, esto induce un movimiento v_i en el punto P_i correspondiente en la imagen, como se puede ver en la figura 2.1[23].

Los vectores de velocidad producidos por el movimiento aparente son descritos de forma distinta, dependiendo del contexto en que se presenten, de un punto de vista biológico los cambios estructurados en los patrones de la luz en la retina de un ojo dejan la impresión de movimiento. En visión por computación los cambios en la escena son representados por una serie de *image frames* (cuadros de imagen), la figura 2.2 muestra una secuencia de tres cuadros, mediante un muestreo espacial y temporal de la luz incidente en la imagen, es decir, como se desplazan los píxeles en la imagen a través del tiempo.

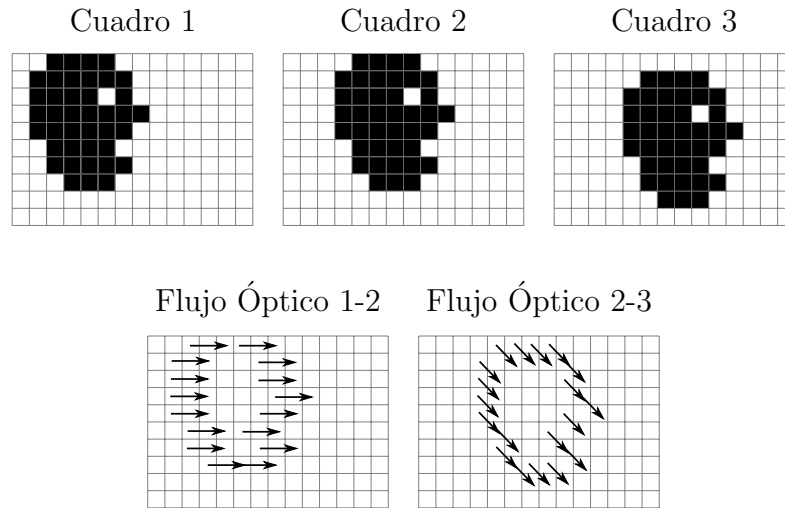


Figura 2.2: Ejemplo de captura del flujo óptico, por medio de cuadros de imagen consecutivos.

Para calcular el flujo óptico por medio el análisis de imágenes se utiliza el método de *Lucas-Kanade* [4], el cual funciona bajo dos suposiciones:

- La intensidad de un pixel en un determinado objeto no cambia entre cuadros consecutivos, refiriéndose a que un objeto no cambia en la escena, siempre la imagen proyectada de éste en la cámara es la misma.
- La segunda suposición dice que los vecinos cercanos a un pixel tienen un movimiento similar a este, esto permite evaluar una zona en la imagen.

Consideramos un pixel $I(x, y, t)$ en la primera imagen (x e y coordenadas dentro de la imagen y t un instante de tiempo) el cual se mueve una distancia de (dx, dy) en el siguiente cuadro después de un instante de tiempo dt , bajo las suposiciones mencionadas, podemos decir que:

$$I(x, y, t) = I(x + dx, y + dy, t + dt) \quad (2.2)$$

Usando series de Taylor [4] aproximamos el lado derecho de la ecuación, removiendo términos semejantes y dividiendo por dt obtenemos:

$$f_x u + f_y v + f_t = 0 \quad (2.3)$$

donde:

$$f_x = \frac{\partial f}{\partial x} ; f_y = \frac{\partial f}{\partial y} \quad (2.4)$$

Esta es la ecuación del flujo óptico, donde f_x y f_y son gradientes de la imagen, como f_t es gradiente del tiempo. Pero (u, v) son desconocidas, por lo que no podemos resolver la ecuación con dos incógnitas. Aquí es donde el método *Lucas-Kanade* toma grupos de píxeles de 3×3 , considerando las suposiciones mencionadas anteriormente, donde estos tienen el mismo movimiento. Ahora es posible resolver (f_x, f_y, f_t) ya que contamos con nueve ecuaciones y las mismas dos incógnitas, resultando con la siguiente ecuación:

$$\begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} \sum_i f_{x_i}^2 & \sum_i f_{x_i} f_{y_i} \\ \sum_i f_{x_i} f_{y_i} & \sum_i f_{y_i}^2 \end{bmatrix}^{-1} \begin{bmatrix} -\sum_i f_{x_i} f_{t_i} \\ -\sum_i f_{y_i} f_{t_i} \end{bmatrix} \quad (2.5)$$

De esta forma se toma un grupo de píxeles y calculamos el flujo óptico sobre ellos, pero el método descrito funciona solo con pequeños movimientos, fallando en condiciones cuando los píxeles en la imagen sufren grandes movimientos. Para so-

lucionar este problema utilizamos el algoritmo de pyramid, el cual escala la imagen removiendo los pequeños movimientos y reduciendo los grandes movimientos a pequeños [4].

El algoritmo de *pyramid* se encarga de realizar *downsampled* (este término se refiere a reducir la tasa de muestreo de alguna señal) a una imagen sucesivamente hasta algún límite dado, creando una colección de imágenes llamada pirámide. Existen dos tipos variantes del algoritmo de *pyramid*: la gaussiana y la laplaciana, en el método de *Lucas-Kanade* se utiliza la variante gaussiana, por lo que esta será descrita en detalle.

Para agregar a la pirámide una nueva capa G_{i+1} , debemos aplicar a la capa G_i un filtro gaussiano y luego eliminar las columnas y filas pares, esto nos genera una nueva imagen con un cuarto del área de la imagen en la capa G_i , iterando este proceso desde la imagen original G_0 producimos la pirámide entera [14].

Cuando se realiza un proceso de muestreo en una señal, en este caso de una imagen, puede producirse *aliasing*, el cual consiste en la distorsión de la señal original una vez que esta es muestreada. Para evitar esto el teorema de muestreo *Nyquist-Shannon* dice que es necesario muestrear una señal al doble de su frecuencia [20].

Es por esta razón que *pyramid* aplica un filtro gaussiano para la capa G_i de la pirámide antes de producir la capa G_{i+1} , esto reduce la frecuencia de la imagen en la capa G_i dando como resultado una imagen con menor distorsión en la capa G_{i+1} . Permitiendo tener una imagen de menor tamaño en una capa G_j , al final de la iteración, la cual tiene una baja distorsión frente a la imagen original en la capa G_0 .

2.4. OpenCV

Como se mencionó anteriormente, la obtención del flujo óptico se hace por el procesamiento de imágenes, para esto se utiliza como herramienta a *OpenCV* que permitirá realizar la captura de imágenes desde una cámara digital, para luego calcular de estas el flujo óptico.

OpenCV (Open Source Computer Vision Library) es una librería open source (código abierto) de *computer vision* (visión por computador), distribuida bajo la licencia BSD, la cual está escrita en C y C++, siendo además multiplataforma. También existen interfaces para Python, Ruby, Matlab y otros lenguajes.

OpenCV está diseñado para ser eficiente computacionalmente y enfocado en ser utilizado en aplicaciones de procesamiento en tiempo real. Para esto, fue escrito en C optimizado y toma ventaja de los procesadores multi núcleo, [14].

El proyecto fue iniciado por *Intel Research Labs* en 1990 con el propósito de hacer la infraestructura de la visión por computador universalmente disponible y de esta forma ampliar a su vez OpenCV fue pasado a código abierto [14].

2.5. Redes neuronales

Otro elemento importante en este documento al igual que el flujo óptico son las redes neuronales. Una red neuronal es la encargada de tomar como entrada el flujo óptico de una determinada imagen y con respecto a esto la red toma una decisión, esta decisión indica la dirección en la cual debe moverse según lo que haya en la escena en ese momento. Esta sección explica la razón por la que se utilizan redes neuronales, además de entregar la definición de estas, como funcionan y son capaces de aprender.

La utilización de redes neuronales viene dada por la intención de crear un sistema que toma como referencia el comportamiento biológico que tienen las aves al volar. Estas perciben el flujo óptico en su entorno el que luego son capaces de procesar y por medio de este dirigir su vuelo [13]. Este procesamiento es realizado por el cerebro del ave, por esta razón se plantea utilizar como medio de procesamiento del flujo óptico una red neuronal, la que en cierta medida funcionaría igual que interconexión neuronal del ave.

Una red neuronal tiene la finalidad de ser un modelo de una red neuronal biológica, que recibe un número determinado de entradas, las que son procesadas dentro de la red y producen una o más salidas. Una red neuronal biológica está conformada por

la interconexión de neuronas, las cuales son células nerviosas que reciben estímulos y conducen el impulso nervioso, por medio de un potencial de acción, a otras neuronas [15]. De la misma forma una red neuronal está formada por neuronas, a las que nos referimos por ahora como perceptrón, este funciona tomando varias entradas x_1, x_2, \dots , para producir una sola salida binaria, como se muestra en la figura 2.3.




Figura 2.3: Perceptrón con tres entradas: x_1 , x_2 y x_3 que genera un salida binaria, con valor 0 o 1.

En este caso se utilizan tres entradas, para computar la salida se introducen *weights* (pesos) w_1, w_2, w_3 , números reales que representan la importancia de cada entrada con respecto a la salida. Finalmente, la salida de la neurona es calculada como la sumatoria $\sum_j w_j x_j$, la salida binaria es 1 o 0 dependiendo de si el resultado de la sumatoria es menor o mayor al *threshold value* (valor de activación), el cual es un número real, parámetro de la neurona.

$$\text{salida} = \begin{cases} 0 & \text{si } \sum_j w_j x_j \leq \text{activación} \\ 1 & \text{si } \sum_j w_j x_j > \text{activación} \end{cases} \quad (2.6)$$

La red neuronal es conformada por la interconexión de perceptrones, los que se agrupan en *layers* (capas), de tal modo que las salidas de los perceptrones en la

primera capa son a su vez las entradas para los perceptrones de la segunda capa, así sucesivamente por la totalidad de las capas que constituyan la red neuronal.




Figura 2.4: Red neuronal conformada por 3 capas, la primera con 3 perceptrones, la segunda con 4 y la tercera y última con 1 perceptrón.

En la definición de perceptrón se menciona que este solo cuenta con una salida, en la figura 2.4 se muestra que un perceptrón tiene múltiples salidas, pero de hecho es la misma única salida que se comparte como entrada para los perceptrones de la siguiente capa.

A la hora de implementar la red neuronal es posible realizar algunas simplificaciones, redefiniendo el comportamiento de los perceptrones, podemos suponer que las entradas y los pesos de estos están definidos como dos vectores, con lo que ahora para producir la salida se calcula el producto punto entre la entrada y los pesos, $w \cdot x \equiv \sum_j w_j x_j$, también se mueve el valor de activación al otro lado de la inecuación y remplazándolo por el termino de *bias* (sesgo del perceptrón), $b \equiv -activación$, ahora el comportamiento del perceptrón se define como:

$$salida = \begin{cases} 0 & \text{si } w \cdot x + b \leq 0 \\ 1 & \text{si } w \cdot x + b > 0 \end{cases} \quad (2.7)$$

El sesgo puede definirse cómo que tan fácil el perceptrón puede producir una salida de valor 1, mientras más grande el sesgo más fácil producir una salida que sea 1.

Una de las principales características de las redes neuronales es su capacidad de aprender, para lograr esto la red debe variar tanto el valor de los pesos tanto como de los sesgos, para que de esta forma podamos tener la salida esperada a partir de una entrada determinada.

Para lograr este entrenamiento pequeños cambios en los parámetros de la red, pesos y sesgos, deben a su vez generar pequeños cambios en la salida, pero esto no sucede en las redes conformadas por perceptrones, cuando se aplica un pequeño cambio en los parámetros de un perceptrón produce que este cambie completamente su salida de 0 a 1, por ejemplo [29].

Este problema se soluciona reemplazando los perceptrones por *sigmoid neuron* (neurona sigmoide), en este tipo de neurona se pueden aplicar pequeños cambios en sus parámetros y esos se verán reflejados también en pequeños cambios en la salida. Una neurona sigmoide funciona de forma similar a un perceptrón donde la salida es calculada por $\sigma(w \cdot x + b)$, σ es una función sigmoide, definida cómo:

$$\sigma(z) \equiv \frac{1}{1 + e^{-z}} \quad (2.8)$$

Reemplazando el parámetro de la función por los de la neurona:

$$\frac{1}{1 + \exp(-\sum_j w_j x_j - b)} \quad (2.9)$$

Al ser sigma una función continua, ahora la salida de la red no es binaria, si no que valor real entre 0 y 1, como se muestra en al figura 2.5.

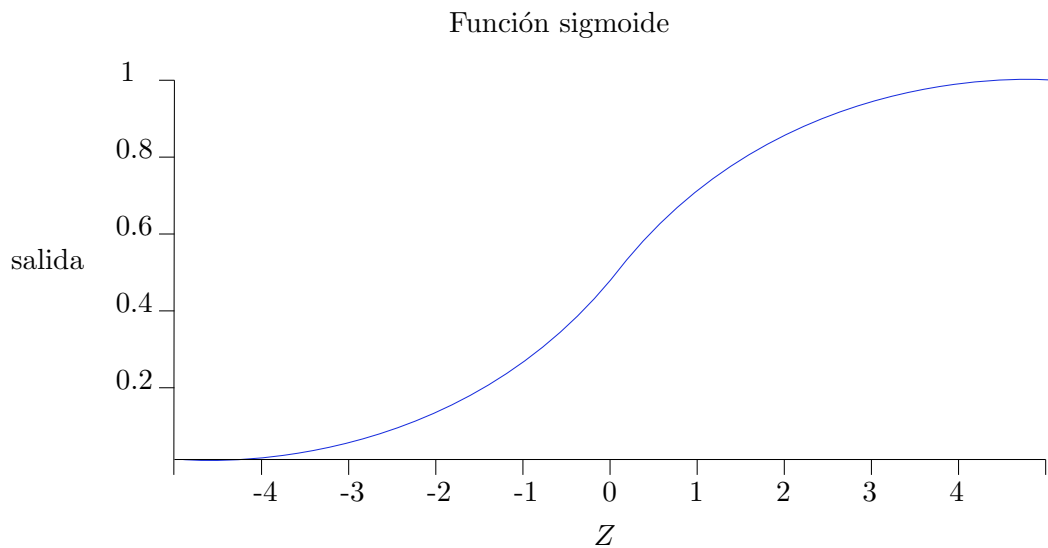


Figura 2.5: Función que utiliza una neurona sigmoide, como se puede ver la salida de la neurona será un valor continuo, entre 0 y 1.

