



INAOE

SUBSISTEMA DE DESCENSO EN CRÁTERES PARA ROVERS PLANETARIOS.

Por
Emmanuel León Soto

Tesis sometida como requisito parcial para obtener
el grado de

**MAESTRO EN CIENCIAS EN Ciencia y
Tecnología del Espacio**

en el
**Instituto Nacional de Astrofísica, Óptica y
Electrónica**

Mayo 2024
Tonantzintla, Puebla

Bajo la supervisión de:

Dr. Leopoldo Altamirano Robles
Investigador Titular INAOE

©INAOE 2024

El autor otorga al INAOE el permiso de reproducir
y distribuir copias parcial o totalmente de esta tesis.



Resumen

Los vehículos robóticos de exploración (Rovers) son utilizados para recopilar datos en Marte desde 1997. Sin embargo, en la última década los Rovers han sido equipados con instrumentos cada vez más complejos para realizar pruebas en el campo de la astrobiología, que incluye la búsqueda de señales de vida microbiana antigua, caracterización geológica y clima planetario. Estos datos construyen el camino hacia la exploración del sistema solar.

Si bien la recompensa es grande, el diseño y operación de un Rover no es trivial, todos los módulos a bordo de estos colosos de una tonelada deben ser robustos para operar sin mantenimiento, de forma autónoma y por largos periodos de tiempo, en condiciones extremas que superan las adversidades presentes en los desiertos del planeta Tierra. Por otro lado, la navegación autónoma (NA) e inteligencia artificial (IA) juegan un papel cada vez más importante en la robótica. En la industria, por ejemplo, los sistemas de visión por computadora y las redes neuronales convolucionales (RNC) se utilizan en la automatización de procesos que requieren de robots para realizar tareas en líneas de producción. Esto motiva a preguntar ¿Hasta dónde puede llegar un robot explorador con IA?

Si bien los sistemas de navegación autónoma ya son utilizados en los Rovers Curiosity y Perseverance (misiones de exploración en Marte lanzadas en 2011 y 2020 respectivamente) ambos tienen una limitante en común. No pueden descender sobre pendientes mayores a treinta grados de forma segura.

Por lo anterior, el objetivo principal de esta tesis es:

- Desarrollar un subsistema de descenso en cráteres que pueda estabilizar un Rover durante el descenso sobre un plano inclinado con pendiente mayor a 30 grados de forma autónoma, combinando elementos de visión por computadora, mecánica e inteligencia artificial en un **prototipo funcional**.

Las características del prototipo *INAOE-AI-ROVER-01* se exponen en el capítulo 4 detallando cada uno de los elementos mecánicos, electrónicos y computacionales utilizados. Los resultados fueron documentados en el capítulo 5, en una serie de experimentos realizados (en laboratorio y campo de pruebas) para probar las capacidades de navegación autónoma de la red neuronal artificial *Mad_Mars* sobre pendientes de entre 20 y 45 grados.

Abstract

Since 1997, mobile exploration rovers have served as invaluable tools for gathering data on Mars. Recent years have witnessed a significant advancement in onboard instrumentation, enabling rovers to conduct sophisticated in-situ investigations in astrobiology, including the search for biosignatures of past microbial life, geological characterization, and planetary climate studies. This data collection paves the way for further exploration of our solar system.

However, the design and operation of rovers present a significant engineering challenge. These one-ton behemoths require robust onboard modules capable of autonomous and long-term operation without human intervention, often under extreme conditions surpassing the harshest terrestrial environments. Furthermore, autonomous navigation (AN) and artificial intelligence (AI) are playing an increasingly crucial role in robotics. For instance, industrial applications leverage computer vision systems and convolutional neural networks (CNNs) to automate tasks involving robots on production lines. This growing reliance on AI prompts the question: to what extent can AI be integrated into exploration robots?

While both the Curiosity and Perseverance rovers (launched in 2011 and 2020, respectively, for Martian exploration) utilize autonomous navigation systems, they share a critical limitation: the inability to safely navigate slopes exceeding 30 degrees.

Therefore, this thesis focuses on the development of a novel descent subsystem for crater exploration. This subsystem aims to achieve autonomous stabilization of a rover during descent on inclined planes with slopes exceeding 30 degrees. The design integrates elements of computer vision, mechanics, and artificial intelligence into a functional prototype.

Chapter 4 details the characteristics of the INAOE-AI-ROVER-01 prototype, providing a comprehensive breakdown of its mechanical, electronic, and computational components.

Chapter 5 presents the results obtained through a series of experiments conducted in both laboratory and field settings. These experiments evaluated the autonomous navigation capabilities of the Mad_Mars artificial neural network on slopes ranging from 20 to 45 degrees.

AGRADECIMIENTOS

Agradezco a el CONACYT por el apoyo económico brindado durante la realización de esta investigación. Agradezco al INAOE por la oportunidad de aprender y convivir con investigadores dedicados a la noble labor de la ciencia en quienes encontré siempre inspiración y consejo durante una de las etapas más enriquecedoras de mi vida.

Quiero agradecer a mi asesor de tesis, él Dr. Leopoldo Altamirano Robles por aceptarme como su estudiante, compartir conmigo ese conocimiento adquirido durante tantos años de experiencia y en especial por su ayuda para construir un prototipo en tan poco tiempo.

Agradezco de todo corazón a mi madre Eugenia Soto y esposa Diana Rosario Sánchez por creer en mí, amarme y tenerme la paciencia durante mis años de estudiante. También agradezco a Andrea Soto quien me ha aconsejado en los últimos 16 años de mi vida, sin usted mis éxitos no serían posibles y finalmente a mis hermanas que escucharon cientos de historias sobre misiones espaciales y robots que exploran mundos distantes.

Índice

Contenido

Capítulo 1 Introducción	8
1.1 Descripción del problema	8
1.2 Objetivo general	9
1.2.1 Objetivos particulares	9
1.3 Metodología.....	9
1.4 Aportación.....	10
Capítulo 2 Marco Teórico	11
2.1 Introducción.....	11
2.1.1 Clasificación de imágenes.....	11
2.1.2 Segmentación semántica	12
2.2 Sistemas de visión LIDAR	14
2.3 Modelos de visión por computadora.....	15
2.4 Sistemas de locomoción en Rovers	17
Capítulo 3 Trabajo Relacionado.....	19
3.1 Perseverance Rover	19
3.2 NeBula-Husky	20
3.3 DuAxel	20
3.4 LEMUR 3.....	21
Capítulo 4 Sobre el prototipo.....	22
4.1 Diseño mecánico.....	22
4.1.1 Análisis mecánico.....	23
4.2 Diseño eléctrico y electrónico.....	24
4.3 Computadoras de abordo	27
4.4 Software de servicio	28
4.4.1 Software para evasión de obstáculos.....	29
4.4.2 Algoritmo Sort.....	29
Capítulo 5 Pruebas y Resultados.....	30
5.1 Mapa cronológico de experimentos	30
5.2 Características del campo de pruebas.....	32
5.3 Prototipo INAOE-AI-ROVER-01	33

5.4	Reducción de la vibración.....	34
5.5	Mecanismo de descenso en cráteres.....	35
5.6	Red Neuronal Artificial Mad_Mars.....	37
5.6.1	Resultados del entrenamiento grupo A.....	38
5.6.2	Resultados del entrenamiento grupo B.....	39
5.6.3	Resultados del entrenamiento grupo C.....	39
5.7	Resultados del modelo Mad_Mars.....	40
5.8	Discusión de los resultados.....	41
Capítulo 6 Conclusiones y Trabajo a Futuro.....		42
	Trabajo a futuro.....	43
	Bibliografía.....	43
	Anexos.....	44
	Índice de figuras.....	44
	Índice de tablas.....	45
	Planos mecánicos.....	46

Capítulo 1

Introducción

La navegación autónoma aplicada a los vehículos robóticos de exploración espacial (Rovers) es actualmente un área de gran interés. Los Rovers son una herramienta efectiva para revelar los secretos que se esconden en la superficie de mundos distantes.