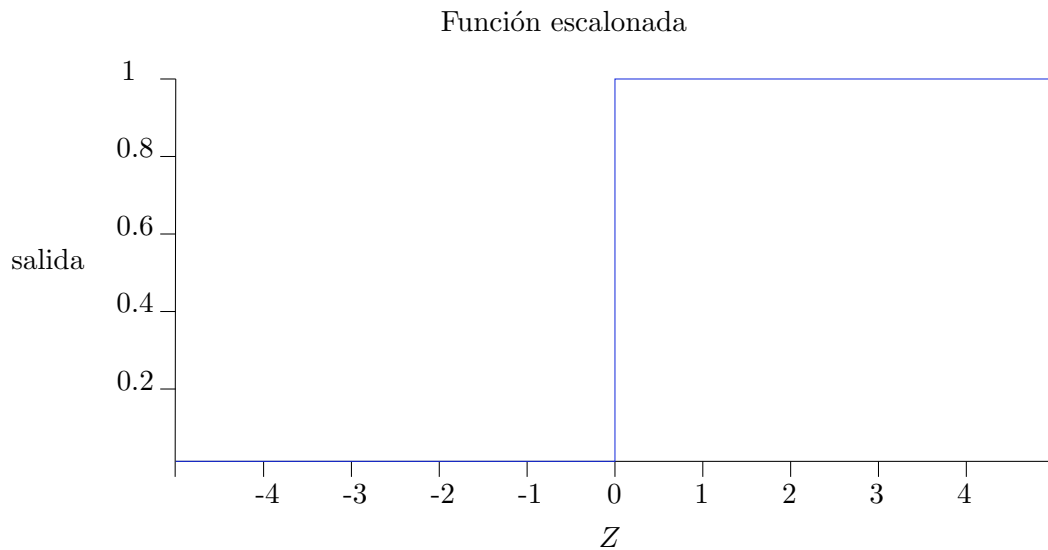


Figura 2.6: Función escalonada que utiliza un perceptrón, el que tiene una salida binaria, con valores 0 y 1.

Ya se mencionó anteriormente que la forma en que la red neuronal aprende es ajustando los valores de los pesos y sesgos de las neuronas que la conforman, para conseguir este objetivo se utiliza el algoritmo de *backpropagation*. Primero se le entrega un vector de entrada a la red neuronal, se conoce de antemano la salida que esta debe generar con estos valores, la red computa la salida y esta se compara con la esperada mediante una función de costo. El algoritmo tiene el objetivo de determinar qué cambios hay que hacer a los parámetros de la red para reducir la función de costo.

Si en una neurona j de la capa l introducimos algún cambio en los parámetros Δz_j^l , entonces la salida de esta será $\sigma(z_j^l + \Delta z_j^l)$. Este cambio se propagara por la red para producir un cambio en la función de costo C en la medida de $\frac{\partial C}{\partial z_j^l} \Delta z_j^l$, la finalidad es encontrar un Δz_j^l que reduzca C . Si $\frac{\partial C}{\partial z_j^l}$ tiene un valor alto, entonces C se puede reducir eligiendo Δz_j^l que contrarreste $\frac{\partial C}{\partial z_j^l}$. En cambio sí $\frac{\partial C}{\partial z_j^l}$ tiene un valor cercano a cero, Δz_j^l no tendrá mucha influencia a C por lo que esa neurona cuenta con parámetros cercanos a los óptimos.

Denotaremos el error en la neurona j en la capa l como δ_j^l y para una neurona en la salida de la red δ_j^L donde:

$$\delta_j^L = \frac{\partial C}{\partial a_j^L} \sigma'(z_j^L) \quad (2.10)$$

El término $\frac{\partial C}{\partial a_j^L}$ determina qué tan rápido cambia C en función de la salida de la neurona j en la capa L . $\sigma'(z_j^L)$ expresa que tan rápido cambia σ en función de z_j^L .

La función de error cuadrático es la función de coste, pero esta calcula el promedio de error sobre una muestra. Para aplicar *backpropagation* solo se utiliza un valor de error y no una muestra de estos, porque la función C será:

$$C = \frac{1}{2}(y - a^L)^2 \quad (2.11)$$

Ahora podemos reescribir el error de la salida de la red δ_j^L utilizando la función de coste como:

$$\delta^L = (a^L - y) \odot \sigma'(z^L) \quad (2.12)$$

Generalizando para el resto de las capas de la red, δ^l en términos del error de la siguiente capa δ^{l+1} :

$$\delta^l = ((w^{l+1})^T \delta^{l+1}) \odot \sigma'(z^l) \quad (2.13)$$

Con el error obtenido y propagado por la red solo falta modificar los pesos y sesgos, la tasa de cambio de C respecto a las sesgos de red se define como:

$$\frac{\partial C}{\partial b_j^l} = \delta_j^l \quad (2.14)$$

Y con respecto a los pesos:

$$\frac{\partial C}{\partial w_{jk}^l} = a_k^{l-1} \delta_j^l \quad (2.15)$$

2.6. Robot omnidireccional

En la realización de las pruebas es necesaria la captura de video, esta debe ser lo más similar a lo que se obtendría si se utilizara una cámara sobre un cuadricóptero. Esa es la razón por qué se utiliza un robot omnidireccional, este permite imitar en cierto grado la forma en la cual puede moverse un cuadricóptero, con algunas limitantes. La siguiente sección explica cómo logra un robot omnidireccional hacer esto.

Un robot omnidireccional (referido en este documento indiferentemente como robot o robot omnidireccional) es un robot que tiene la capacidad de moverse en cualquier dirección sin tener que rotar antes de moverse. Esto es posible por las ruedas omnidireccionales con que está construido el robot, estas tienen la capacidad de moverse libremente en dos direcciones, pueden rodar como una rueda normal o desplazarse lateralmente con las ruedas ubicadas perpendicularmente a lo largo de la circunferencia de la rueda, como se muestra en la figura 2.7.




Figura 2.7: Direcciones en las cuales puede moverse una rueda omnidireccional.

Esto permite que el robot puede trazar un camino en línea recta, en cualquier dirección, sin tener que hacer giros, además de poder combinar el trayecto con algún tipo de rotación para cambiar la dirección a la que apunta el robot, si es necesario. Esto es definido como un robot holonómico, en comparación con un robot normal no-holonómico el cual tiene 1,5 grados de libertad que puede desplazarse a través de

los ejes coordenados X e Y , pero requiere movimientos complejos para poder moverse en alguno de los dos ejes. Un robot holonómico que tiene 2 grados de libertad puede moverse libremente por ambos ejes X e Y [25].

Para lograr que el robot se desplace en cualquier dirección es necesario calcular la velocidad y dirección de giro para cada rueda de forma independiente. En la figura 2.8 se muestra la dirección en la que deben girar las ruedas para mover el robot hacia adelante y atrás, en la figura 2.9 hacia la derecha e izquierda.

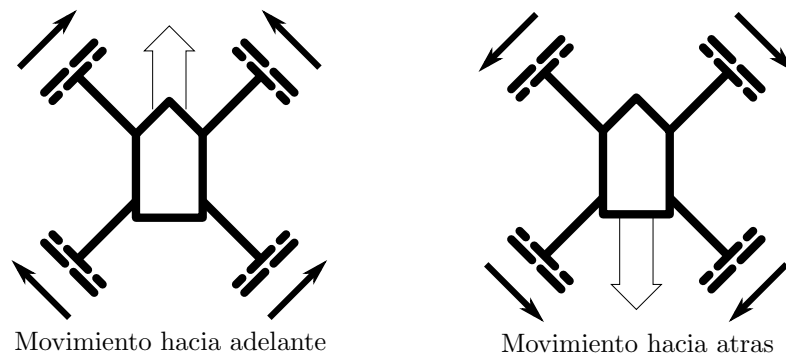


Figura 2.8: Las flechas muestran la dirección en la que las ruedas deben girar para lograr los movimientos hacia adelante y atrás.

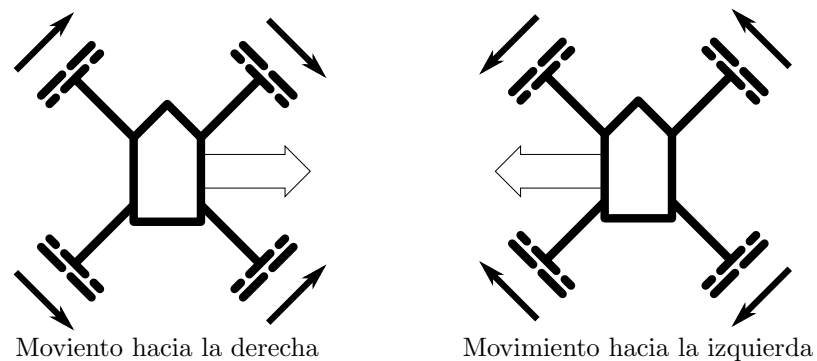


Figura 2.9: Las flechas muestran la dirección en la que las ruedas deben girar para lograr los movimientos hacia la derecha e izquierda.

En estos movimientos la velocidad de las ruedas siempre es la misma, solo cambia su dirección de giro, al modificar la velocidad el robot puede desplazarse en una dirección que combina los movimientos de adelante y atrás con los de derecha e izquierda, como muestra la figura 2.10.

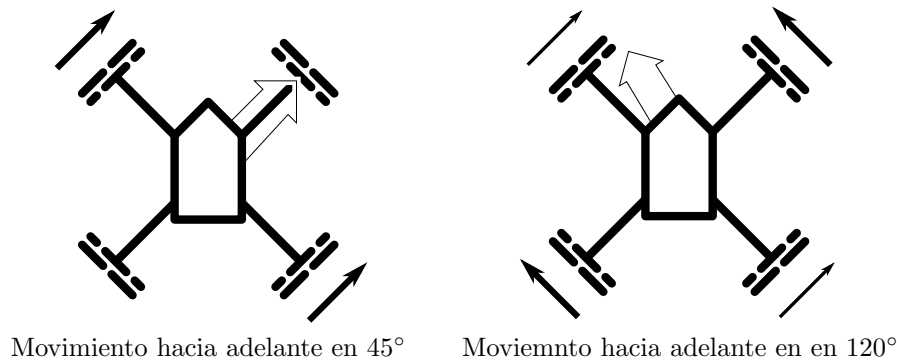


Figura 2.10: Izquierda movimiento del robot en 45° donde solo se mueve un par de ruedas. Derecha movimiento del robot en 120° donde un par de ruedas se mueve más rápido que otro, representado por el grosor la fecha que acompaña a las ruedas.

2.7. Microcontrolador

Para el control y comunicación del robot es necesario contar con alguna unidad de procesamiento, en este caso se hace uso de un microcontrolador. Este se encarga recibir las señales de radio control e interpretarlas, comunicarse vía puerto serial con el computador externo y controlar la dirección y velocidad de los motores.

Un microcontrolador es un pequeño computador fabricado en un solo circuito integrado, lo que es llamado sistema en un chip (SoC por sus siglas del inglés: *system on a chip*). Un microcontrolador consta de uno o más CPUs junto con memoria, periféricos de entradas y salidas programables y almacenamiento destinado al alojamiento del programa que ejecuta el microcontrolador.

Como se puede ver un microcontrolador está compuesto de distintos elementos embebidos que permiten su funcionamiento de forma autónoma con la adición poco o ningún componente, evitando la dependencia de elementos periféricos.

El microcontrolador utilizado es un ATmega328P [10] y dentro de los elementos que lo conforman se encuentran:

CPU: Se encarga de la ejecución de programas, teniendo acceso la memoria, ejecutando cálculos, controlando periféricos y manejando interrupciones. La CPU utiliza

una arquitectura Harvard que se caracteriza en tener buses y memoria separados para los programas y los datos. Además de hacer uso de un set de instrucciones RISC (del inglés *reduced instruction set computer*) funcionando a una frecuencia de 16 MHz.

Registros: Espacios dentro de la CPU donde se almacenan datos que se utilizan para realizar las operaciones dentro de los demás componentes de la CPU, además se guardan los resultados de la ejecución de instrucciones. El ATmega328P cuenta con 32 registros de 8 bit cada uno.

Memoria: Se cuentan con tres tipos de memoria:

- SRAM: 2 KBytes de memoria interna compartida con los registros de entrada y salida.
- Flash Program Memory: Esta memoria reprogramable es compartida para almacenar los programas y el *Boot Loader*, con una capacidad de 32 KBytes.
- EEPROM: Memoria para almacenar datos con una capacidad de 1 KBytes.

Entradas y salida: Todos los pines del ATmega328P tiene la funcionalidad *Read-Modify-Write* lo que significa que la dirección de cada pin puede ser cambiada, de entrada, a salida o viceversa. Se cuenta con 23 pines de los que por sus funciones especiales quedan disponibles para libre uso 20. Los pines PB6 y PB7 son usados para el cristal externo y PC6 para reiniciar el microcontrolador. Estos pines también comparten funcionalidades especializadas como lo son: SPI, I2C, PWM, puerto serial, conversor análogo digital y ISCP [10].

El microcontrolador es utilizado bajo la plataforma de desarrollo *Arduino*, la que se define como una plataforma de código abierto basada en hardware y software fácil de usar. Esta proporciona el hardware por medio de las *Arduino Board* y el software en *Arduino programming language* y el IDE de desarrollo *Arduino Software* [9].

En específico se utiliza la placa *Arduino UNO Rev 2*, especificaciones en el anexo B, y el IDE en su versión 1.8.2.

2.8. Controlador para motores

Un elemento necesario para el funcionamiento del robot son los controladores para motores, estos componentes son un intermediario entre el microcontrolador y los motores. Estos permiten que las señales de control puedan actuar sobre los motores.

Un controlador para motores es un dispositivo que maneja el desempeño de un motor eléctrico, este incluye mecanismos para arrancar y detener el motor, seleccionar la dirección de rotación y regular la velocidad [33]. La mayoría de los controladores utilizan un circuito eléctrico llamado puente H (también referido como *full-bridge*, este permite aplicar corriente sobre una carga en cualquier dirección, con esto un motor de corriente continua puede girar en ambas direcciones [37].

El nombre es derivado de su representación gráfica, como se muestra en la figura 2.11.A, que tiene una forma de H. El circuito cuenta con cuatro interruptores, los que son accionados de apares, según la figura 2.11.B, S1 y S4 pueden estar en estado cerrado, mientras S2 y S3 en abierto, en esta configuración la corriente circula en una dirección a través del motor M, si en cambio S2 y S3 están cerrados y S1 y S4 abiertos como en la figura 2.11.C la corriente sobre el motor M circulara en la dirección opuesta. Los interruptores S1 y S2, al igual que S3 y S4 nunca son activados al mismo tiempo, ya que esto genera un corto circuito sobre la fuente de voltaje.




Figura 2.11: Funcionamiento de un puente H. A estructura del puente H. B interruptores S1 y S4 cerrado. C interruptores S3 y S2 cerrados.

El controlador utilizado es el L298N, cual contiene dos puentes H compatibles con nivel lógico estándar TTL y puede manejar cargas inductivas, como motores de corriente directa. Cuenta con dos entradas de control para cada motor además de una para la habilitación del puente H. En la descripción de un puente H se mencionó el control sobre 4 interruptores, pero el controlador solo cuenta dos entradas de control por cada puente H, esto se debe a que dos interruptores nunca son activados al mismo tiempo, por ejemplo: S1 y S2. Esto permite que el control sobre estos interruptores puede ser compartida negando la señal de entrada a uno de estos, es decir, que cuando un interruptor está activado el otro siempre esta desactivado. Esta misma situación se da para los interruptores S3 y S4. En la figura 2.12 se muestra el control lógico que realiza el L298N sobre el puente H y la utilización de transistores de canal-N como interruptores.




Figura 2.12: Control lógico dentro del L298 sobre uno de sus puente H.