La exploración de Marte utilizando Rovers no se limita solo a fotografías, las misiones *Curiosity en 2011* y *Perseverance en 2020* están equipadas con pesados instrumentos científicos que permiten recolectar muestras y analizarlas in situ para obtener, por ejemplo, datos de la composición mineralógica y atmosférica del planeta rojo. Si bien las misiones espaciales utilizando Rover se han concretado solo en Marte y la Luna terrestre, podemos concluir que son misiones de gran éxito por la cantidad de información obtenida.

Futuras misiones espaciales como la misión Artemis que la National Aeronautics and Space Administration (NASA) planea ejecutar en 2025 y cuyo objetivo es establecer de forma permanente una base lunar. Propone la necesidad de robots **autónomos** que puedan realizar tareas complejas como la exploración, extracción de minerales, construcción y mantenimiento de instalaciones.

La inteligencia artificial (IA) y el uso de redes neuronales artificiales (RNA) introducen en el campo de la robótica espacial nuevos métodos para el control autónomo de robots con misiones de exploración en planetas rocosos. La investigación de esta tesis está dirigida hacia el diseño y construcción de un prototipo de Rover con capacidad de descenso sobre pendientes rocosas como las que podemos observar en un cráter donde la pendiente supera los treinta grados de inclinación, (Lakdawalla, 2018).

1.1 Descripción del problema

El *Perseverance* desarrollado por el *Jet Propulsion Laboratory (JPL)* de la NASA es en la actualidad el vehículo robótico para la exploración espacial con mayor tecnología, que ha realizado una misión con éxito. Con un chasis de mil veinticinco kilogramos se desplaza sobre la superficie de Marte evitando en su trayectoria zonas con pendientes mayores a 30 grados que ponen en riesgo la estabilidad del sistema de locomoción. Sin embargo, un Rover sin esta limitación podría explorar cráteres y zonas rocosas facilitando misiones de minería espacial, colonización y exploración en planetas rocosos.

La problemática es realizar el descenso de un Rover sobre pendientes accidentadas de forma autónoma, utilizando un subsistema de descenso que combina la adquisición de imágenes en tiempo real y un mecanismo estabilizador.

1.2 Objetivo general

El objetivo general de esta tesis es desarrollar un subsistema de descenso en cráteres que pueda estabilizar un Rover durante el descenso sobre un plano inclinado con pendiente mayor a 30 grados de forma autónoma, combinando elementos de visión por computadora, mecánica e inteligencia artificial en un **prototipo funcional**.

1.2.1 Objetivos particulares

Los objetivos particulares de esta tesis se enlistan a continuación:

- Analizar la dinámica de un Rover con tracción trasera durante el descenso sobre un plano inclinado.
- Diseñar e implementar un mecanismo de descenso.
- Diseñar y programar un sistema de visión para determinar posición y distancia de un objeto.
- Entrenar y probar una Red Neuronal Artificial para control del Rover durante el descenso sobre un plano inclinado.
- Programar el software de control para los actuadores del Rover.

1.3 Metodología

El entrenamiento de una Red Neuronal Convolutiva para realizar la detección y segmentación de obstáculos como los que podemos encontrar en un cráter en Marte requiere de imágenes. El conjunto de datos “*Imágenes de la superficie de Marte Nasa*” contiene imágenes de la superficie de Marte capturadas por los instrumentos de visión a bordo del Rover Curiosity durante su expedición (2011 -2015). Estas imágenes brindan características de la superficie del planeta rojo que como demostraremos, pueden ser usadas para resolver nuestro problema específico, la navegación autónoma sobre un plano inclinado.

Para validar los resultados del modelo de visión por computadora y el sistema mecánico de descenso propuestos, se construyó un prototipo de vehículo robótico con características mecánicas similares a las de los Rovers enviados a Marte. Finalmente, una serie de experimentos comprobarán si es posible realizar el descenso sobre pendientes mayores a 30 grados de forma segura, utilizando los mecanismos propuestos y los modelos de visión por computadora entrenados.

En la actualidad el único planeta explorado desde su superficie utilizando vehículos robóticos es Marte. La distancia entre la Tierra y Marte varía de 56 a 400 millones de kilómetros, por este motivo, utilizar sistemas de navegación autónoma es indispensable en una misión de exploración robótica. Pero los modelos de inteligencia artificial (IA) deben ser entrenados y probados en la Tierra antes de ser enviados a misiones en planetas distantes, con la intención de minimizar la probabilidad de fracaso en cualquiera de los sistemas del Rover.

De las misiones en Marte se han obtenido imágenes y análisis de suelo que relatan la hostilidad del planeta con sus visitantes, en la figura 1.1 se observan los daños en llantas del Rover Curiosity tras 13 años de servicio.



*Figura 1.1 Llanta de Rover y sus daños a lo largo del tiempo.
Créditos: NASA/JPL-Caltech.*

Es importante continuar mejorando los sistemas que permiten a un Rover realizar su trabajo, dependemos de estas misiones para recabar datos suficientes antes de realizar una misión con seres humanos que en algún momento exploraran otros planetas del sistema solar.

Las características geográficas de Marte muestran zonas accidentadas por toda la superficie del planeta. Cráteres, barrancos y acantilados, son parte del entorno marciano. El acceso a estas zonas y los datos que se podrían obtener, son un problema para los Rovers que trabajan en Marte en este momento, la razón es que sus sistemas de locomoción no pueden asegurar el descenso del Rover sobre un plano inclinado con ángulo mayor a 30 grados.

1.4 Aportación

Las aportaciones de este trabajo de tesis son:

Un subsistema que utiliza elementos que ya existen en el sistema de visión y locomoción de un Rover para realizar tareas de navegación complejas, agregando un mecanismo de descenso nuevo, capaz de estabilizar sistemas de locomoción independientemente del número de elementos mecánicos.

El desarrollo de una red neuronal convolucional nombrada **Mad_Mars**, entrenada para realizar navegación autónoma controlando los actuadores del prototipo desde una computadora NVIDIA Jetson Xavier.

Un prototipo funcional y económico de vehículo robótico explorador (comparado con otros proyectos en desarrollo) con elementos suficientes para probar modelos de inteligencia artificial y navegación autónoma.

Capítulo 2

Marco Teórico

2.1 Introducción

En este capítulo se presentan estrategias para el modelado y entrenamiento de redes neuronales convolucionales que realizan detección de objetos y segmentación semántica en tiempo real. Describiremos el modelo YOLO (*You Only Look Once*) como una herramienta de aprendizaje profundo en sistemas de visión por computadora.

Los sistemas de visión por computadora son necesarios para realizar navegación autónoma, las cámaras se encargan de proporcionar imágenes del entorno sobre el que se desplaza el Rover para identificar obstáculos y los sensores LIDAR calculan la distancia a la que se encuentran los mismos, de esta forma podemos determinar la cantidad de obstáculos en una escena y determinar la trayectoria que se debería seguir para no chocar o volcar el Rover.