Además se puede ver que el controlador recibe una tercera entrada En (sigla del inglés: *Enable*), está activa o desactiva el puente H dependiendo del estado lógico que presente: Si el estado es alto el puente H funcionara según corresponda con las entradas In1 e In2, pero si está en estado bajo desconecta ambas salidas OUT1 y OUT2 [35].

2.9. Sensor óptico de movimiento

Este es otro componente que es parte del robot omnidireccional, permite registrar los movimientos realizados sobre la superficie en la que se ha desplazado. Estos datos son necesarios ya que forman una estrecha relación con la salida que entrega la red neuronal y son utilizados tanto para realizar el entrenamiento de la red como comprobar si este entrenamiento ha sido efectivo o no. A continuación se muestra el funcionamiento del sensor y cómo entrega la información de posicionamiento.

El sensor óptico de movimiento acoplado al robot que tiene la función registrar las trayectorias que este sigue, proviene de un *mouse* óptico (referido en este documento

indistintamente como *mouse* o *mouse* optico). Este utiliza una fuente de luz, en este caso un LED rojo y detector de luz como una matriz de fotodiodos, los que forman una pequeña cámara digital, para detectar el movimiento relativo a una superficie.

El sensor del *mouse* forma una imagen capturando las texturas sobre la superficie en que se encuentra, estas texturas son resaltadas por el ángulo de incidencia de la luz proveniente del LED. Se toma una continua sucesión de imágenes de la superficie, las que son comparadas unas con otras para determinar cuánto se ha movido el *mouse*.

Para determinar esto el *mouse* evalúa dos imágenes consecutivas y busca coincidencias de la primera imagen en la segunda, cuantificando cuanto se desplazado la segunda imagen sobre la primera, así se puede cuantificar el movimiento del *mouse*.

El *mouse* toma cientos de imágenes por segundo. Dependiendo de qué tan rápido se esté moviendo cada imagen va a estar desplazada con la imagen anterior por una fracción de pixel o tanto como varios pixeles. El *mouse* procesa matemáticamente las imágenes usando correlación cruzada para calcular cuánto cada imagen, de la sucesión de imágenes, se ha desplazado desde la imagen anterior.

El protocolo de comunicación utilizado es PS/2 (*IBM Personal System 2*), el cual es serial, síncrono y bidireccional. Utiliza dos líneas de comunicación DATA por la que se envían los datos y CLOCK que proporciona la señal de reloj, el dispositivo que en este caso es el *mouse* siempre es el que genera la señal de reloj, cuando las dos líneas están en alto el dispositivo puede enviar datos, pero el *host* tiene el control sobre la línea de datos, por lo que puede inhibir la comunicación enviando la señal de comunicación a low [17].

El *mouse* envía la información de estado de los botones, derecho, central e izquierdo, además del desplazamiento en el eje X e Y en un paquete de tres *byte*, que se muestra en la tabla 2.1. El movimiento es un entero de 9 *bite* a complemento 2, el *bit* más significativo es Y sign y X sign que aparece en el primer *byte*. Este valor representa la diferencia relativa a la posición del *mouse* desde la última vez que se envió el paquete de datos. El rango va de -255 a +255, si el rango es excedido el

correspondiente *bit* de *overflow* es activado [16].

Tabla 2.1: Paquete de datos del movimiento del *mouse*.

	Bit 7	Bit 6	Bit 5	Bit 4	Bit 3	Bit 2	Bit 1	Bit 0
Byte 1	Y overflow	X overflow	Y sign	X sign	always 1	Btn central	Btn derecho	Btn izquierdo
Byte 2	Movimiento X							
Byte 3	Movimiento Y							

En el presente apartado se abordaron las temáticas necesarias para el desarrollo del proyecto. Dando a conocer que es como se calcula el flujo óptico, porque se utiliza y cómo funciona una red neuronal, también se da a conocer la forma en que un robot omnidireccional es capaz de desplazarse y razón por la que se usa ese tipo de robot. Además de abarcar otras temáticas relacionadas: visión por computador, vehículos aéreos no tripulados y elementos necesarios para la implementación: controlador de motores, microcontrolador y sensor óptico de movimiento.

3. Implementación

En este capítulo se detallan los elementos que fueron necesarios implementar para poder cumplir con el objetivo principal. Dentro de estos esta la forma como se obtiene el flujo óptico desde la captura de video; el funcionamiento de la red neuronal, el procesamiento de una entrada para producir una salida y el entrenamiento de esta; el diseño y construcción del robot omnidireccional.

3.1. Flujo óptico

El flujo óptico es la información que se obtiene desde la captura de imágenes y la que posteriormente será entregada a la red neuronal. Para procesar las imágenes y obtener como resultado el flujo óptico se utiliza la librería *OpenCV* en un programa escrito en *Python*, esta entrega el método *calcOpticalFlowPyrLK* que implementa el algoritmo de *Lucas-Kanade*, más detalle en la sección 2.3, la cual recibe como parámetros dos imágenes img_0 e img_1 y los puntos p_0 donde calcular el flujo óptico.

Los puntos p_0 son una sucesión de pares coordenados dentro de img_0 , los que tiene una posición predefinida a un intervalo regular de pixeles. El algoritmo usa los pixeles de img_0 correspondientes a los puntos definidos y calcula donde se han desplazado en img_1 , dando como resultado una nueva sucesión de puntos, estos nuevos puntos p_1 indican la nueva posición que tiene p_0 en img_1 .

Una vez obtenido p_1 estos son procesados para dejar solo los puntos que han podido ser calculados correctamente. Esto se hace analizando la distancia de desplazamiento y las banderas de estado y error que acompañan a cada punto, si el

desplazamiento es mayor a 50 píxeles o una de las banderas esta como *False* ese punto es descartado y reemplazado por su valor correspondiente en p_0 .

Las imágenes img_0 e img_1 son obtenidas secuencialmente *frame* por *frame* desde la fuente de video, la cual puede ser un archivo de video o directamente de una cámara digital. img_1 es el siguiente *frame* después de img_0 , cuando se procesa img_0 se copia el *frame* a img_1 , para luego obtener el siguiente *frame* para img_0 .

El flujo óptico es representado por el desplazamiento que tiene P_0 en P_1 , el que es en el plano de imagen tanto en eje X como en el Y .

A continuación en el algoritmo 1 se describe el pseudocódigo del cálculo del flujo óptico.

Algorithm 1 Calculo Flujo Óptico

```

1: function CALOPTICALFLOW
2:    $frame \leftarrow cam.read()$       ▷ Obtiene el siguiente frame de la fuente de video
3:    $img_1 \leftarrow gray(frame)$       ▷ Convierte el frame a escala de grises
4:    $p_1, st, err \leftarrow calcOpticalFlowPyrLK(img_0, img_1, p_0)$ 
5:    $img_0 \leftarrow img_1$ 
6:    $p_1 \leftarrow goodPoints(p_1, st, err)$       ▷
7:   return  $p_1$ 
8: end function

```

3.1.1. Captura de flujo óptico

Para obtener el flujo óptico se utiliza una cámara de digital conectada por USB con una resolución de 640x480 píxeles, Con formato de pixel YUV 4:2:2, velocidad de obturación de hasta 1/30 seg

De las imágenes obtenidas desde la cámara se calcula el flujo óptico en una matriz de 21 x 5 puntos, cada punto está separado por 30 píxeles uno del otro. La matriz se extiende a todo el ancho la imagen y desde los 200 hasta 330 píxeles de alto.

Los puntos se ubican en esta posición para así obtener la información que entrega la pista de pruebas, en la figura 3.1 y 3.2 se puede ver la captura de flujo óptico

capturada desde el robot.




Figura 3.1: Captura de flujo óptico desde el robot omnidireccional.




Figura 3.2: Captura de flujo óptico de imágenes desde el robot omnidireccional, frente a un obstáculo.

El plano de la cámara está ubicado perpendicularmente al del desplazamiento del robot, por lo que solo se entrega a la red neuronal el flujo óptico que es calculado en el eje X de la imagen, es decir, la cuantificación del desplazamiento lateral de los píxeles en la imagen.

Por cada *frame* en el que se calcula el flujo óptico se obtiene un arreglo con un tamaño de 105 elementos que proporciona el desplazamiento de los puntos con respecto a la matriz antes descrita. Además del desplazamiento que tuvo el robot sobre el eje X de la pista, en la figura 3.3 se muestra un ejemplo de esto. Esta es la información que posteriormente se le entrega a la red neuronal.

[15.1345, 45.7654, 75.4358, ... 615.5472, 645.8256, 675.1234], [0.75]

Figura 3.3: Ejemplo del flujo óptico obtenido de un *frame* más el desplazamiento del robot.

El algoritmo 2 muestra el pseudocódigo de cómo se realiza la captura del flujo óptico.

Algorithm 2 Captura de datos

```

1: function DATACAPTURE
2:   data_input  $\leftarrow$  []
3:   data_output  $\leftarrow$  []
4:   data_mouse  $\leftarrow$  []
5:   while video_capture do
6:     optical_flow_calc  $\leftarrow$  calcOpticalFlow()
7:     optical_flow_data  $\leftarrow$  getXComponent(optical_flow_calc)    ▷ Obtiene el
      componente X del flujo óptico
8:     x, y  $\leftarrow$  getMovement()    ▷ Obtiene el desplazamiento del robot
9:     data_input.append(optical_flow_data)
10:    data_output.append(normalize(x))
11:    data_mouse.append([x, y])
12:  end while
13:  saveData(data_input, data_output, data_mouse)
14: end function

```

La información obtenida de cada *frame* es almacenada en tres arreglos distintos: para el flujo óptico, el movimiento normalizado del robot en el eje *X* y la información completa del movimiento tanto en el eje *X* como en el *Y*. Cuando termina la captura de video se almacenan los tres arreglos en un archivo serializado. Por cada recorrido del robot por la pista se tiene una captura continua de video, entonces también se tiene un archivo con el flujo óptico y el desplazamiento realizado.

3.2. Red neuronal

La red neuronal es una adaptación de la implementada por *Michael Nielsen* en del libro *Neural Networks and Deep Learning* escrita en *Python* [28] haciendo uso de la librería *numPy*, que contiene un paquete de funciones matemáticas para el trabajo con matrices multidimensionales [19], está tiene la finalidad de recibir la información visual obtenida por el cálculo del flujo óptico y direccionar correctamente el robot por la pista. Aquí se documenta el funcionamiento de la red y el método que se utiliza para hacer que esta aprenda.

3.2.1. Funcionamiento

Para representar la estructura de la red, la que cuenta con *weights* y *biases* (pesos y sesgos) por cada neurona, se utiliza un arreglo multidimensional por cada parámetro. Para los sesgos se utiliza una matriz de dos dimensiones, así obtenemos b_{ij} que representa el sesgo para la j -ésima neurona en la i -ésima capa. La representación de los pesos se hace con una matriz de tres dimensiones, dando w_{ijk} que se traduce como el peso de la j -ésima neurona de la i -ésima capa con la k -ésima neurona de la $i+1$ -ésima capa.

La obtención de la salida de red neuronal, también llamado *feedforward*, se hace ejecutando para cada capa la siguiente función:

$$a' = \sigma(z) \tag{3.1}$$

donde z :

$$z = (wa + b) \tag{3.2}$$

Si aplicamos la función σ a la i -ésima capa usamos la función sigmoide σ en cada elemento del arreglo z , z contiene el resultado del producto punto entre los pesos y el arreglo a más el sesgo de cada neurona. Donde a es la salida de la $i-1$ -ésima capa o si es la primera la entrada de la red. Dando como resultado la salida a' la cual es el resultado i -ésima capa. El pseudocódigo se muestra en el algoritmo 3.

Algorithm 3 Red neuronal

```

1: function FEEDFORWARD(a)
2:   for  $b, w \leftarrow \text{biases, weights}$  do
3:      $a \leftarrow \sigma((w \cdot a) + b)$ 
4:   end for
5:   return  $a$ 
6: end function

```

La implementación del algoritmo de *backpropagation* consta de realizar el proceso de *feedforward* para una determinada entrada y poder calcular con su salida esperada y la siguiente ecuación de error:

$$\delta^L = (a^L - y) \odot \sigma'(z^L) \quad (3.3)$$

Donde a^L y z^L pertenecen a la última capa L , el arreglo δ^L representa la influencia de la salida de la red en la función de costo. Ahora se obtiene la diferencia de los sesgos y pesos de la capa L :

$$\begin{aligned} b^L &= \delta^L \\ w^L &= \delta^L \sigma'(z^L)^t \end{aligned} \quad (3.4)$$

Este procedimiento se propaga hacia atrás en la red por las capas $L - 1, L - 2, L - 3 \dots$ hasta alcanzar la primera capa. Para luego actualizar los parámetros de red aplicando las diferencias obtenidas bajo un coeficiente de aprendizaje, este determina cuanto se deben modificar los parámetros existentes en la red con respecto a las diferencias obtenidas del algoritmo de *backpropagation*.

3.2.2. Entrenamiento

Para entrenar la red neuronal se utiliza como entrada el flujo óptico obtenido de la captura de video de la pista de pruebas y como salida esperada la dirección en la cual se mueve el robot sobre el eje X de la pista. Para modificar los parámetros al interior de la red (pesos y sesgos), que se traduce como el aprendizaje de la red, se utiliza la técnica de *backpropagation*, véase sección 2.5.

La implementación de red reorganiza de forma aleatoria los datos de entrenamiento e itera el entrenamiento un número determinado de veces. Al final de cada iteración se valida el entrenamiento con los datos de prueba, así se evalúa el transcurso del entrenamiento. Al finalizar la iteración se guarda la red que tuvo un mejor desempeño en la validación del entrenamiento.

La generación de set de datos del cual la red aprende se hace por medio de un esquema *on-the-fly* [31], el cual tiene como objetivo que la red neuronal imite el comportamiento de un humano al realizar la misma tarea, la cual es desplazar el robot por la pista de pruebas. Por lo que el flujo óptico y la dirección del robot se obtiene de la conducción manual del robot.

La salida esperada de la red neuronal, que representa la dirección en la cual debe moverse el robot mientras se desplaza por la pista y que es utilizada como parámetro en el entrenamiento por *backpropagation*, es obtenida por el seguimiento de los movimientos que realice el robot por medio de un sensor óptico de movimiento. La arquitectura de la red neuronal tendrá una sola salida la que estará normalizada entre cero y uno, por lo que la dirección del robot será representada por un solo valor.

Se realizan dos entrenamientos: el primero con los datos obtenidos del robot al desplazarse sin obstáculos, el segundo utiliza los mismos datos y se le suman los datos de los recorridos con obstáculos. Son usadas dos redes neuronales, cada red neuronal tiene 105 entradas y una sola salida, la primera solo tiene la una capa oculta de 50 neuronas mientras que la segunda cuatro capas ocultas con 100, 70, 40 y 10 neuronas respectivamente. En cada entrenamiento consta de 30 iteraciones y un coeficiente de entrenamiento de 0.5. En la tabla 3.1 se muestra el número de datos utilizados para cada etapa del entrenamiento. El algoritmo 4 muestra el pseudocódigo del entrenamiento.