2.1.1 Clasificación de imágenes

La clasificación de imágenes según su contenido es una tarea en la que las Redes Neuronales Convolucionales (CNN) son particularmente buenas. Consiste en el entrenamiento de un modelo utilizando un conjunto de datos objetivo de los que aprenderá a reconocer patrones complejos para determinar el contenido de la imagen.

Una vez que la red esta entrenada podemos cuantificar sus resultados utilizando imágenes de entrada desconocidas para la red, los datos de entrada son cada uno de los pixeles en la imagen y el resultado es la etiqueta de contenido asignada por la red.

En la figura 2.1a es posible observar los patrones en los pixeles de una imagen de Marte, (Alice Stanboli, & Kiri Wagstaff , 2017). Los patrones identifican obstáculos en la escena, para posterior mente figura 2.1b clasificar la escena como **con obstáculos** o **libre de obstáculos** según sea el caso.




Figura 2.1 Fotografía de Marte, clasificación de imágenes según su contenido utilizando una CNN.
Créditos: NASA/JPL-Caltech.

Ejemplo 2.1 Imágenes de Marte, Detección obstáculos (rocas) en una escena.

Para el entrenamiento de una CNN que se encarga de la detección de obstáculos, se requieren imágenes con rocas y sin rocas con una distribución 50-50 en el conjunto de datos. En este ejemplo fue necesario un conjunto de 200 imágenes como las que podemos observar en la figura 2.2a y 2.2b.




Figura 2.2 Fotografías de Marte, conjunto de datos
2.2a escenas con obstáculos, 2.2b escenas sin obstáculos.
Créditos: NASA/JPL-Caltech.

Dentro de un sistema de visión la clasificación oportuna de una serie de imágenes (video) permite decidir de forma eficiente (en menor tiempo) las acciones subsecuentes a la detección de obstáculos estén o no relacionadas con el sistema de locomoción.

2.1.2 Segmentación semántica

A diferencia de la clasificación de imágenes la segmentación semántica se realiza a nivel de píxeles que se agrupan en colecciones para identificar objetos dentro de la escena y separarlos por ejemplo del fondo en la imagen.

El modelo para la segmentación semántica por aproximación sucesiva *Segment Anything Model* (SAM) desarrollado por *Meta AI Research* (Li, B, H & Tang, 2024), facilita comprender como se realiza esta tarea a nivel computacional. Al proporcionar una imagen de entrada figura 2.3a el modelo agrupa en segmentos los píxeles de la imagen de entrada generando en la salida máscaras o colecciones de píxeles que comparten características dentro de la escena figura 2.3b.




Figura 2.3 Fotografías de Marte, A imagen de entrada en un modelo de disparo cero, B imagen de salida en un modelo de disparo cero.
Créditos: NASA/JPL-Caltech.

Si bien visualmente podemos determinar que el modelo agrupó dentro de la imagen los conjuntos cielo, fondo y rocas en la escena, los resultados provienen del aprendizaje de disparo cero (F. Pourpanah, 2023), que es un escenario de aprendizaje automático en el que se entrena un modelo de IA para reconocer y categorizar objetos o conceptos sin haber visto ningún ejemplo similar previamente.

Aunque los modelos de segmentación semántica como YOLOv8 aprenden haciendo predicciones en un conjunto de datos de entrenamiento etiquetado donde las etiquetas de datos proporcionan el rango de respuestas posibles para cada ejemplo. En el aprendizaje de disparo cero, se ajustan las ponderaciones del modelo para minimizar la diferencia entre las predicciones del modelo y las respuestas posibles.

La segmentación semántica de imágenes, supervisada o no, es una tarea de especial utilidad en un sistema de visión por computadora, es una herramienta para identificar características específicas de los objetos en escena y generar una máscara superpuesta de la que podemos obtener datos como área que ocupa en escena, posición dentro de escena y grupo al que pertenece según sea necesario.

Ejemplo 2.2 Imágenes de Marte, Segmentación semántica de obstáculos (rocas) en escena.

Para el entrenamiento de una CNN, que se encarga de la segmentación semántica de un objeto, fue necesario proporcionar un conjunto de datos y un mapa de datos donde por medio de software se indica al modelo a entrenar la posición de los objetos de interés y el grupo al que pertenecen en cada una de las imágenes.




Figura 2.4 Fotografías de Marte, conjunto de datos y sus anotaciones para realizar segmentación semántica, los objetos de interés son rocas y fueron identificadas mediante la herramienta web Open Data Annotation.

Créditos: NASA/JPL-Caltech.

Dentro del sistema de visión por computadora desarrollado la segmentación semántica de obstáculos permite determinar la magnitud del obstáculo (en términos de área) para realizar maniobras de evasión según las características del sistema de locomoción.

2.2 Sistemas de visión LIDAR

Los sensores Light Detection and Ranging (LIDAR) son detectores que utilizan longitudes de onda de 775 a 795 nm para medir distancias con gran precisión. Funciona emitiendo pulsos de luz láser y midiendo el tiempo que tarda cada pulso en reflejarse en un objeto y regresar al sensor. Los datos recabados se utilizan para crear un modelo del entorno que podría ser bidimensional o tridimensional según la configuración del LIDAR (Q. Li, S. Dong, D. Zhang and X. Wang, 2020).

Dentro de un sistema de visión por computadora el sensor LIDAR proporciona la distancia de un objeto detectado en un ángulo de observación configurable. También puede recrear de forma digital su entorno utilizando nubes de puntos. Los datos se actualizan con velocidades de entre 2000 y 8000 muestras por segundo.

Ejemplo 2.3 Detección de objetos con LIDAR y paquetería de Robot Operating System (ROS) en sistemas LINUX.

Utilizando un sensor LIDAR modelo A2 es posible realizar la adquisición de pares ordenados que corresponden a la posición de obstáculos dentro del campo de visión del prototipo con un radio máximo de 12 metros. Los datos proporcionados por el sensor son bidimensionales y pueden ser visualizados utilizando las librerías de ROS.




Figura 2.5 Sistemas LIDAR, adquisición de datos bidimensionales.

2.5a Primera versión del prototipo durante las pruebas con el sensor LIDAR como único elemento del sistema de visión.

2.5b Visualización de nube de puntos 2D utilizando la herramienta ARviz de ROS.

En la figura 2.5a se observa un prototipo preliminar que integra un sensor LIDAR como único elemento de visión. El robot puede determinar la distancia a la que se encuentra un obstáculo, pero no tiene la capacidad de visualizar su entorno. La figura 2.5b muestra los pares ordenados como puntos en un plano a través de ROS.

2.3 Modelos de visión por computadora

Los modelos de visión por computadora (Diagrama 2.1) son cada vez más utilizados en aplicaciones relacionadas con la robótica. Tanto en la investigación como en aplicaciones industriales el uso de imágenes como entradas en una red neuronal artificial (RNA) soluciona con eficiencia diversos problemas de control.