Tabla 3.1: Datos de entrenamiento y validación

Etapa	Datos de entrenamiento	
	Entrenamiento	Validación
1	34755	7367
2	66297	20635

Algorithm 4 Entrenamiento

```

1: function TRAINING(training_data, test_data, epoch, eta)
2:   result  $\leftarrow$  []
3:   for epoch do
4:     training_data  $\leftarrow$  shuffle(training_data)
5:     for x, y  $\leftarrow$  training_data do
6:       backpropagation(x, y, eta)
7:     end for
8:     effectiveness, mse = evaluate(test_data)
9:     result.append([effectiveness, mse])
10:  end for
11:  return result
12: end function

```

3.3. Conducción autónoma

El objetivo principal es conseguir la conducción autónoma del robot y que este sea capaz de evadir los obstáculos que se dispongan en la pista de pruebas. Para lograr esto es necesario utilizar la captura de video en tiempo real para calcular el flujo óptico, una vez obtenido se entregado a la red neuronal. Una vez que la red neuronal entrega el resultado este es utilizado para dirigir el robot, para volver a repetir el proceso en el siguiente *frame* de la captura de video.

La captura de video consiste en obtener los *frame* que envía la cámara digital, para posteriormente calcular el flujo óptico por cada uno de estos. Una vez que se tiene el flujo óptico a este se le obtiene su componente en eje X y es entregado a la red neuronal.

La red realiza el proceso de *feedforward* y el valor entregado, que está normalizado entre cero y uno, corresponde a la dirección a la cual debe moverse el robot. La información que recibe el robot tiene un rango entre 1000 y 2000, por lo que antes de ser enviada debe ser normaliza dentro de estos valores.

Después de enviar los datos al robot se leen los provenientes del sensor de movimiento, los cuales son almacenados para tener un registro de los movimientos realizados por el robot al realizar la conducción autónoma.

Una vez terminado el procedimiento se obtiene el nuevo *frame* de la cámara de video y se repite el proceso mencionado, el algoritmo 5 muestra el pseudocódigo de la conducción autónoma.

Algorithm 5 Conducción autónoma

```

1: function AUTODRIVING
2:   data_mouse  $\leftarrow$  []
3:   while video_capture do
4:     optical_flow_calc  $\leftarrow$  calcOpticalFlow()
5:     optical_flow_data  $\leftarrow$  getXComponent(optical_flow_calc)    ▷ Obtiene el
        compoenete X del flujo óptico
6:     net_output  $\leftarrow$  net.feedforward(optical_flow_data)
7:     move_data  $\leftarrow$  normalize(nte_output)
8:     writeData(move_data)    ▷ Envía los datos al robot para realizar el
        movimiento correspondiente
9:     x, y  $\leftarrow$  getMovement()    ▷ Obtiene el desplazamiento del robot
10:    data_mouse.append([x, y])
11:  end while
12:  saveData(data_mouse)
13: end function

```

3.4. Procesamiento de datos

Todo el procesamiento de datos es realizado por un computador externo al robot, las tareas que este realiza son: la captura de datos, entrenamiento de red neuronal y conducción autónoma. Para esto se utiliza el lenguaje de programación *Python* en su versión 2.7.

El computador utilizado es un notebook *ProBook* 4440s con las siguientes características:

- **Procesador:** Intel Celeron(R) CPU B840 1.90GHz x 2
- **Memoria:** 4 GB
- **Sistema Operativo:** Debian GNU/Linux 8 (jessie)
- **Arquitectura:** 64-bit

Los periféricos utilizados son conectados por medio de puerto USB, el robot cuenta con un *hub* donde está conectada la cámara digital, el sensor de movimiento y el

Arduino UNO, por lo que al computador solo llega una interfaz USB.

Para obtener los datos del sensor de movimiento se programó un *thread* que está constantemente leyendo el archivo `/dev/input/mice` el cual entrega el dato *raw* (en bruto) del movimiento del sensor. Para comunicar el Arduino UNO también se utiliza un *thread* que establece comunicación serial que está configurada a 57600 *baudios*.

3.5. Robot omnidireccional

El diseño del robot está basado en uno del repositorio de diseños 3D thingiverse (<https://www.thingiverse.com/thing:167923>), de este se tomó el concepto de las ruedas omnidireccionales las que se rediseñaron para este robot en específico.

3.5.1. Diseño del robot

El diseño del robot contempla el uso de 4 ruedas omnidireccionales, las que se sitúan de forma perpendicular alrededor del robot, cada rueda está separada una de la otra por 90° . La construcción de cada rueda consta de dos ruedas paralelas rotadas sobre el eje de giro 45° una de la otra, unidas por medio de tres tornillos. Cada una de estas ruedas cuenta a su vez con cuatro ruedas o rodillos en su circunferencia colocadas perpendicularmente separadas cada una por 90° , esto permite tener un solapamiento con los rodillos de la otra rueda ubicada paralela a esta. Los rodillos van fijos a un eje de 2mm que los atraviesa y puede girar libremente en el soporte de la rueda. Cada rueda tiene un diámetro de 80mm y un ancho de 40mm, en la figura 3.4 se puede ver la construcción de esta.




Figura 3.4: Diseño de rueda omnidireccional.

Cada rueda cuenta con un acople, que en un extremo va atornillado a la rueda por tres tornillos y en el otro va sujeto a presión al eje de la caja reductora del motor, como muestra la figura 3.5.




Figura 3.5: Acople para unir las ruedas del robot con la caja reductora de los motores.

A su vez los motores y su respectiva caja reductora están unidos por una extensión que permite unirlos al cuerpo principal, de esta forma se puede modificar el diámetro total del robot sin tener que modificar también el cuerpo principal, 3.6




Figura 3.6: Extensión para unir los motores.

En el cuerpo principal se posicionan el resto de los componentes necesarios para el funcionamiento, estos son el microcontrolador, los *driver* para los motores, las baterías, el receptor de radio, la cámara digital y sensor de movimiento. El cuerpo fue diseñado de acuerdo a las dimensiones de cada componente, de esta manera se pueden colocar de manera precisa, además de usar las fijaciones para las cuales fueron diseñados, que se muestra en la figura 3.7.




Figura 3.7: Cuerpo principal donde se alojan todos los componentes del robot omnidireccional.

El compartimiento para las baterías es ubicado debajo de cuerpo principal, este permite la fijación de baterías de litio estándar 18650 colocadas en serie, permite colocar un total de 3 baterías. El diseño se puede ver en la figura 3.8.




Figura 3.8: Compartimiento para colocar en serie las tres baterías de litio 18650.

Debajo de este, en contacto con la superficie donde se desplaza el robot, va el soporte del sensor óptico de movimiento. En la figura 3.9 se puede ver que el soporte

cuenta con perforaciones por las que se atornilla al cuerpo principal por medio de separadores, para ajustar la altura del soporte para que quede posicionado de forma precisa sobre la superficie.




Figura 3.9: Soporte para la instalación del sensor óptico que registra las trayectorias realizadas por el robot.

Al frente del robot va instalada la cámara digital, esta va sobre un soporte que se ajusta a sus dimensiones, el que a su vez va unido al cuerpo principal, en la figura 3.10 se muestra el diseño, que incluye una ranura para posicionar el cable de la cámara.




Figura 3.10: Soporte sobre el cual va la cámara digital.

El ensamblaje completo con todos los componentes diseñados para la construcción del robot se puede ver en la figura 3.11. Todos los acoples mecánicos fueron realizados con tornillos de métrica 3 (M3), cortados una medida específica para cada unión.




Figura 3.11: Ensamble completo del robot omnidireccional.




Figura 3.12: Robot completo con todos los componentes.

Los componentes mencionados y diseñados específicamente para el robot (ruedas omnidireccionales, extensiones para los motores, cuerpo principal, compartimiento para baterías, soporte para la cámara digital y soporte para el sensor óptico) fueron diseñados con la herramienta FreeCAD, un modelador 3D paramétrico. Para el proceso de fabricación se utiliza Sli3r, que convierte los modelos 3D a instrucciones para la impresora 3D. Las piezas son construidas con impresión 3D de filamento fundido (FFF del termino en inglés: *Fused Filament Fabrication*) con las siguientes especificaciones:

- **Material:** PLA 1.75mm
- **Diámetro boquilla:** 0.4mm
- **Altura de capa:** 0.2mm
- **Temperatura de boquilla:** 220°
- **Temperatura placa:** 60°

- **Velocidad impresión:** 30mm/s
- **Velocidad recorrido:** 60mm/s
- **Relleno:** 15 %
- **Patrón relleno:** rectilíneo

La especificación completa de la configuración de la impresora se puede ver en el anexo C

3.5.2. Control de las ruedas

El desplazamiento del robot es producido por cuatro motores, estos no van en conexión directa con las ruedas, si no que por medio de una caja reductora y esta transmite el movimiento del motor a las ruedas. Los motores son de tamaño estándar 130 alimentados con 12v de corriente continua (DC) con una caja reductora TT a 90°, de relación 120:1, como se muestra en la figura 3.13.




Figura 3.13: Motor con caja reductora del robot omnidireccional.

Los motores son controlados por el *driver* (controlador) L298N, este cuenta con dos puentes H, uno por motor, por lo que el robot utiliza dos controladores. Los controladores son alimentados con 12v y estos son los que suministran la energía a

los motores.

La fuente de energía del robot es proporcionada por baterías de litio, se utilizan tres de estándar 18650 conectadas en serie, cada batería es de 3,7v, por lo que en total en conjunto se tiene un voltaje nominal de 11.1v, con las baterías cargadas al 100 % de su capacidad su voltaje es de 12,6v.

Los movimientos del robot son realizados posteriormente al cálculo de las velocidades y dirección de giro de cada rueda, esta tarea es realizada por el microcontrolador, el utilizado es un ATmega328P bajo la infraestructura de Arduino UNO. El microcontrolador toma como entrada la velocidad y dirección a la cual debe moverse y realiza los cálculos para obtener los valores asociados a cada motor. Las salidas de control van dirigidas a los controladores de los motores, se utilizan tres líneas por cada motor, figura 3.14, dos para controlar la dirección del motor y la tercera para la velocidad, por lo que se tiene un total de doce salidas de control para todos los motores.

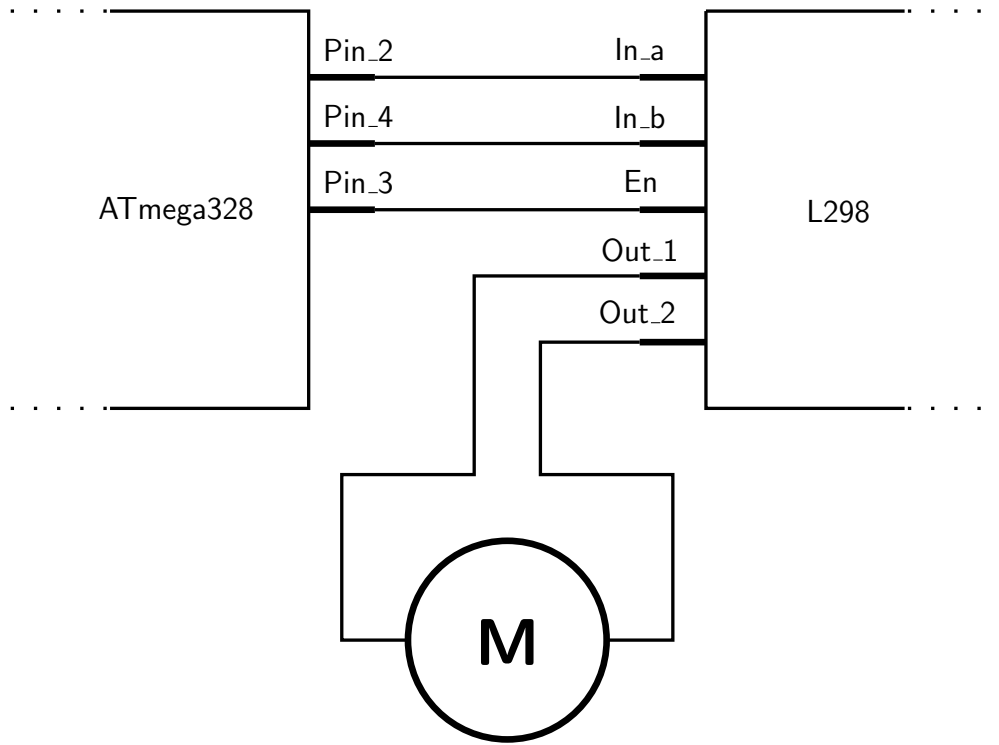


Figura 3.14: Control del microcontrolador ATmega328P sobre uno de los motores, por medio del controlador L298N.

El control sobre los motores se hace de la siguiente manera: En el controlador L298N las salidas reflejan el estado en el que se encuentran las entradas, por lo que OUT1 tendrá el mismo estado que In1, lo mismo sucede cuando con OUT2 y In2, siempre y cuando En este en estado lógico alto. La tabla 3.2 muestra el comportamiento del controlador con respecto a las distintas entradas.

Tabla 3.2: Comportamiento de las salidas del controlador L298N. L = estado lógico bajo, H = estado lógico alto y X = cualquier estado.

Entradas			Salidas	
In1 = H	In2 = L	En = H	OUT1 = H	OUT2 = L
In1 = L	In2 = H	En = H	OUT1 = L	OUT2 = H
In1 = X	In2 = X	En = L	OUT1 = L	OUT2 = L

De esta forma variando el estado de las entradas es posible cambiar la dirección

hacia donde giran los motores, ahora para establecer la velocidad a los motores se utiliza la tercera entrada En con una señal *PWM* (sigla del inglés: *Pulse-width modulation*) que mediante la variación del *duty cycle* (ciclo de trabajo) logra establecer la variación de la velocidad. El ciclo de trabajo se define como el tiempo en que la señal se encuentra en estado alto, por ejemplo, en un ciclo de trabajo del 50 % la mitad del tiempo la señal está en alto y la otra mitad en bajo, en un ciclo del 25 % la señal está en alto solo el 25 % y el 75 % restante del tiempo está en estado bajo [12], como muestra la figura 3.16.




Figura 3.15: Señal *PWM* con distintos ciclos de trabajo.

Esta señal de control es producida por el microcontrolador a una frecuencia de 490 Hz, con una resolución de 8 bit, es decir, el ciclo de trabajo puede ser configurado con un rango de valores entre 0 y 255, siendo 0 un ciclo de trabajo del 0 % y 255 del 100 % [8].

3.5.3. Enlace de radio

Para dar al robot su dirección y velocidad se utiliza un enlace de radio 2.4GHz el que proporciona hasta seis canales de comunicación, para el control de robot solo se utilizan dos. Cada canal se lee desde el receptor de radio por separado por el microcontrolador, utilizando una entrada por canal. La señal se codifica mediante *PWM* donde la duración del pulso determina el valor del canal, cada pulso se produce en serie uno tras otro, este valor va en el rango de $1000\mu s$ a $2000\mu s$.




Figura 3.16: Señal *PWM* de distintos canales, el pulso tiene una tiempo de duración mínimo de $1000\mu s$ y máximo de $2000\mu s$.

Para obtener el valor de cada canal desde el receptor con el microcontrolador se lee la señal de un canal y se toma el tiempo, en milisegundos, que esta señal permanece con un valor alto, el tiempo registrado corresponderá al valor de dicho canal, esto se repite para el resto de los canales.