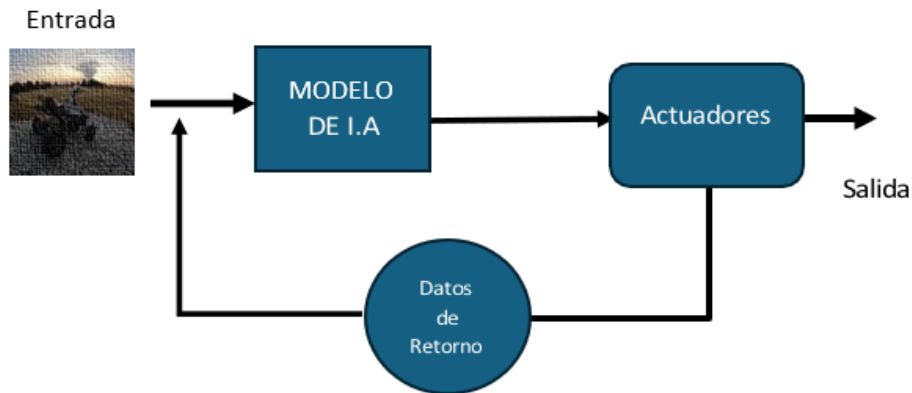


Diagrama 2.1 Modelo de inteligencia artificial en el control de actuadores.

Por otra parte, el desarrollo de hardware para equipos de cómputo ha impulsado este campo de la inteligencia artificial y la ciencia de la computación, desarrollando sistemas que pueden interpretar, analizar y comprender imágenes y videos digitales casi de la misma manera que lo haría un ser humano. Esto implica la capacidad de entender la información visual, identificar objetos, reconocer patrones, y extraer características significativas de las imágenes.

Algunas de las aplicaciones de la visión por computadora incluyen reconocimiento facial, clasificación de imágenes, segmentación semántica, seguimiento de objetos, análisis de imágenes médicas, vehículos autónomos, sistemas de seguridad, sistemas robóticos autónomos, aplicaciones espaciales, etc.

En el caso particular de los vehículos robóticos para la exploración espacial el uso estos modelos de visión por computadora disminuye los riesgos durante el desplazamiento del Rover sobre la superficie de Marte. El modelo de visión por computadora aporta datos relevantes a la computadora de abordo que facilitan la toma de decisiones en el sistema de navegación autónoma.

Es posible usar más de un modelo de visión por computadora en un sistema de navegación autónoma y los datos recibidos por cada modelo pueden ser el resultado de diferentes longitudes de onda lo que facilitaría la visión en condiciones adversas (lluvia, nieve o polvo).

Un ejemplo práctico de estos modelos de visión son las Hydranets de Tesla Motors®. En estos sistemas de navegación autónoma para vehículos observaremos que mientras una red se ocupa del reconocimiento de semáforos en una intersección, otra podría verificar las condiciones de tránsito en el camino y una más podría detectar la presencia de peatones (Diagrama 2.2.)

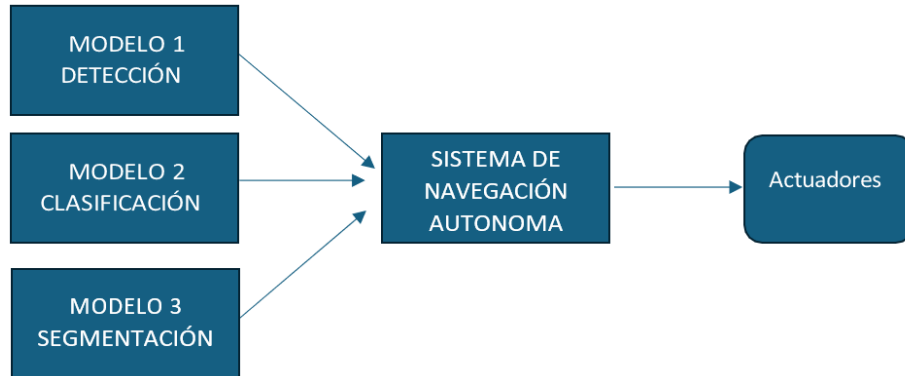


Diagrama 2.2 Modelo de visión por computadora con múltiples RNA.

Por las características mencionadas anteriormente, en este proyecto se toma como punto de partida el concepto de las Hydranets para la ejecución de múltiples RNA en una computadora principal que busca realizar una tarea específica, pero no se utiliza Hydranet. En su lugar se desarrolla un sistema de navegación autónoma que utiliza un modelo de detección de objetos y segmentación de imágenes en tiempo real (Joseph Redmon, Santosh Divvala, 2016).

2.3.1 HydraNet

Las HydraNets son redes amplias que contienen componentes distintos especializados para calcular características para clases visualmente similares, pero conservan la eficiencia al seleccionar dinámicamente solo una pequeña cantidad de componentes para evaluar cualquier imagen de entrada. Este diseño es posible gracias a un mecanismo de activación suave que fomenta la especialización de los componentes durante el entrenamiento y realiza con precisión la selección de componentes durante la inferencia (Velasco, Borja & Cerquides, 2023).




Figura 2.6 Arquitectura Hydranet, donde Z es la capa de representación. El modelo k+2 corresponde con los resultados potenciales del modelo k+1, $\hat{Q}(k, \cdot)$ y $\hat{G}(\cdot)$ la puntuación generalizada estimada.

2.4 Sistemas de locomoción en Rovers

Cuando hablamos del sistema de locomoción nos referimos al conjunto de elementos mecánicos que trabajan en uno o más mecanismos para conseguir el desplazamiento del Rover una distancia **d**.

En la exploración espacial podemos dar el crédito del primer sistema de locomoción probado en Marte al robot **Sojourner**, durante la misión Mars Path Finder. Si bien este Rover fue pequeño comparado con sus predecesores, logro navegar sobre las arenas marcianas por **83 días** utilizando un sistema de locomoción *rocker buggy* de seis llantas maquinadas en una aleación de titanio conocida como beta titanio que proporcionaba una combinación ideal de resistencia y flexibilidad para adaptarse a las condiciones del terreno marciano, ver figura 2.7.



Figura 2.7 Sojourner Rover y su sistema de locomoción Rocker-Bogie.
Créditos: Madrid Deep Space Communications Complex (MDSCC)

2.4.1 Sistemas de locomoción Rocker Bogie

Si bien la configuración Rocker Bogie figura 2.8 es un sistema de locomoción probado en las cinco misiones con Rovers lanzadas a Marte por la NASA y demostró buenos resultados en la exploración de planetas rocosos, también es un sistema que requiere de seis motores independientes y el maquinado de elementos mecánicos que se ensamblan al chasis del Rover. Lo que representa un reto de control mayor comparado con otros sistemas de locomoción más simples y menos costosos.




Figura 2.8 Sistemas de locomoción, configuración Rocker-Bogie.
Créditos: NASA/JPL-Caltech

En el caso del **Rover Perseverance** que fue el último robot enviado a Marte por la NASA, el sistema de locomoción cuenta con tres componentes principales:

- Diferencial, es un pivote en el centro de la plataforma superior lo conecta con los balancines izquierdo y derecho y el cuerpo del Rover.
- Balancín, uno a la izquierda, otro a la derecha. Conexión de la rueda delantera al diferencial y al bogie trasero.
- Carretón, conecta las ruedas intermedias y traseras al balancín.

La suspensión de bogie basculante del Rover le permite pasar sobre obstáculos (como rocas) o a través de depresiones tan grandes como la rueda del Rover (20,7 pulgadas o 52,5 centímetros). Cada rueda tiene una banda de rodadura con 48 garras (o tacos) mecanizadas en su superficie. Las garras brindan una excelente tracción al conducir sobre arena blanda y rocas duras.

2.4.2 Sistemas de locomoción de cuatro ruedas

Algunos sistemas de locomoción simples para vehículos de cuatro ruedas utilizados en la Tierra los podemos encontrar en automóviles y motocicletas en su mayoría aun impulsados por motores de combustión interna, pero también por motores eléctricos. Una ventaja de estos sistemas de locomoción son la cantidad de elementos mecánicos necesarios para lograr el movimiento, por otro lado, su diseño disminuye considerablemente la estabilidad en maniobras de descenso sobre un plano inclinado en comparación con los de seis ruedas.