Los canales utilizados corresponden a uno y dos (ch1 y ch2), de estos se normalizan sus valores a un rango entre -500 y 500, con estos se conforma un vector \vec{d} con coordenadas (ch1, ch2), como muestra la figura 3.17, con este vector se calcula posteriormente el movimiento del robot.




Figura 3.17: Vector formado por los valores de los canales uno y dos obtenidos desde el receptor de radio.

3.5.4. Movimiento

Primero se necesita establecer un marco de referencia, el robot es capaz de desplazarse en dos dimensiones sobre un plano, este está formado por los ejes X e Y . Cuando se menciona que el robot se mueve hacia adelante hace su recorrido avanzando sobre el eje Y , al contrario, cuando se mueve hacia atrás retrocede en el eje Y , como esta representado en la figura 3.18. Ahora cuando se mueve a la derecha, avanza en el eje X y a la izquierda retrocede. Haciendo una comparación con los cuadricópteros, el movimiento hacia adelante y atrás del robot corresponde al movimiento de *pitch* en el cuadricóptero y los de derecha e izquierda al *roll*. No está dentro de los alcances contemplar el movimiento de *yaw*.

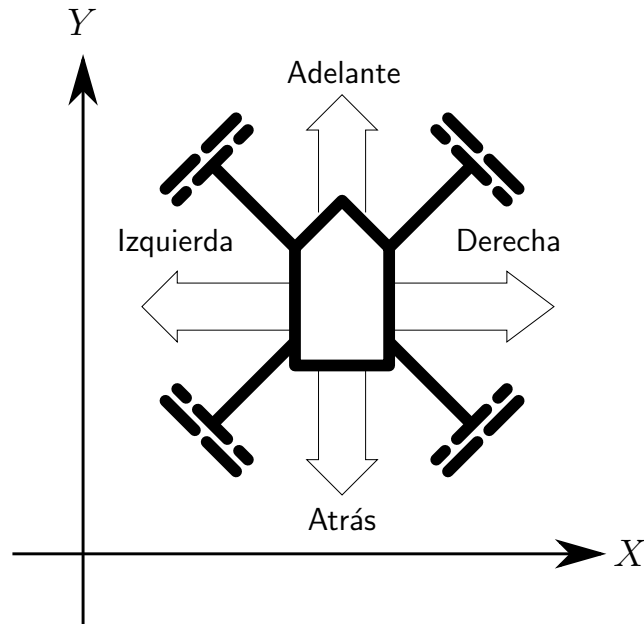


Figura 3.18: Desplazamiento del robot sobre el plano conformado por los ejes X e Y .

El movimiento del robot está determinado por dos parámetros, hacia donde debe moverse y a qué velocidad. Con esto se tiene un vector, que llamaremos \vec{d} , donde la dirección de este es la misma que debe seguir el robot y la magnitud es la velocidad del movimiento. Dado que las ruedas del robot están dirigidas en distintas orientaciones no es posible moverse directamente en la dirección de \vec{d} . Cada rueda se mueve en una dirección distinta con su propio vector de movimiento, por lo que para poder desplazarse en \vec{d} se tiene que realizar la suma de los vectores de cada rueda, de tal forma que el resultado coincida con \vec{d} .

Si bien el robot cuenta con cuatro ruedas, con los movimientos que se tiene contemplados hacer (delante, atrás, derecha e izquierda) siempre un par de ruedas se mueven en paralelo, como muestra la figura 3.19, así los movimientos de robot pueden descomponerse en dos vectores: \vec{r}_1 y \vec{r}_2 , la magnitud de estos representa la velocidad a la que gira cada rueda. La suma de estos debe dar \vec{d} , como muestra la figura 3.20.




Figura 3.19: \vec{r}_1 y \vec{r}_2 pares de ruedas que se mueven de forma paralela.




Figura 3.20: Suma de los vectores \vec{r}_1 y \vec{r}_2 que dan como resultado la dirección del robot.

Para realizar esta suma primero se obtienen las proyecciones de \vec{d} sobre el eje X e Y , dando como resultado \vec{d}_x y \vec{d}_y . El ángulo θ se mide entre el \vec{d} y el eje X como muestra la figura 3.21.

$$\begin{aligned} \vec{d}_x &= |\vec{d}| \cos(\theta) \\ \vec{d}_y &= |\vec{d}| \sin(\theta) \end{aligned} \quad (3.5)$$




Figura 3.21: Proyección del vector \vec{d} sobre el eje X e Y , dando los vectores \vec{d}_x y \vec{d}_y .

Ahora la magnitud de \vec{r}_1 y \vec{r}_2 se puede definir como:

$$\begin{aligned} \vec{r}_1 &= \vec{d}_x \cos(\pi/4) + \vec{d}_y \cos(\pi/4) \\ \vec{r}_2 &= -\vec{d}_x \cos(\pi/4) + \vec{d}_y \cos(\pi/4) \end{aligned} \quad (3.6)$$

Donde $\pi/4$ es ángulo de \vec{r}_1 y \vec{r}_2 sobre el eje X . Si la magnitud de los vectores toma un valor negativo es debe invertir la dirección de las ruedas.

En este capítulo fueron descrito todo lo que se necesita implementar para poder llegar a dar con la solución. Se detalló la forma en cómo se obtiene el flujo óptico y se utiliza para generar los datos necesarios, También se explica la utilización de la

red neuronal y la forma en que va a ser entrenada, Por último, se mostró el diseño de cada componente necesario para construir el robot omnidireccional y como este logra desplazarse.

4. Pruebas y Resultados

En el siguiente capítulo se detallan las pruebas realizadas y los resultados obtenidos, las pruebas se dividen en dos etapas: La primera consta en mover el robot sobre la pista de pruebas sin colocar obstáculos, sólo con información visual a los costados, la que será captada como flujo óptico, esta permitirá que el robot evite los bordes de la pista y sea capaz de centrarse dentro de esta. En la segunda etapa se mantendrá el mismo esquema de la primera, además de incluir un obstáculo en la pista de pruebas, que el robot tendrá que evadir.

Con los datos obtenidos de las pruebas se puede determinar si la red neuronal fue capaz de aprender y por lo tanto es capaz de evadir obstáculos, para esto se calcula cual es el error que produce la red, comparando los datos que esta produce con valores de referencia. De esta forma si el error está dentro de los márgenes establecidos se puede determinar si la red logró aprender o no.

Una vez que se recopilan todos los datos correspondientes a las pruebas, se procede a realizar un análisis para determinar si estos son válidos o no, si satisfacen a los resultados esperados y las razones de porqué se dieron los resultados obtenidos.

4.1. Pruebas

Por cada una de las etapas se comprobará de dos formas distintas si la red neuronal está aprendiendo. La primera es evaluando el aprendizaje con un set de datos de prueba, que no fue usado para el entrenamiento, aquí se evalúa cuánto difiere la salida teórica que debería entregar la red, salida esperada, con la que entrega realmente

la red. Esta diferencia se considera *test error* (error de prueba) y esta será obtenida por la técnica de *Validation Set Approach* (enfoque de conjunto de validación) la que consiste en dejar parte del conjunto de entrenamiento para validar cuán efectivo fue este [24].

Para la primera etapa se usaron 34755 datos para el entrenamiento y 7367 para la validación, en la segunda etapa se suman a los datos ya utilizados 31542 datos de entrenamiento y 13268 de validación. Dando un total de datos para la segunda etapa de 66297 elementos para entrenamiento y 20635 para validación.

La cuantificación del error se mide de dos formas distintas: La primera es mediante el error cuadrático medio *MSE* (del inglés: *mean squared error*):

$$MSE = \frac{1}{n} \sum_{x=1}^n (y_i - a^L(x_i))^2 \quad (4.1)$$

Donde y_i es la salida esperada y $a^L(x_i)$ es la salida que da la última capa L de la red neuronal con la entrada x_i , con un set de prueba de tamaño n .

En el segundo método se mide el porcentaje de *efectividad* de la red, lo que permite tener una medida concreta de cuantas veces la red entrega una respuesta correcta. Esto se obtiene cuantificando la cantidad de veces que la red entrega una salida que satisface a una respuesta esperada sobre el total de respuestas entregadas. Ya que la salida de la red está dentro de un rango continuo (entre cero y uno, con una resolución de 64 bit) la probabilidad de que la salida que entrega la red sea el valor exacto que se espera es muy baja, es por eso que la salida esperada de la red está dentro de un rango de aceptación, en este caso de un 90 %, donde la salida de la red no puede desviarse más allá de este porcentaje para que se considere salida correcta. El entrenamiento se considera exitoso si la eficacia de la red está sobre el 90 %.

La segunda comprobación de entrenamiento se realizará de forma empírica, comparando el comportamiento de la conducción manual del robot, contra la conducción

autónoma guiada por la red neuronal, cada vez que el robot se desplace por la pista de pruebas se deja registro de su desplazamiento, por lo que se puede comparar el recorrido realizado de forma manual y el de forma autónoma.

4.2. Obtención de datos

La obtención del conjunto de datos, para realizar las pruebas, consta de conducir de forma manual el robot repetidas veces por la pista de pruebas, colocando el robot en posiciones definidas al comienzo de la pista y dirigirlo hasta un punto determinado de esta.

Para la primera etapa, sin importar la posición de inicio, tiene como objetivo mover el robot al centro de la pista direccionando sobre el eje X mientras se desplaza por la pista en el eje Y , para que de esta forma la red neuronal pueda aprender a direccionar el robot evadiendo los bordes de la pista.

En la segunda etapa se posicionará un obstáculo dentro de la pista, al igual que en la primera etapa, también se deberá centrar el robot dentro de la pista, pero al enfrentarse a un obstáculo este debe ser evadido.

Para la recopilación de datos el recorrido del robot comienza en tres posiciones distintas en el inicio de la pista, las posiciones están a 20 cm del borde derecho, al centro y a 20 cm del borde izquierdo. Por cada una de estas se registran 30 recorridos del robot sobre la pista para los datos de entrenamiento y 10 para los datos de prueba. Obteniendo la información de flujo óptico y el recorrido hecho por este. El recorrido registrado es a una velocidad constante de 60 cm por segundo y una distancia de 2 m desde el comienzo de la pista.

Para la recopilación de datos con obstáculos, se utilizará el mismo esquema anterior, pero se posiciona un obstáculo dentro de la pista en distintas posiciones predefinidas. El obstáculo está construido con tres cilindros de cartón pintados de negro con una franja vertical blanca de 12 mm de ancho (para aumentar el flujo óptico registrado por el robot), cada cilindro tiene un diámetro de 5 cm y 18.5 cm de alto.

El obstáculo es posicionado en tres lugares distintos dentro de la pista, a 25 cm del borde derecho de la pista, al centro de la pista y a 25 cm del borde izquierdo, cada posición está a 1,5 mt del inicio de la pista.

Por cada posición del obstáculo se registran cinco recorridos para los datos de entrenamiento y tres para los da prueba por cada una de las tres posición de inicio, dando un total de quince recorridos para el entrenamiento y nueve para las pruebas por cada posición del obstáculo.

A continuación, se muestran los resultados obtenidos al realizar la comprobación del entrenamiento de la red neuronal y las pruebas empíricas de conducción autónoma del robot tanto para la primera etapa, que consta de evitar los bordes de la pista, como para segunda que tiene como objetivo evadir los obstáculos que se le presentan al robot.

4.3. Resultados

En este apartado se muestran los resultados obtenidos después de entrenar la red neuronal en los dos escenarios descritos en las pruebas: en la evasión de los bordes de la pista y la evasión de objetos.

4.3.1. Evasión de bordes

El entrenamiento de la red neuronal en esta etapa se hace con un set de 34755 datos y la validación con un set de 7367 datos. El entrenamiento consta de 30 iteraciones, es decir que la red se entrena por *backpropagation* luego se calcula el *test error* por medio de su efectividad y MSE, luego con red ya entrenada se repite el proceso por un total de 30 veces. El entrenamiento es realizado a dos redes distintas la primera con una sola capa oculta de 50 neuronas (denotada a continuación como Red.1.A), la segunda con 4 capas ocultas de 100, 70, 40, 10 neuronas respectivamente (denotada a continuación como Red.1.B). En la figura 4.1 y 4.2 se muestran los

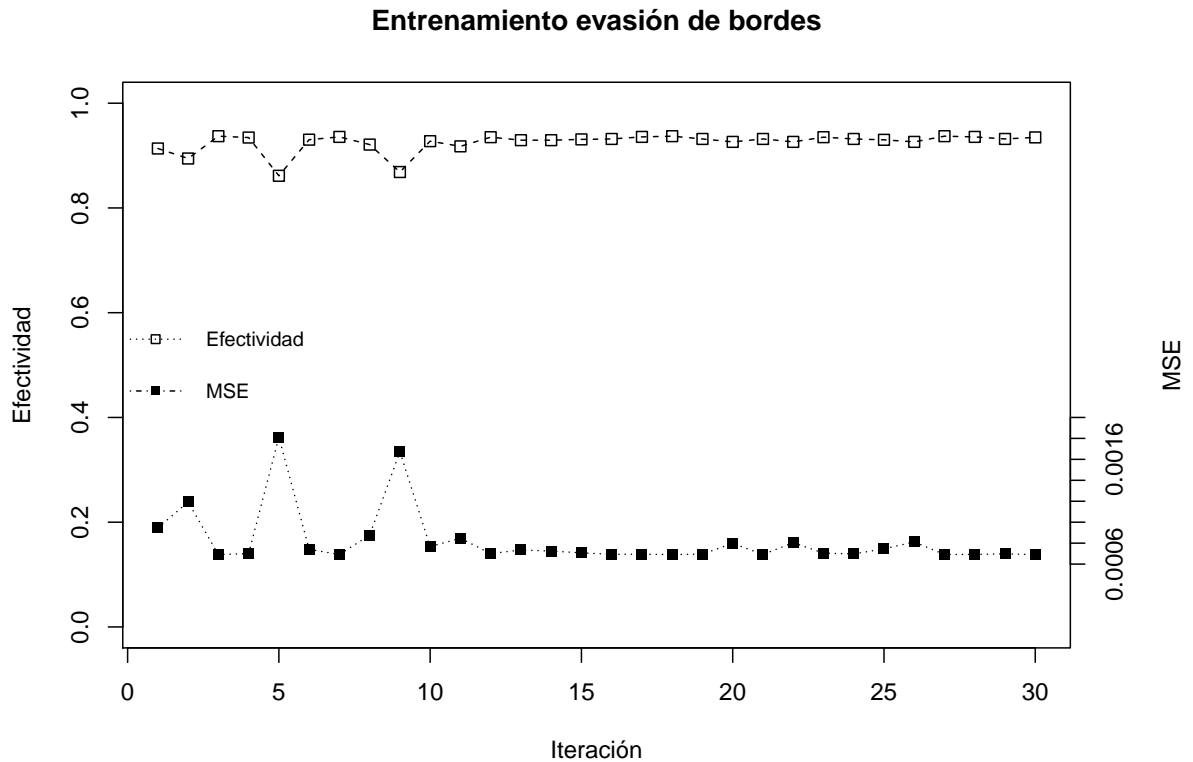


Figura 4.1: Resultado del entrenamiento después de 30 iteraciones de Red.1.A.

resultados obtenidos con las dos redes neuronales.

Como se puede ver en las figuras no existe mucha diferencia en la efectividad de las dos redes, las dos tiene una efectividad máxima de 0.9370164, en la figura 4.3 se muestra la comparación entre las dos redes. A través de las 30 iteraciones la desviación estándar de la efectividad de Red.1.A es de 0.01846731 y de Red.1.B es 0.01068135.

Dado que las dos redes tiene un número distinto de neuronas se diferencia en el tiempo que se tarda en computar el entrenamiento, Red.1.A toma 2.7691 minutos en completar las 30 iteraciones y Red.1.B 8.4236 minutos.

El MSE de las redes es bastante bajo, en comparación con un resultado aleatorio que presenta un valor de 0.25, a lo largo del entrenamiento el MSE máximo y mínimo




Figura 4.2: Resultado del entrenamiento después de 30 iteraciones de Red.1.B.

de Red.1.A es de 0.00069 y 0.001812, el de Red.1.B de 0.00067 y 0.00124.

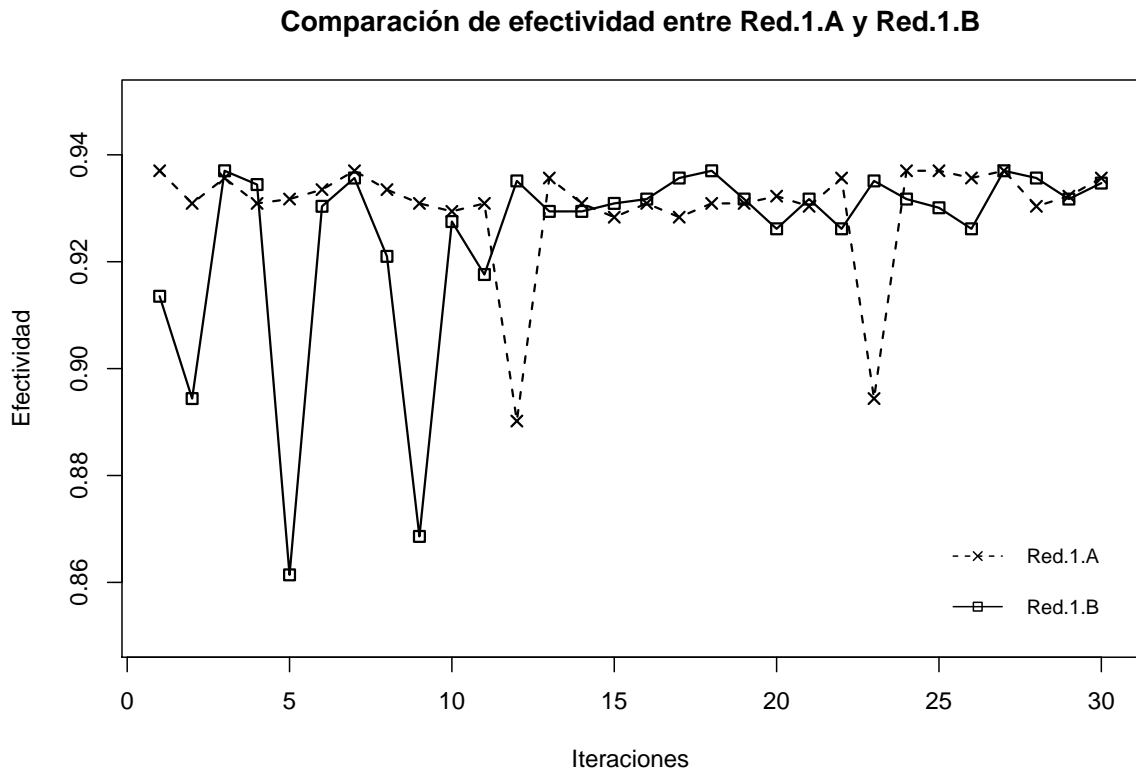


Figura 4.3: Comparación de efectividad entre Red.1.A y Red.1.B.

En la tabla 4.1 muestra una comparativa entre el entrenamiento de las redes neuronales Red.1.A y Red.1.B.

Tabla 4.1: Datos comparativos del entrenamiento en Red.1.A y Red.1.B

Entrenamiento Red.1.A y Red.1.B					
Red	Efectividad maxima	Desviación estándar	MSE minimo	MSE maximo	Tiempo de entrenamiento
Red.1.A	0.9370164	0.01846731	0.0006908158	0.0018120270	2.76913118362
Red.1.B	0.9370164	0.01068135	0.0006799585	0.0012468020	8.42360328436

4.3.2. Evasión de obstáculos

En esta etapa se utilizan los mismos datos que en la evasión de bordes, pero a estos se le suman 31542 elementos al set de entrenamiento y 13268 al de validación, obtenidos de los recorridos realizados por la conducción del robot evadiendo obstáculos. Con estos nuevos conjuntos de datos que tienen un total de 66297 elementos para el entrenamiento y 20635 para la validación, se vuelve a hacer el proceso de entrenamiento, iterar 30 veces para ambas redes neuronales (denotadas como Red.2.A y Red.2.B) y al término de cada entrenamiento hacer la comprobación con los datos de validación. La figura 4.4 y 4.5 muestra los resultados del proceso.

Al igual que en la primera etapa no se muestra mucha diferencia entre la efectividad de las redes neuronales Red.2.A y Red.2.B, pero esta vez la red que cuenta con más neuronas, Red.2.B, logró una efectividad de 0.932348 mientras que Red.2.A 0.9311849, la figura 4.6 muestra una comparativa entre las dos. La desviación estándar a lo largo del entrenamiento fue de 0.01630602 y 0.001632309, para la Red.2.A y Red.2.B respectivamente. Además ambas redes disminuyeron su resultados en comparación con el primera etapa, pero destaca la Red.2.B por tener una disminución notoria frente a las demás redes.

Debido al aumento tanto del set de datos de entrenamiento como el de validación los tiempos para completar el entrenamiento también aumentaron siendo de 5.5678 minutos para Red.2.A y 17.6041 para Red.2.B. Nuevamente debido al número de neuronas el tiempo de entrenamiento es mayor para la segunda red.

El MSE en esta etapa también se mantuvo con valores bajos, pero al igual que la desviación estándar de la Red.2.B el rango sufrió una reducción notoria, siendo de 0.0006519474 y 0.0007619559 mientras que para la Red.2.A el mínimo y máximo fue de 0.000653724 y 0.001927609 respectivamente.




Figura 4.4: Resultado del entrenamiento después de 30 iteraciones de Red.2.A.

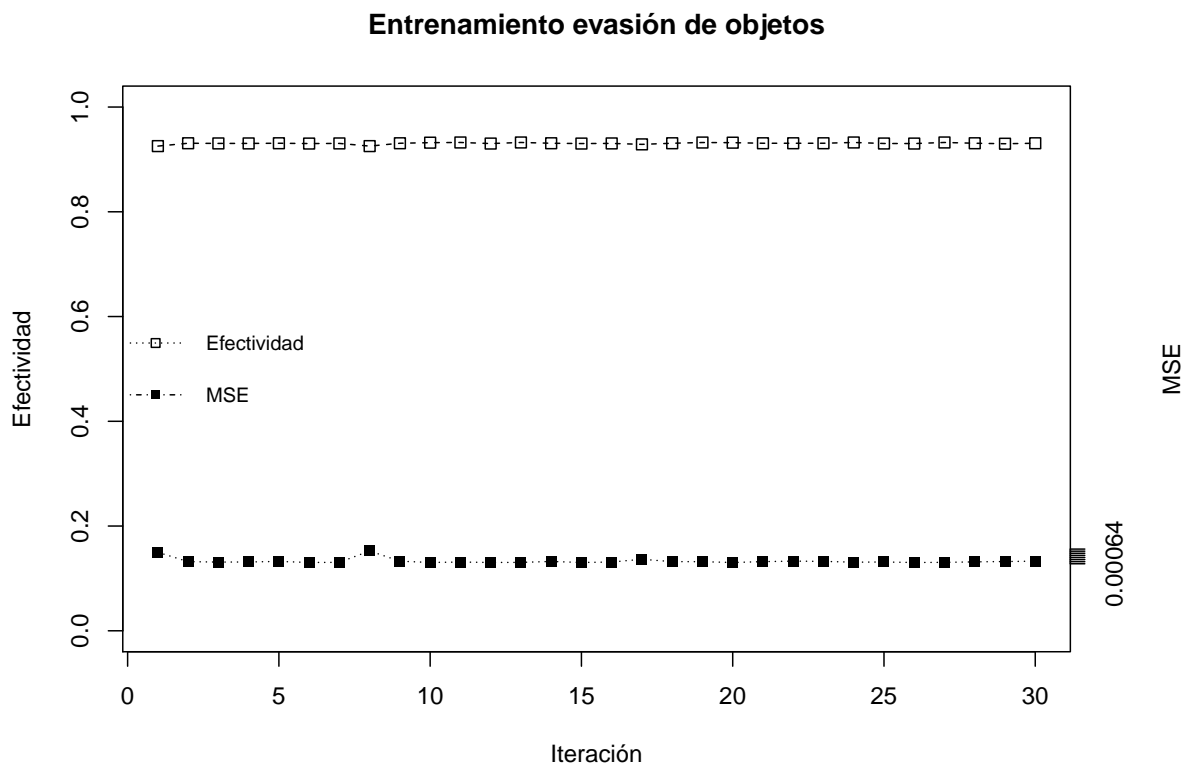


Figura 4.5: Resultado del entrenamiento después de 30 iteraciones de Red.2.b.

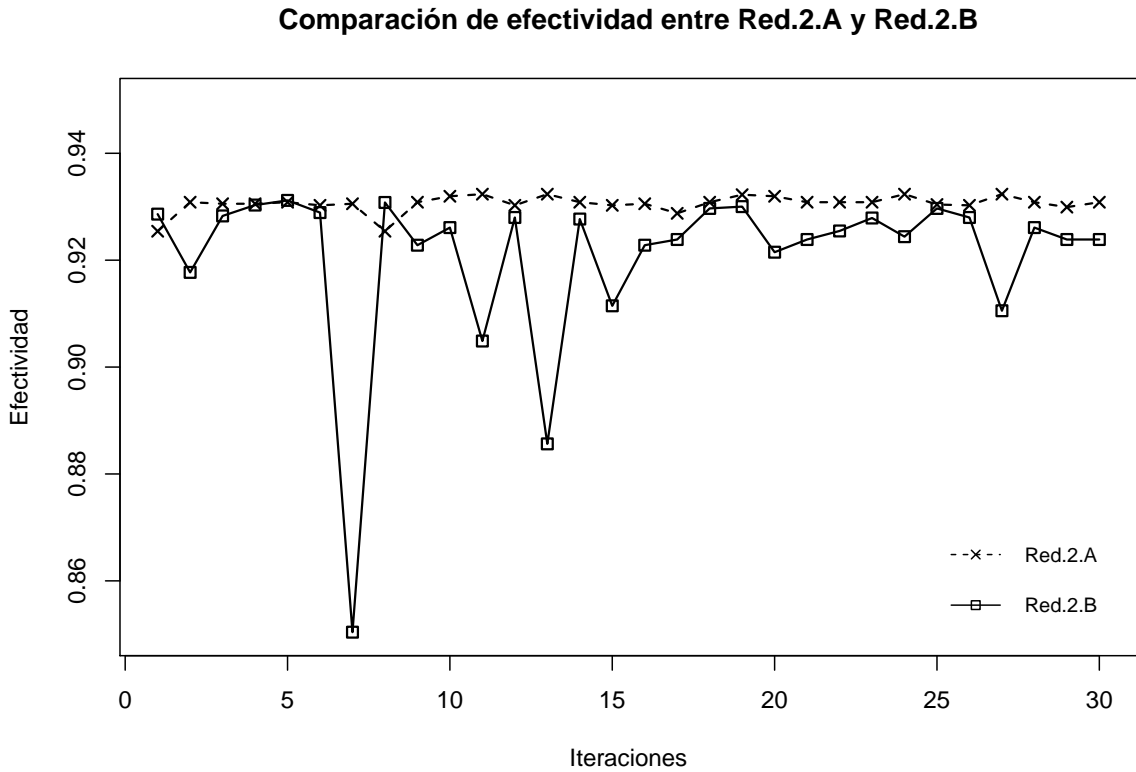


Figura 4.6: Comparación de efectividad entre Red.2.A y Red.2.B.

La tabla 4.2 muestra la comparativa entre la Red.2.A y Red.2.B de los resultados obtenidos en la segunda etapa de entrenamiento.

Tabla 4.2: Datos comparativos del entrenamiento en Red.2.A y Red.2.B

Entrenamiento Red.2.A y Red.2.B					
Red	Efectividad maxima	Desviación estándar	MSE minimo	MSE maximo	Tiempo de entrenamiento
Red.2.A	0.9311849	0.01630602	0.000653724	0.001927609	5.56788144906
Red.2.B	0.932348	0.001632309	0.0006519474	0.0007619559	17.604199481

En el anexo A se muestran los resultados completos del entrenamiento realizado a las distintas redes neuronales, se listan las iteraciones y en cada una la efectividad

y MSE conseguidos.

4.4. Conducción autónoma

Una vez que se terminó de entrenar las redes neuronales se probó la capacidad que estas tenían de conducir el robot por la pista de pruebas. Primero se prueba sin ningún objeto que evadir, el robot sólo tiene que dirigirse por el centro de la pista, con el objetivo de replicar el comportamiento de la conducción manual.

Al momento de realizar la primera prueba se registra que el robot no reacciona frente al flujo óptico, sin importar la información que recibe el comportamiento de este es el mismo, no cambia la dirección de la trayectoria. La respuesta que entrega la red debería modificar el recorrido en el eje X de la pista, pero en la prueba la información que se le entrega al robot indica que este no debe realizar ningún movimiento. Esto se traduce en que el movimiento siempre es en línea recta.

El resultado obtenido se repitió con las dos redes entrenadas, tanto con Red.1.A como Red.1.B, la salida de la red está normalizada entre 0 y 1, cuando toma el valor mayor a 0.5 el robot debe moverse a la derecha, si el valor es menor a la izquierda y si permanece en 0.5 la dirección no debe cambiar. La salida analizada siempre se mantenía en 0.5 o muy cercana a este valor, sin importar el flujo óptico que se utilizaba como entrada para la red.

Dado el comportamiento obtenido con la utilización de la red neuronal para la conducción autónoma se puede considerar que la prueba fue fallida, aunque los resultados de la validación de entrenamientos hayan sido exitosos.

4.5. Análisis

Como se deja ver en los resultados obtenidos existe una contradicción entre la validación del entrenamiento de la red y la conducción autónoma, por esta razón se revisa la forma en que se realiza el entrenamiento. Este tiene una estrecha relación

con los datos capturados, los que son el flujo óptico y los movimientos del robot, ambos capturados de los recorridos hechos en la pista de prueba.