En la figura 2.9 podemos observar la configuración base de un vehículo a gasolina impulsado solo por un motor, donde la tracción y dirección del vehículo se encuentran en el eje delantero. La suspensión en este sistema depende de pistones y resortes independientes para cada una de las ruedas.




Figura 2.9 Sistemas de locomoción, vehículos de cuatro ruedas con tracción solo en uno de sus ejes.

La principal desventaja en esta configuración se encuentra en la tracción del vehículo, durante el movimiento solo uno de los ejes del vehículo realiza trabajo y si perdiera fricción entre uno de los neumáticos y la superficie atascaría el vehículo impidiendo el movimiento. Por tal motivo, no puede pasar sobre obstáculos con altura superior al radio de las ruedas y debe evitarlos en todo momento.

Capítulo 3

Trabajo relacionado

Al escribir esta tesis solo dos Rovers (Curiosity y Perseverance) de un total de seis enviados a Marte se encuentran operativos. Esto no es casualidad ya que bajo las condiciones extremas del planeta rojo es complicado para un robot realizar cualquier tarea sin sufrir daños. Las temperaturas extremas y las constantes tormentas de arena son las principales causantes de fallos en un Rover, pero otras condiciones como la superficie rocosa del planeta, también causan desgaste que terminan por estropear los sistemas de locomoción.

Por este motivo construir y probar vehículos robóticos de exploración en la Tierra previo a cualquier misión es de indiscutible importancia. El JPL de la NASA tiene presente esta necesidad y desarrolla constantemente sistemas robóticos para atacar problemas específicos como la exploración de zonas de difícil acceso. Cuevas, cráteres y regiones montañosas son algunos ejemplos, durante el estudio de trabajos relacionados fueron considerados los Rovers que se encuentran en operación y algunas propuestas que se encuentran en desarrollo, (Shishko, R, Aster, 2018).

3.1 Perseverance Rover

La misión espacial de la NASA “Mars 2020 Perseverance Rover”, destinada a la exploración del planeta Marte. Fue lanzada el 30 de julio de 2020 y aterrizó con éxito en Marte el 18 de febrero de 2021. La misión tiene múltiples objetivos científicos, incluida recolección y análisis de muestras de rocas y la búsqueda de signos de vida microbiana pasada. Al igual que Curiosity Rover su antecesor, el Perseverance es un laboratorio robótico ambulante, equipado con múltiples detectores en su sistema de visión que nos han regalado hermosas postales del planeta rojo.

De los sistemas probados en la misión Perseverance, el estudio de los cinco elementos numerados en la figura 3.1 se considera de especial importancia en el desarrollo de este trabajo de tesis por ser sistemas necesarios para la operación del subsistema de descenso.




Figura 3.1 Rover Perseverance, misión en Marte activa desde 2021.
Créditos: NASA/JPL-Caltech.

El sistema de locomoción en el Perseverance está diseñado para descender sobre pendientes de hasta 45 grados, sin embargo, durante su exploración en Marte se limita a descenso sobre pendientes de 30 grados, con la finalidad de evitar riesgos.

3.2 NeBula-Husky

Estos robots están diseñados para desarrollar y probar tecnologías para explorar de forma autónoma en entornos desconocidos. NeBula-Husky ha sido probado con éxito en la Tierra en minas, cuevas y zonas urbanas subterráneas.

El sistema fue diseñado para abordar diversos desafíos técnicos en múltiples campos de la exploración autónoma de entornos extremos. El sistema de software modular unificado, llamado NeBula (Autonomía perceptual consciente de creencias en red). Está diseñado específicamente para abordar la estocasticidad y la incertidumbre en varios elementos de la misión, incluidos los sensores, el medio ambiente, el movimiento, el estado del sistema y la comunicación, entre otros.



- 1) Sistema de visión.
- 2) Chasis.
- 3) Sistema de locomoción.
- 4) Computadora de abordo.

*Figura 3.2 Vehículos robóticos exploradores de software modular unificado.
Créditos: NASA/JPL-Caltech.*

El sistema de navegación autónoma en los Rovers modelo NeBula utiliza algoritmos de visión por computadora que facilitan la navegación en lugares con poca iluminación y de difícil acceso como cuevas, pero su sistema de locomoción de cuatro ruedas y la distancia entre sus ejes dificultan su uso en aplicaciones de descenso sobre un plano inclinado.


De los sistemas probados en los Rovers NeBula, el estudio de los cuatro elementos numerados en la figura 3.2 se considera de especial importancia en el desarrollo de este trabajo de tesis por ser sistemas necesarios para mejorar el sistema de visión.

3.3 DuAxel

El DuAxel es un vehículo explorador lunar en desarrollo, diseñado para operar en la superficie de la Luna. Su nombre es una adaptación de "dual-axle" (doble eje en inglés), refiriéndose a su diseño con dos ruedas motrices independientes.

El DuAxel está diseñado para ser un vehículo extremadamente versátil y robusto, capaz de navegar por terrenos difíciles y explorar áreas que pueden ser inaccesibles para otros

vehículos convencionales. Este Rover cuenta con un diseño modular que le permite dividirse en dos partes separadas (chasis principal y la plataforma), cada eje está equipado con su propio motor y ruedas, lo que le permite maniobrar con mayor agilidad y sortear obstáculos de manera más eficiente. A diferencia de otros Rovers, DuAxel si está diseñado para realizar el descenso sobre un plano inclinado mayor a treinta grados, pero se encuentra en desarrollo.



- 1) Sistema de visión.
- 2) Mecanismo de separación modular.
- 3) Sistema de locomoción.
- 4) Chasis.


*Figura 3.3 Prototipo DuAxel para el descenso sobre un plano inclinado.
Créditos: NASA/JPL-Caltech.*

De los sistemas propuestos en DuAxel, el estudio de los cuatro elementos numerados en la figura 3.3 se considera de especial importancia en el desarrollo de este trabajo de tesis por ser sistemas diseñados para permitir el descenso sobre un plano inclinado. El prototipo DuAxel plantea una reestructuración del chasis, lo que también puede representar una desventaja en las actividades científicas por que los instrumentos para realizar análisis de suelo se encuentran resguardados en el interior del Rover.

3.4 LEMUR 3

El proyecto LEMUR es un prototipo en desarrollo que pertenece a una nueva generación de robots que se están construyendo en JPL para escalar paredes de roca. Este robot fue diseñado para operar en terrenos extremos, demostrando la aplicabilidad de sus sistemas para posibles misiones a Marte, la Luna y cuerpos pequeños.

El proyecto LEMUR plantea un rediseño total de los robots enviados a Marte con el objetivo de explorar acantilados utilizando cuatro extremidades con 7 grados de libertad y pinzas de micro espina para sujetarse a las rocas figura 3.4.



- 1) Sistema de visión.
- 2) Sistema de navegación.
- 3) Sensores.

*Figura 3.4 Prototipo Lemur, exploración sobre pendientes de 90 grados.
Créditos: NASA/JPL-Caltech*

Capítulo 4

Sobre el prototipo

El prototipo de Rover INAOE-AI-ROVER-01 es una herramienta diseñada para probar modelos de inteligencia artificial y navegación autónoma. Sus sistemas de visión y locomoción cuentan con elementos suficientes para desplazarse en zonas rocosas de forma segura con una autonomía de hasta 1.2 horas.

4.1 Diseño mecánico

El chasis de un Rover es la base sobre la que se colocan los sistemas que convierten un vehículo en un robot, si bien las dimensiones del chasis son la característica principal de este elemento mecánico, en la práctica se deben tomar en cuenta otras especificaciones como los materiales y puntos de unión en la estructura, (Beer, G, 2021).

Para el desarrollo del prototipo IA-ROVER-01 la calidad de los materiales utilizados en el chasis no es relevante, pues el propósito del **prototipo** es desarrollar un sistema de navegación autónoma bajo condiciones específicas (descenso sobre un plano inclinado). El prototipo no asemeja las características mecánicas de un Rover moderno.

La configuración base se puede describir como un vehículo de cuatro ruedas, con tracción en el eje trasero y un sistema de dirección mecánico de 22 grados de libertad en las llantas delanteras figura 4.1.




Figura 4.1 Diseño mecánico, vista inferior del prototipo AI-ROVER-01.

El sistema de locomoción es impulsado por un motor de combustión interna (a gasolina) de dos tiempos y mono pistón de 49cm^3 . La transferencia de torque al eje trasero se realiza por medio de un mecanismo de piñón y cadena con relación 3:1. Finalmente el sistema de control de aceleración utiliza un servomotor con 180 grados de libertad que regula la admisión de combustible en el carburador. La dirección por su parte es controlada con un mecanismo de transferencia, conectada a un servo motor de $550\text{ kg} \cdot \text{cm}$ fuerza, con un acoplamiento manufacturado en aluminio. La dirección tiene un bloqueo mecánico que permite solo movimientos de 22 grados (ver figura 4.2).

El diseño mecánico contempla la posición de sensores y actuadores que controlan las funciones en el sistema de visión. Las cámaras colocadas en el prototipo se encuentran a 1 m sobre el suelo para facilitar la detección de rocas.




Figura 4.2 Diseño mecánico, vista lateral reducida del prototipo AI-ROVER-01.

El mecanismo de descenso por otro lado depende de un motor eléctrico con caja de reducción que genera una fuerza de $350 \text{ kg} \cdot \text{cm}$ adicional a esto la fuerza se amplifica utilizando un mecanismo de piñón y cadena con relación 2:1 para logran 294 Newton fuerza (datos experimentales 5.5).

4.1.1 Análisis mecánico

El diagrama de cuerpo libre de la figura 4.3 presenta las fuerzas actúan sobre el Rover mientras realiza el ascenso y descenso sobre un plano inclinado. Al determinar la capacidad de torque instalada en el mecanismo de descenso como 294 Newton y sin considerar la fuerza generada por el motor de combustión interna, podemos determinar las fuerzas que se oponen al movimiento para calcular si el sistema de locomoción es funcional.

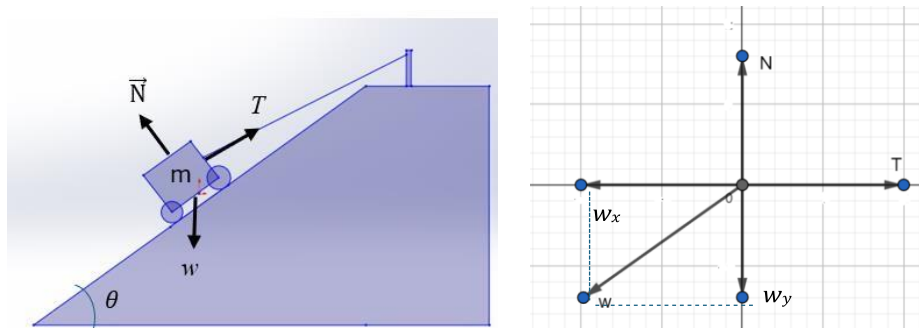


Figura 4.3 Diseño mecánico, Diagrama de fuerzas.

Datos:	<i>Coefficiente de fricción</i>	$\mu_k = 0.22$
	<i>Masa</i>	$m = 34 \text{ kg}$
	<i>Pendiente</i>	$\theta = 45^\circ$
	<i>Peso</i>	$w = 34 \text{ kg} * 9.81 \frac{\text{m}}{\text{s}^2} = 333.54 \text{ N}$
	<i>Torque</i>	$T = 294 \text{ N}$

Al aplicar la segunda ley de Newton:

$$F = m\vec{a} \rightarrow (1)$$

$$\sum F_x = T - F_k - w_x$$

$$\sum F_y = N - w_y = 0$$

$$\sum F_x = T - \mu_k * \vec{N} - w_x$$

$$\sum F_y = N = (333.54N)(\sin \theta)$$

$$\sum F_x = T - 0.22(235.84N) - w_x$$

$$\sum F_y = N = (333.54N)(\sin 45^\circ)$$

$$\sum F_x = T - 51.88N - 333.54(\cos 45)$$

$$\sum F_y = N = 235.84N$$

$$\sum F_x = T - 51.88N - 235.84N$$

$$\sum F_x = T - 287.72N$$

Por lo tanto, la fuerza total:

$$F_t = 294N - 287.72N = 6.28N$$

La aceleración por su parte:

$$\text{De (1)} \quad F_t = m\vec{a} \quad \text{ó} \quad \vec{a} = \frac{F_t}{m}$$

$$\vec{a} = \frac{6.28N}{34kg} = 0.184 \frac{m}{s^2}$$

Con estos resultados podemos concluir que se cuenta con el torque necesario en el prototipo para realizar el descenso o ascenso utilizando solamente el motor secundario y por lo tanto el mecanismo de descenso cumple con las necesidades del sistema de locomoción.

4.2 Diseño eléctrico y electrónico

Si bien durante el desarrollo de este proyecto de tesis el objetivo siempre fue llegar a un prototipo funcional. En el diseño del sistema eléctrico y electrónico fueron consideradas dos condiciones adicionales.

- Conseguir una autonomía mínima de 60 minutos para realizar pruebas.
- Aislamiento de actuadores, como una protección para las computadoras de abordo.

Respecto a las baterías instaladas en el prototipo se cuenta con dos baterías la primera es una batería Pb con capacidad de 11.2 Amperes x hora a 12 volts y la segunda es una batería de litio con 5.8 Amperes x hora a 14 volts. Con 16 amperes x hora instalados podemos conectar una carga de aproximadamente 192Wh.

Respecto al consumo energético del prototipo, la Tabla 4.1 especifica los vatios necesarios por componente electrónico.

Dispositivo	Modelo	Consumo en Wh
COMPUTADORA 1	Jetson Xavier	10Wh
COMPUTADORA 2	Raspberry 4	5Wh
INVERSOR DE CORRIENTE	DX-GAC500W	5Wh
SENSOR LIDAR	RP LIDAR A2	7.5Wh
PANTALLA	Odroid-VU7A	4Wh
MOTOR DIRECCIÓN	Docyke 500	280*0.2 =56Wh
SERVO MOTOR 1	Futaba MG996R	18*0.2 =3.6Wh
SERVO MOTOR 2	Futaba MG996R	18*0.2 =3.6Wh
MOTOR MECANISMO	ASME-04B	210*0.2=42Wh
TARJETA CONTROL 1	INAOE	0.5Wh
TARJETA CONTROL 2	INAOE	0.5Wh
	Total	137.7Wh

Tabla 4.1 Requerimientos eléctricos, componentes electrónicos y su consumo energético.