Los movimientos del robot que son capturados por el sensor de movimientos tienen un valor mínimo de -255 y máximo de 255, los que son normalizados entre 0 y 1. Estos registran el desplazamiento del robot sobre el eje X . Se analiza la distribución que tienen estos en los datos de entrenamiento.




Figura 4.7: Histograma del movimiento registrado en el desplazamiento del robot por el eje X de la pista.

En la figura 4.7 se puede ver que la concentración de los datos se encuentra alrededor del valor 0.5, lo que significa que a lo largo de la captura de datos de entrenamiento no se registró el desplazamiento que hacía lateralmente el robot. Esto trae como consecuencia que al momento de hacer el entrenamiento la red aprende que indistintamente del flujo óptico que recibe como entrada la salida que debe entregar

es 0.5.




Figura 4.8: Comparativa de histogramas entre datos de entrenamiento y validación del movimiento registrado en el desplazamiento del robot por el eje X de la pista.

Ahora si se analiza los datos para la validación del entrenamiento, se ve que estos tiene una distribución que concuerda con los datos con que se realizó el entrenamiento, figura 4.8 muestra la comparativa entre los datos de entrenamiento y validación. Es por esta razón que cuando se valida el entrenamiento el resultado obtenido es una alta efectividad, a pesar de que el entrenamiento no cumple con el objetivo que se busca.

Las razones por la que se obtuvieron estos datos están estrechamente relacionadas con el sensor óptico de movimiento, el desplazamiento hecho por el robot en el intervalo de dos *frames* consecutivos pudo ser captado como un movimiento muy pequeño o nulo por el sensor. Otro motivo por el cual no se registraron los datos

esperados es que el sensor no puede captar el movimiento por no estar funcionando bajo las especificaciones para las que fue diseñado, como el no estar en un tipo de superficie compatible o estar fuera del rango de distancia que se necesita para captar el movimiento relativo a la superficie donde se desplaza.




Figura 4.9: Histograma del movimiento registrado en el desplazamiento del robot por el eje Y de la pista.

Al analizar el movimiento del robot en el eje Y gana más sustento el segundo motivo descrito anteriormente, al momento de capturar los datos del robot este siempre estuvo en movimiento sobre este eje, por lo que el sensor nunca debió entregar un valor de 0.5 ya que esto significa que el robot no se está desplazando. Al ver los datos del sensor se puede apreciar que al igual en el eje X la mayor concentración está alrededor del valor 0.5, la figura 4.9 muestra la distribución que estos tuvieron.

Teniendo estos antecedentes en cuenta se puede concluir que efectivamente al

momento de capturar los datos, tanto de entrenamiento como de validación, no se capturó adecuadamente el movimiento del robot. El sensor de movimiento en la mayoría de los casos no alertó desplazamiento alguno cuando en la realidad el robot estuvo en constante movimiento mientras se obtenían los datos.

Este fallo en la percepción de movimiento del robot no fue alertado con anterioridad por tener en pruebas preliminares buenos resultados en la validación del entrenamiento. Esos resultados no sugieren tener una falencia en los datos utilizados para entrenar red neuronal. Tampoco se contaba con una retroalimentación visual de la cuantificación del desplazamiento como si se tenía de la captura de flujo óptico.

Para corregir esta falencia es necesario hacer un rediseño en el robot omnidireccional que permita un buen funcionamiento del sensor de movimiento, garantizando que cualquier movimiento hecho por este pueda ser percibido por el sensor. Otra opción es utilizar un tipo diferente de sensor que se adapte mejor a los requerimientos específicos de cuantificar el desplazamiento hecho por el robot.

En el reciente capítulo se detalló cómo son llevadas a cabo las pruebas, estas son las que darán a conocer si la red neuronal es capaz de aprender a mantenerse en la pista y evadir obstáculos. Se explicaron los procedimientos necesarios para llevar a cabo las pruebas, los mecanismos por los que se van a medir los resultados, además de especificar el escenario donde van a realizarse.

También se mostró los resultados obtenidos de las distintas pruebas realizadas, las que consistieron en evaluar el entrenamiento de la red neuronal y cómo se comportaba el robot en la conducción autónoma, además de analizar el porqué de los resultados.

5. Conclusión

En este capítulo se revisa el trabajo realizado desde el punto de vista de los planteamientos hechos en un comienzo y si fue posible cumplir con estos. Se revisan los objetivos planteados, como fueron abordados y si pudieron ser completados.

Además de exponer las experiencias que se tuvieron a lo largo de la implementación de la solución y por qué se abordó la problemática de esta forma.

Para finalmente ver cuál es el trabajo que queda pendiente y que cosas se podrían hacer en el futuro para ampliar el ámbito de la solución.

5.1. Objetivos

Con todos los antecedentes recopilados y redactados en este documento no es posible decir que se logró cumplir con el objetivo principal que se planteó, debido a las razones argumentadas anteriormente. Por otro lado, no se descarta que la solución planteada pueda llevarse a cabo si se redefinen ciertos puntos de la implementación, que son necesarios para resolver la problemática, haciendo referencia a falencia de la captura de movimiento del robot.

Ahora si se revisan los objetivos específicos, que desglosan el trabajo realizado durante la construcción de la solución al problema planteada se puede decir lo siguiente:

- **Definir herramientas que permitan la obtención del flujo óptico desde la captura de video:** Este era un de los objetivos principales de solución,

marca el punto de partida para el resto de la implementación que se trabajó posteriormente. Se logró desarrollar el *software* necesario para calcular el flujo óptico, teniendo que indagar y comprender el funcionamiento de algoritmos de procesamiento de imágenes, como lo es el método *Lucas-Kanade*. Con esto se logró diseñar una solución, con la que podemos decir que este objetivo fue cumplido.

- **Implementación de una red neuronal que permita el procesamiento del flujo óptico:** Las investigaciones que se realizaron permitieron encontrar una implementación de una red neuronal que pudo ser adaptada a las necesidades específicas de este trabajo. A pesar de que era un trabajo ya desarrollado de todos modos fue necesario hacer un estudio detallado de cómo fue realizada esta implementación y analizar su funcionamiento. El cumplimiento de este objetivo implica a su vez manipular la información obtenida del flujo óptico, ya que no basta solo con la obtención de datos, sino que es necesaria la adaptación de estos para lograr el trabajo en conjunto con la red neuronal. Permitiendo poder procesar el flujo óptico por medio de una red neuronal.

- **Entrenamiento de una red neuronal para que sea capaz de aprender cómo evadir obstáculos:** Si bien se logró llevar a cabo el entrenamiento de una red neuronal mediante datos obtenidos del cálculo de flujo óptico, este entrenamiento no dio los resultados esperados, a pesar de que la cuantificación obtenida cumplía con las métricas definidas para dar este como exitoso. Esto muestra que a pesar de tener buenos resultados estos no siempre son los que se necesitan o son los que permitirán cumplir con los objetivos planteados. Por las pruebas hechas posteriormente se pudo determinar que este objetivo no pudo ser cumplido.

- **Implementación de un robot omnidireccional que permite la obtención de datos para entrenar la red neuronal:** Este objetivo es el que necesito mayor trabajo para ser completado. Abarca distintas áreas interdisciplinarias ya que el diseño tomó solo algunas referencias a elementos ya cons-

truidos y desde estas se realizó el diseño y construcción completa del robot. Fue necesaria la aplicación de diversos conocimientos como: modelado 3D, fabricación de piezas por impresión 3D, electrónica de microcontroladores y desarrollo de software, entre otros. Logrando así la construcción de una herramienta que además puede ser utilizada en el desarrollo de futuras investigaciones en este u otros ámbitos.

- **Realizar pruebas con el robot para evaluar el comportamiento de la red neuronal ante obstáculos:** Este objetivo es el que permite determinar si fue o no posible dar como exitoso el objetivo principal. Además de aglomerar todo el trabajo realizado. Una vez construido el robot y hecho el entrenamiento pertinente a la red neuronal se necesita saber si en conjunto pueden servir de solución al problema planteado, lo que se logra por medio del desarrollo de pruebas y posterior análisis de resultados. Estos dejaron en evidencia una falencia que compromete el cumplimiento del objetivo principal, pero a su vez permitieron dar con un diagnóstico y posibles soluciones para poder llegar a cumplir el objetivo. Si bien el robot cumple con su función de realizar las pruebas necesarias los resultados obtenidos no fueron los esperados. Estos dan a conocer que el entrenamiento realizado no permite la evasión de obstáculos por medio de la conducción autónoma del robot.

5.2. Trabajo realizado

Un punto importante fue la motivación que llevó el desarrollo de la solución planteada, la cual fue tomar como referencia elementos que existen en la naturaleza. Partir de esos referentes y usarlos como ejemplo para traspasar esos conceptos por medio de la construcción de un sistema que imite el desempeño de algunas entidades biológicas. El punto central indaga en el funcionamiento de las conexiones que hacen las neuronas para poder procesar información, de esto se basa la utilización de redes neuronales para analizar otro elemento que proviene de la naturaleza que es el flujo óptico. Todo esto culmina con la construcción de un robot que no solo pretende tener conducción autónoma, sino que busca ser un reflejo de lo el mundo natural puede

hacer.

Sin dudas esto lleva a un objetivo ambicioso pero que buscaba abarcar otras áreas que no son cubiertas o por lo menos no en profundidad en la formación profesional. Si bien el desempeño como ingeniero civil en computación cumple un rol fundamental de forma transversal en toda la implementación de este proyecto, también se añadieron otras áreas que estuvieran fuera del ámbito central que se estudia a lo largo de carrera y que son parte de interés personales, como lo es la computación física. Lo que genera un atractivo por el diseño de elementos que puedan interactuar de forma más tangible en nuestro entorno, como lo es la construcción de robots, estos permiten la unión del conocimiento adquiridos de los estudios como los aprendidos de forma autónoma por simple motivación.

A medida que se avanzó en el cumplimiento de los objetivos, fue posible evidenciar las diferencias que existen en la construcción de elementos que son abstractos en comparación con la implementación de objetos que tiene que lidiar con el mundo físico. La forma acostumbrada trabajar es tomar una idea, modelarla y plasmarla como una pieza de *software*, sin embargo, cuando se parte de la misma base, pero esta tiene que ser implementada y construida físicamente, esta no se comporta como uno espera o no puede prever los inconvenientes que pueden surgir. En contraste con el desarrollo de *software* donde se trabaja en un ambiente que es controlado y se conocen todas las variables que influyen en su comportamiento. Esto llevó a distintos eventos no anticipados en los que se debió buscar soluciones para poder seguir adelante con el desarrollo, sin embargo, situaciones como esas comprometieron el cumplimiento de objetivos planteados.

Por último, si bien no se obtuvieron los resultados esperados, de todos modos, fue satisfactorio el trabajo realizado, ya que durante el desarrollo de este fue necesario conocer sobre nuevas áreas, como por ejemplo los cuadricópteros, además de concluir la construcción del robot omnidireccional, el que no solo forma parte de este ámbito en particular, sino que puede ser utilizado como una herramienta para trabajar en proyectos futuros.

5.3. Trabajo futuro

Como ya se dio a conocer, no fue posible cumplir con todos los objetivos planteados, es por esto que se amplió el trabajo realizado, donde se utilizó un enfoque distinto el cual consiste en generar datos de prueba artificiales en vez de ser obtenidos por medio de la captura de video. De este modo se puede tener total control sobre los datos y asegurar que estos están correctos, así evitar los inconvenientes presentados en la generación de datos de entrenamiento ya discutidos.

Con estos nuevos datos se entrenó nuevamente la red neuronal, de la misma forma cómo se hizo con los datos obtenidos de la conducción de robot. Al probar la efectividad de esta nueva red la efectividad fue mayor al 90 %, al igual que en las redes entrenadas con los datos obtenidos desde la captura de video.

La diferencia se presentó al momento de probar la red en la pista de pruebas, donde el robot esta vez sí fue capaz de evadir las paredes además de esquivar los obstáculos que eran puestos al frente del robot. Lo que demuestra lo importante que es entrenar la red neuronal con datos validados y que reflejan el comportamiento que se espera que la red aprenda.

Dado que los nuevos datos generados no reflejan con mucha precisión los datos que el robot captura del entorno, tiene una baja efectividad al esquivar los obstáculos en la pista de pruebas. De la totalidad de los recorridos que se realizaron con el robot de forma autónoma, solo en el 25 % de los casos el robot logró esquivar los obstáculos con éxito.

Debido a que quedaron elementos pendientes en los objetivos planteados, en primer lugar, se deben solucionar los problemas encontrados, para que de esta forma se puedan volver a efectuar las pruebas planteadas y obtener los resultados esperados. Por otro lado debido a los ámbitos especificados falta la construcción de nuevos elementos que permitan en un futuro poder implementar este sistema en vehículos aéreos no tripulados y de esta forma poder dar una solución al problema planteado.

Dentro de estos elementos está por ejemplo ampliar las pruebas a condiciones

más complejas, como evadir múltiples objetos en más de una dirección y que puedan estar en movimiento, también poder portar el sistema al *hardware* adecuado para que este, por ejemplo, pueda funcionar a bordo de un cuadricóptero y ver cómo se comporta el sistema en una situación real.

También sería de interés poder ampliar el sistema para que pueda trabajar no solo con la información proveniente del flujo óptico, si no que poder contar una red neuronal que sea capaz de procesar distintos tipos de información a la vez y de esta forma poder agregar mayor capacidad al sistema planteado.

Otra alternativa es expandir el ámbito en el cual se planteó el problema y no solo usar el sistema para mejorar la autonomía de los vehículos aéreos no tripulados, si no que analizar en qué otra área podría ser de utilidad, por ejemplo, como asistencia a personas con visión reducida para puedan desplazarse con mayor facilidad.

Glosario

Ángulo de ataque: Se denomina ángulo de ataque al ángulo que forman la cuerda geométrica de un perfil alar con la dirección del aire incidente.

Caja reductora: Mecanismo que consiste en un grupo de engranajes con el que se consigue reducir el número de revoluciones.

Circuito en serie: Un circuito en serie es una configuración de conexión en la que los bornes o terminales de los dispositivos se conectan secuencialmente. La terminal de salida de un dispositivo se conecta a la terminal de entrada del dispositivo siguiente.

Filtro gaussiano: Un filtro gaussiano es un filtro cuyo impulso es una función gaussiana

Grado de libertad: Grados de libertad se refiere al número mínimo de parámetros que necesitamos especificar para determinar completamente la velocidad de un mecanismo o el número de reacciones de una estructura.

Holonómico: Sistemas holonómicos son aquellos capaces de modificar su dirección instantáneamente y sin necesidad de rotar previamente.

Impresión 3D: La impresión 3D es un grupo de tecnologías de fabricación por adición donde un objeto tridimensional es creado mediante la superposición de capas sucesivas de material

LED: LED del inglés: *light-emitting diode* (diodo emisor de luz) es un componente optoelectrónico activo y, más concretamente, un diodo que emite luz.

Modelado Paramétrico: Se denomina diseño paramétrico a un proceso de diseño basado en un esquema algorítmico que permite expresar parámetros y reglas que definen, codifican y aclaran la relación entre los requerimientos del diseño y el diseño resultante.