El consumo total de energía por hora es de 137.7 Wh mientras que la energía disponible es 192Wh por lo tanto el tiempo total de operación se puede calcular a partir de:

$$\text{Porcentaje de energía} = \frac{137.7}{192} * 100 = 71.71\%$$

Lo que representa el consumo de aproximadamente 71.71% y un porcentaje de energía disponible de 28.29% después de la primera hora de operación.

4.2.1 Distribución de cargas

Los voltajes instalados en el sistema eléctrico del prototipo son 120v-AC, 14v-DC, 12v-DC, 6v-DC y 5v-DC. La configuración del sistema (figura 4.4) mantiene separada la fuente de energía requerida por los motores mediante optoacopladores que además protegen la computadora principal y secundaria de corrientes inducidas.

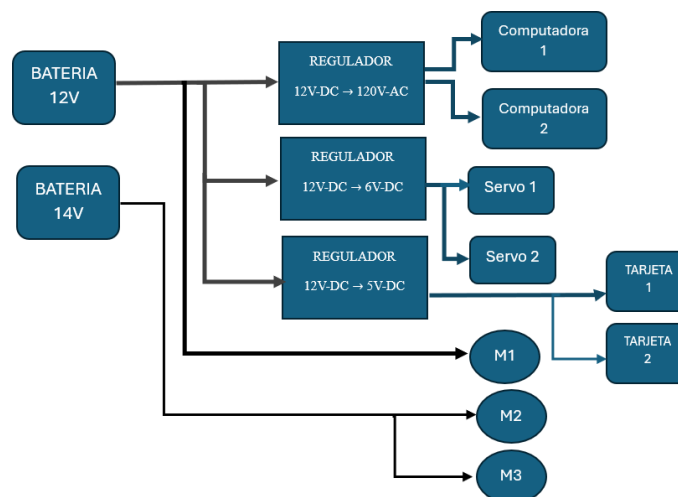


Figura 4.4 Diseño eléctrico, distribución de cargas instaladas y cambios de voltaje, donde M1 es el motor para la refrigeración de la computadora principal, M2 es el motor de la dirección y M3 es el motor del mecanismo de descenso.

La distribución de cargas presentada juega un papel importante dentro del diseño del prototipo ya que reduce la cantidad de cables y conexiones necesarias para la operación. En el prototipo fueron usados organizadores de cable en espiral y conectores XT60.

4.2.2 Circuitos electrónicos

Respecto a las tarjetas de circuito manufacturadas, la tarjeta 1 se encarga del control de los motores dirección y aceleración utilizando dos optoacopladores y transistores como protección (ver figura 4.5). La tarjeta 2 se encarga del control del mecanismo de descenso utilizando un optoacoplador y un relevador como se muestra en la figura 4.6.




Figura 4.5 Diagrama de circuito, tarjeta 1 optoacopladores.

En la tarjeta 1 los optoacopladores recrean el tren de pulsos (PWM) enviado por la computadora de abordaje para controlar la posición final de los motores de dirección y aceleración.




Figura 4.6 Diagrama de circuito, tarjeta 2 optoacoplador y relevador.

En la tarjeta 2 el optoacoplador recibe la señal de activación de la computadora de abordaje abriendo y cerrando el relevador para controlar el giro en el motor del mecanismo de descenso, al tratarse de un motor de corriente directa no es necesaria la modulación de ancho de pulso.

4.3 Computadoras de abordo

Fueron necesarias dos computadoras de abordo para controlar las funciones del prototipo AI-ROVER-01. La computadora principal modelo *NVIDIA Jetson Xavier* se encarga del procesamiento de imágenes y datos enviados por el sistema de visión, así como la toma de decisiones a través de una RNA. Por otra parte, la computadora secundaria modelo *Raspberry Pi 4* se encarga del control de tres servomotores, un motor a gasolina y un motor DC sin escobillas con caja de reducción. La relación entre las computadoras es maestro esclavo es decir la computadora secundaria recibe a través de los puertos de comunicación IO instrucciones que luego son ejecutadas según la programación.

4.3.1 Computadora principal Xavier

La Jetson Xavier es una computadora embebida de alto rendimiento desarrollada por NVIDIA®, diseñada específicamente para aplicaciones de inteligencia artificial y robótica.

La Jetson Xavier está equipada con un potente conjunto de hardware, incluyendo un Sistema en chip (SoC), que cuenta con un procesador octa-core ARM de 64 bits, una GPU Volta con Tensor Cores dedicados para acelerar operaciones de aprendizaje profundo, y una unidad de procesamiento de video (VPU) para tareas de visión por computadora y procesamiento de imágenes. Además, incluye una amplia gama de interfaces de E/S para conectividad con diferentes dispositivos y sensores.

4.3.2 Computadora secundaria Raspberry Pi 4

La Raspberry Pi 4 es la cuarta generación de una serie de computadoras de placa única (SBC) desarrolladas por la Fundación Raspberry Pi. Estas computadoras están diseñadas para ser económicas, de tamaño reducido y versátiles, lo que las hace ideales para una amplia gama de proyectos de computación.

Está equipada con un procesador Broadcom BCM2711 de cuatro núcleos Cortex-A72 de 64 bits que funciona a una velocidad de hasta 1.5 GHz, dispone de 4 GB de memoria RAM LPDDR4, lo que permite manejar una variedad de cargas de trabajo, desde aplicaciones básicas hasta tareas más intensivas en memoria e integra un procesador gráfico Video Core VI que ofrece un mejor rendimiento gráfico en aplicaciones con imágenes.

4.3.3 Sistema operativo

El sistema operativo utilizado en el prototipo fue Linux por su compatibilidad con la arquitectura de ambas computadoras, su compatibilidad con las librerías de ROS y finalmente por su facilidad para programar en Python 3 que es el lenguaje de programación utilizado en todo el software.

Linux® es un sistema operativo (SO) de código abierto y desarrollado para computadoras, servidores, mainframes y dispositivos embebidos. La ventaja principal sobre otros sistemas operativos es que podemos instalar un sistema muy ligero e ir añadiendo solo lo necesario para la operación del Rover.

4.4 Software de servicio

Como se discutió en la sección 4.3 el control del AI-ROVER-01 se encuentra embebido en dos computadoras de abordo Jetson Xavier (principal) y Raspberry Pi 4 (secundaria).

La computadora principal se encarga de recibir las imágenes de entrada y calcular a través de los modelos de visión la posición, tamaño y distancia a la que se encuentran los obstáculos. Estas instrucciones se transmiten a la computadora secundaria que se encarga de controlar la posición de los actuadores para conseguir el movimiento del Rover.

Podríamos hacer una analogía comparando la computadora principal con el cerebro humano que recibe las imágenes de nuestro entorno por medio de los ojos y la computadora secundaria como la comunicación entre el sistema nervioso y el sistema muscular al realizar algún movimiento.