Motor DC: El motor de corriente continua es una máquina que convierte energía eléctrica en mecánica, provocando un movimiento rotatorio, gracias a la acción de un campo magnético.

Open source: El software de código abierto (en inglés open source) es el software cuyo código fuente y otros derechos que normalmente son exclusivos para quienes poseen los derechos de autor, son publicados bajo una licencia de código abierto o forman parte del dominio público.

Overflow: Ocurre cuando una operación aritmética intenta crear un valor numérico que está fuera del rango que se puede representar con un número dado de bits

Paso de hélice: Es el ángulo de ataque que forma la hélice con respecto a vector de movimiento del aire.

Bibliografía

- [1] arduino-info - ultrasonic distance sensor.
- [2] What is lidar?
- [3] Understanding laser-based 3d triangulation methods for machine vision systems, 2015.
- [4] Opencv: Optical flow, 2017.
- [5] Monocular cues for depth perception, 2018.
- [6] What are slam technology and slam cars?, 2018.
- [7] Clay Allen. Quadcopters, 2014.
- [8] Arduino. Arduino reference analogwrite, 2017.
- [9] Arduino. What is arduino?, 2017.
- [10] Atmel Corporation. *ATmega48A/PA/88A/PA/168A/PA/328/P*, 11 2015.
- [11] Dana Ballard. *Computer vision*. Prentice-Hall, Englewood Cliffs, N.J, 1982.
- [12] Steven Barrett. *Microcontrollers fundamentals for engineers and scientists*. Morgan and Claypool Publishers, San Rafael, Calif, 2006.
- [13] Partha S Bhagavatula, Charles Claudianos, Michael R Ibbotson, and Mandyam V Srinivasan. Optic flow cues guide flight in birds. *Current Biology*, 21(21):1794–1799, 2011.

- [14] Gary Bradski and Adrian Kaehler. *Learning OpenCV: Computer vision with the OpenCV library*. "O'Reilly Media, Inc.", 2008.
- [15] Myriam Cayre, Jordane Malaterre, Sophie Scotto-Lomassese, Colette Strambi, and Alain Strambi. The common properties of neurogenesis in the adult brain: from invertebrates to vertebrates. *Comparative Biochemistry and Physiology Part B: Biochemistry and Molecular Biology*, 132(1):1–15, 2002.
- [16] Adam Chapweske. Ps/2 mouse interfacing, 2003.
- [17] Adam Chapweske. The ps/2 mouse/keyboard protocol, 2003.
- [18] Fintan Corrigan. Top collision avoidance drones and obstacle detection explained, 2018.
- [19] NumPy developers. Numpy — numpy, 2017.
- [20] Sanja Filder. Image pyramid.
- [21] David Forsyth. *Computer vision : a modern approach*. Prentice Hall, Upper Saddle River, N.J. London, 2003.
- [22] G. Yahav G.J. Iddan. 3d imaging in the studio (and elsewhere...).
- [23] Berthold Horn. *Robot vision*. MIT press, 1986.
- [24] Gareth James, Daniela Witten, and Trevor Hastie. An introduction to statistical learning: With applications in r., 2014.
- [25] Munasinghe Muhandiram Premarathna Jayakody, Munagamage and Rajakaruna. Design and development of an omni-directional wheeled mobile robot. *International Research Symposium on Engineering Advancements 2015 (RSEA 2015)*, 2015.
- [26] Reinhard Klette. *Concise computer vision : an introduction into theory and algorithms*. Springer, London, 2014.
- [27] Tim Morris. *Computer vision and image processing*. Palgrave Macmillan, Basingstoke, 2004.
- [28] Michael Nielsen. Neural networks and deep learning, 2017.

- [29] Michael Nielsen. Using neural nets to recognize handwritten digits, 2017.
- [30] International Civil Aviation Organization. Unmanned aircraft systems (uas), 2011.
- [31] Dean A Pomerleau. Alvin: An autonomous land vehicle in a neural network. pages 305–313, 1989.
- [32] Linda Shapiro. *Computer vision*. Prentice Hall, Upper Saddle River, NJ, 2001.
- [33] Charles Siskind. *Electrical control systems in industry*. McGraw-Hill, New York, 1963.
- [34] Milan Sonka. *Image processing, analysis, and machine vision*. Thompson Learning, Toronto, 2008.
- [35] STMicroelectronics. *L298*, 2000.
- [36] C. E. Vandoni. *Proceedings : 1996 CERN School of Computing : Egmond aan Zee, the Netherlands, 8 September-21 September 1996*. CERN, Geneva, 1996.
- [37] Al Williams. *Microcontroller projects using the Basic Stamp*. CMP Books, Lawrence, Kan, 2002.

ANEXOS

A. Resultados entrenamiento de redes neuronales

A.1. Red.1.A

Tabla A.1: Datos del entrenamiento realizado a la Red.1.A.

Entrenamiento Red.1.A		
Iteración	Efectividad	MSE
1	0.913533324284	0.000945908778483
2	0.894393918827	0.00119303279299
3	0.937016424596	0.00069081575127
4	0.934437355776	0.00070042173591
5	0.861408986019	0.00181202704469
6	0.930365141849	0.000741045642054
7	0.935659019954	0.000691926551444
8	0.920999049817	0.000876352966901
9	0.868603230623	0.00167283443075
10	0.9275145921	0.000767064584306
11	0.917605538211	0.000846716155162
12	0.935116058097	0.000700496521621
13	0.929414958599	0.000734796869545
14	0.929414958599	0.000724355116221
15	0.930908103706	0.000707206147845

16	0.931722546491	0.000693620418216
17	0.935659019954	0.000694472906729
18	0.937016424596	0.000690996410918
19	0.931722546491	0.000695499916258
20	0.926157187458	0.000797349211209
21	0.931722546491	0.000691992846241
22	0.926157187458	0.000804536187667
23	0.935116058097	0.000704533339926
24	0.931722546491	0.000696808227387
25	0.93009366092	0.000745401931822
26	0.926157187458	0.000811712662915
27	0.937016424596	0.000691168580695
28	0.935659019954	0.000692704302926
29	0.931722546491	0.000697733637806
30	0.934708836704	0.000691069343532

A.2. Red.1.B

Tabla A.2: Datos del entrenamiento realizado a la Red.1.B.

Entrenamiento Red.1.B		
Iteración	Efectividad	MSE
1	0.937016424596	0.000680479158646
2	0.930908103706	0.000693363879534
3	0.935659019954	0.000681495122213
4	0.930908103706	0.000732845982048
5	0.931722546491	0.000683404847922
6	0.933487172526	0.000688381137309
7	0.937016424596	0.000680450324945
8	0.933487172526	0.000687662533276
9	0.930908103706	0.000692330783035
10	0.929414958599	0.000724415835138
11	0.930908103706	0.000701182301275

12	0.890185964436	0.00124680202199
13	0.935659019954	0.000683446893253
14	0.930908103706	0.000698575037316
15	0.928329034885	0.000751828245677
16	0.930908103706	0.000696074099689
17	0.928329034885	0.000753517327056
18	0.930908103706	0.000698791474565
19	0.930908103706	0.000703277030309
20	0.932265508348	0.00070997250449
21	0.930365141849	0.000715367567923
22	0.935659019954	0.000681680637419
23	0.894393918827	0.00118822859392
24	0.937016424596	0.000679987713934
25	0.937016424596	0.000679958482945
26	0.935659019954	0.000681375297971
27	0.937016424596	0.000680985065225
28	0.930365141849	0.000717947488892
29	0.932265508348	0.000708196541166
30	0.935659019954	0.00068277419994

A.3. Red.2.A

Tabla A.3: Datos del entrenamiento realizado a la Red.2.A.

Entrenamiento Red.2.A		
Iteración	Efectividad	MSE
1	0.928616428398	0.000719893721006
2	0.917712624182	0.000800126689279
3	0.928277198934	0.000664979822336
4	0.930312575721	0.000654552914366
5	0.931184880058	0.000654863604206
6	0.928907196511	0.000658793172797
7	0.850399806155	0.00192760902722

8	0.930797189242	0.000653724038728
9	0.92280106615	0.000800747839431
10	0.926096438091	0.000733538849396
11	0.904870365883	0.0010089428019
12	0.927986430821	0.000685578890759
13	0.885631209111	0.00147211690003
14	0.927695662709	0.000703759297938
15	0.911461109765	0.00103087829926
16	0.92280106615	0.000801065965672
17	0.923867215895	0.000730485527153
18	0.929682578144	0.000662293709483
19	0.930021807608	0.000696563117277
20	0.921492609644	0.000762692770483
21	0.923867215895	0.000737694338211
22	0.925466440514	0.000750068796091
23	0.927889508117	0.000701192146117
24	0.924400290768	0.000776208040826
25	0.929682578144	0.00066460162863
26	0.927986430821	0.000678062613667
27	0.910540344076	0.000930106000753
28	0.926096438091	0.000745957305927
29	0.923867215895	0.000730502893394
30	0.923867215895	0.000734406848618

A.4. Red.2.B

Tabla A.4: Datos del entrenamiento realizado a la Red.2.B.

Entrenamiento Red.2.B		
Iteración	Efectividad	MSE
1	0.925417979162	0.000749432750139
2	0.930845650594	0.000660165282152
3	0.930554882481	0.000655959851093

4	0.930554882481	0.000656857864731
5	0.930845650594	0.000662295925217
6	0.930264114369	0.000652311348451
7	0.930554882481	0.000653654554964
8	0.925417979162	0.000761955863816
9	0.930845650594	0.000664555387331
10	0.931960261691	0.000652296703772
11	0.932347952508	0.000656277069034
12	0.930264114369	0.000652385361621
13	0.932347952508	0.000652944033472
14	0.930845650594	0.000661843223622
15	0.930264114369	0.000652187111804
16	0.930554882481	0.000656488882683
17	0.928761812455	0.000683020599665
18	0.930845650594	0.00066003563414
19	0.932251029804	0.00065971120924
20	0.931960261691	0.000651947403756
21	0.930845650594	0.000660280012452
22	0.930845650594	0.000665047738241
23	0.930845650594	0.000662555843386
24	0.932347952508	0.000654873962048
25	0.930409498425	0.00065689395976
26	0.930264114369	0.000652052591494
27	0.932347952508	0.0006534034983
28	0.930845650594	0.000657837034339
29	0.929924884904	0.000661217162169
30	0.930845650594	0.000664652371238

B. Arduino UNO rev 2

Especificaciones de la placa *Arduino* UNO rev 2.

Tabla B.1: Especificaciones Arduino UNO.

Microcontrolador	ATmega328P
Voltaje de operación	5V
Voltaje de entrada (recomendado)	7-12V
Voltaje de entrada (limite)	6-20V
Pin digitales	14 (6 proporcionan salida PWM)
Pines digitales PWM	6
Pin de entrada analógica	6
Corriente por pin	20 mA
Corriente por pin 3.3V	50 mA
Memoria Flash	32 KBytes de los cuales 0.5 KBytes son usados por el bootloader
SRAM	2 KBytes
EEPROM	1 KBytes
Velocidad de reloj	16 MHz
LED_BUILTIN	13
Largo	68.6 mm
Ancho	53.4 mm
Peso	25 g

C. Configuración impresora 3D

Configuración completa de la impresora 3D al momento de construir las piezas para el robot omnidireccional.

```
# generated by Slic3r 1.2.9 on Tue Jun 20 23:36:24 2017
avoid_crossing_perimeters = 0
bed_shape = 0x0,200x0,200x145,0x145
bed_temperature = 60
before_layer_gcode =
bottom_solid_layers = 3
bridge_acceleration = 0
bridge_fan_speed = 100
bridge_flow_ratio = 1
bridge_speed = 30
brim_width = 0
complete_objects = 0
cooling = 1
default_acceleration = 0
disable_fan_first_layers = 3
dont_support_bridges = 1
duplicate_distance = 6
end_gcode = M104 S0 ; turn off temperature\nG28 X0
; home X axis\nG0 Y149; \nM84 ; disable motors\n
external_fill_pattern = rectilinear
external_perimeter_extrusion_width = 0
```

```
external_perimeter_speed = 80%
external_perimeters_first = 0
extra_perimeters = 1
extruder_clearance_height = 20
extruder_clearance_radius = 20
extruder_offset = 0x0
extrusion_axis = E
extrusion_multiplier = 1
extrusion_width = 0
fan_always_on = 1
fan_below_layer_time = 0
filament_colour = #000000
filament_diameter = 1.75
fill_angle = 45
fill_density = 15%
fill_pattern = rectilinear
first_layer_acceleration = 0
first_layer_bed_temperature = 60
first_layer_extrusion_width = 250%
first_layer_height = 0.4
first_layer_speed = 50%
first_layer_temperature = 215
gap_fill_speed = 15
gcode_arcs = 0
gcode_comments = 0
gcode_flavor = reprap
infill_acceleration = 0
infill_every_layers = 1
infill_extruder = 1
infill_extrusion_width = 0
infill_first = 0
infill_only_where_needed = 0
infill_overlap = 15%
infill_speed = 40
```

```
interface_shells = 0
layer_gcode =
layer_height = 0.2
max_fan_speed = 100
max_print_speed = 80
max_volumetric_speed = 0
min_fan_speed = 70
min_print_speed = 10
min_skirt_length = 0
notes =
nozzle_diameter = 0.4
octoprint_apikey =
octoprint_host =
only_retract_when_crossing_perimeters = 1
ooze_prevention = 0
output_filename_format = [input_filename_base].gcode
overhangs = 1
perimeter_acceleration = 0
perimeter_extruder = 1
perimeter_extrusion_width = 0
perimeter_speed = 30
perimeters = 3
post_process =
pressure_advance = 0
raft_layers = 0
resolution = 0
retract_before_travel = 2
retract_layer_change = 1
retract_length = 5
retract_length_toolchange = 10
retract_lift = 0
retract_restart_extra = 0
retract_restart_extra_toolchange = 0
retract_speed = 40
```

```
seam_position = aligned
skirt_distance = 6
skirt_height = 1
skirts = 2
slowdown_below_layer_time = 20
small_perimeter_speed = 15
solid_infill_below_area = 70
solid_infill_every_layers = 0
solid_infill_extruder = 1
solid_infill_extrusion_width = 0
solid_infill_speed = 80%
spiral_vase = 0
standby_temperature_delta = -5
start_gcode = G28 ; home all axes\n;G1 Z5 F5000 ; lift nozzle\n
support_material = 0
support_material_angle = 0
support_material_contact_distance = 0.2
support_material_enforce_layers = 0
support_material_extruder = 1
support_material_extrusion_width = 0
support_material_interface_extruder = 1
support_material_interface_layers = 3
support_material_interface_spacing = 0
support_material_interface_speed = 100%
support_material_pattern = pillars
support_material_spacing = 2.5
support_material_speed = 40
support_material_threshold = 0
temperature = 210
thin_walls = 1
threads = 2
toolchange_gcode =
top_infill_extrusion_width = 0
top_solid_infill_speed = 50%
```

```
top_solid_layers = 3
travel_speed = 60
use_firmware_retraction = 0
use_relative_e_distances = 0
use_volumetric_e = 0
vibration_limit = 0
wipe = 0
xy_size_compensation = 0
z_offset = 0
```