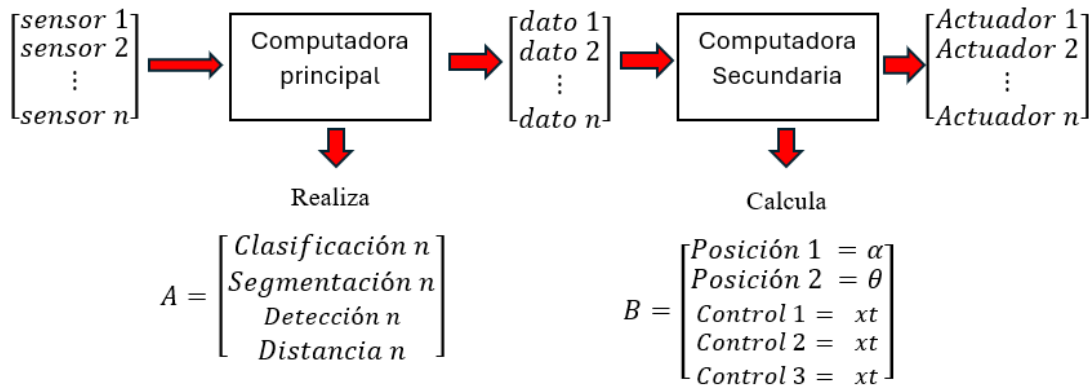


Figura 4.7 Diagrama de operación en computadoras de abordo, el vector A representa las tareas que pueden ser ejecutadas en la computadora principal y el vector B los valores que son calculados en la computadora secundaria según los datos de entrada recibidos.

En la figura 4.7 se muestra un análisis serial del algoritmo de control en el Rover, donde los primeros elementos en generar datos de entrada son los sensores, estos datos son esencialmente imágenes sobre las que podemos realizar detección de patrones de interés. En la salida de los modelos de IA, ejecutados en la computadora principal, los denominados datos son instrucciones que deben ser interpretados por la computadora secundaria para calcula las posiciones en los actuadores.

Luego de terminar el primer ciclo, se actualizan los valores de entrada en el sistema de visión y se repiten las operaciones, esta vez considerando los valores calculados en el vector B antes de generar una respuesta.

4.4.1 Software para evasión de obstáculos

Realizar la evasión de obstáculos es la función principal del modelo de visión, esta tarea requiere de un seguimiento en tiempo real de los obstáculos. Para definir que es tiempo real en este prototipo, debemos aclarar que la cámara detectora envía una secuencia de imágenes de 60 cuadros por segundo, es decir, el modelo analiza 60 fotografías para encontrar características nombradas obstáculos en la imagen. Esta tarea implementa el algoritmo Simple Online And Realtime Tracking (SORT) para identificar los elementos que se mueven dentro del rango de visión del Rover o escena (figura 4.8).




Figura 4.8 Software de visión, Seguimiento de objetos en escena.

4.4.2 Algoritmo Sort

El método se describe mediante los componentes clave de detección, propagación de objetos en fotogramas futuros, asociar detecciones actuales con objetos existentes y gestionar la vida útil de los objetos rastreados. Sort es un algoritmo confiable para realizar seguimiento de múltiples objetos (MOT), donde los objetos se detectan en cada cuadro y se representan como cuadros delimitadores o cajas. La mayoría de las soluciones MOT tienen como objetivo impulsar el rendimiento hacia mayor precisión, a menudo, a costa del rendimiento del tiempo de ejecución. Pero en el caso de los vehículos robóticos de exploración tanto la velocidad como la precisión en la detección de objetos es relevante. La figura 4.9 tomada del artículo (Bewley & Paulus 2017). Muestra los resultados de Sort en comparación con otros algoritmos.

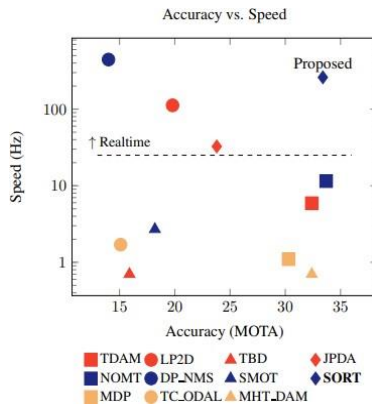


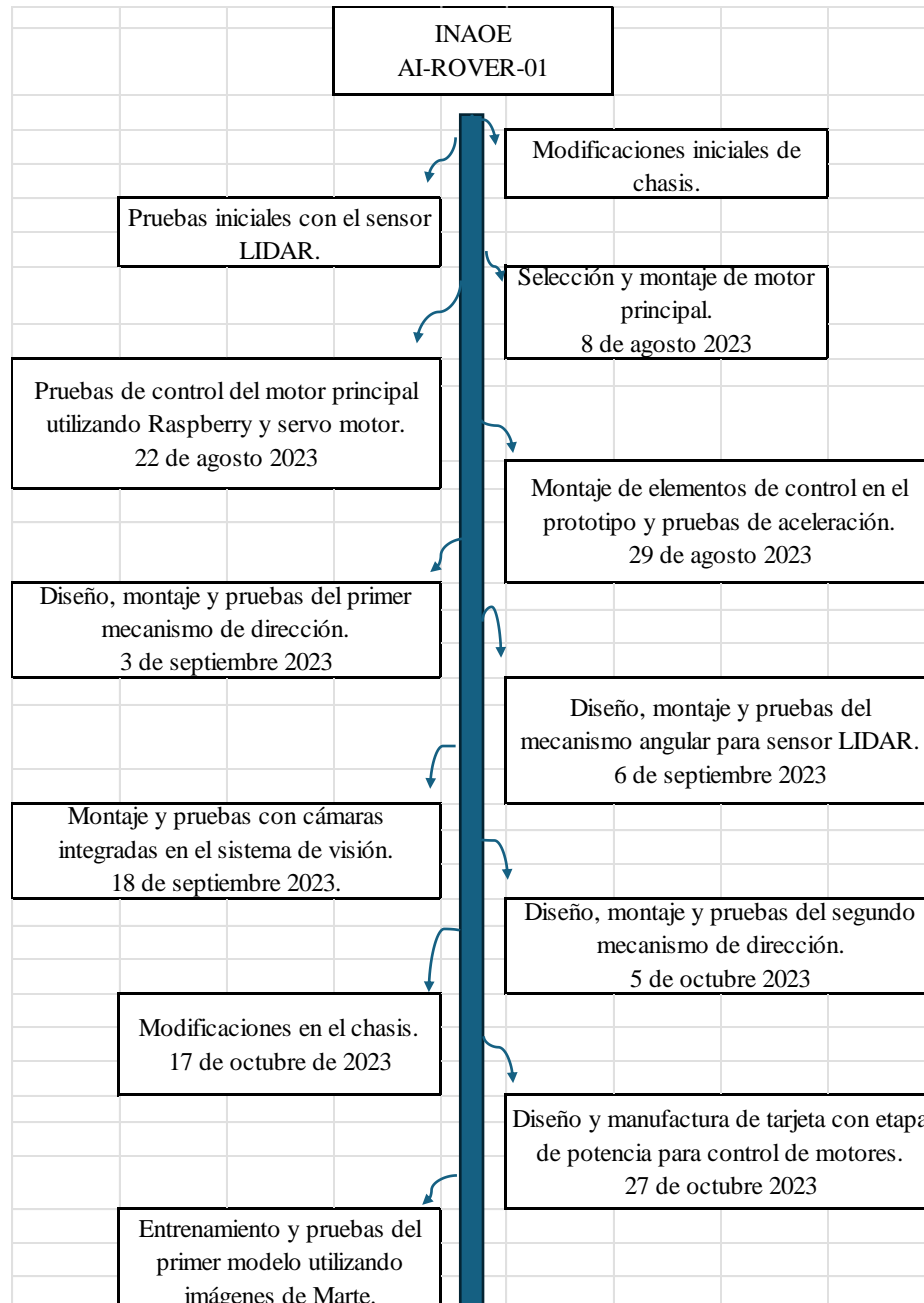
Figura 4.9 Software de visión, resultados del algoritmo Sort en el seguimiento de objetos. Créditos: Bewley & Paulus 2017.

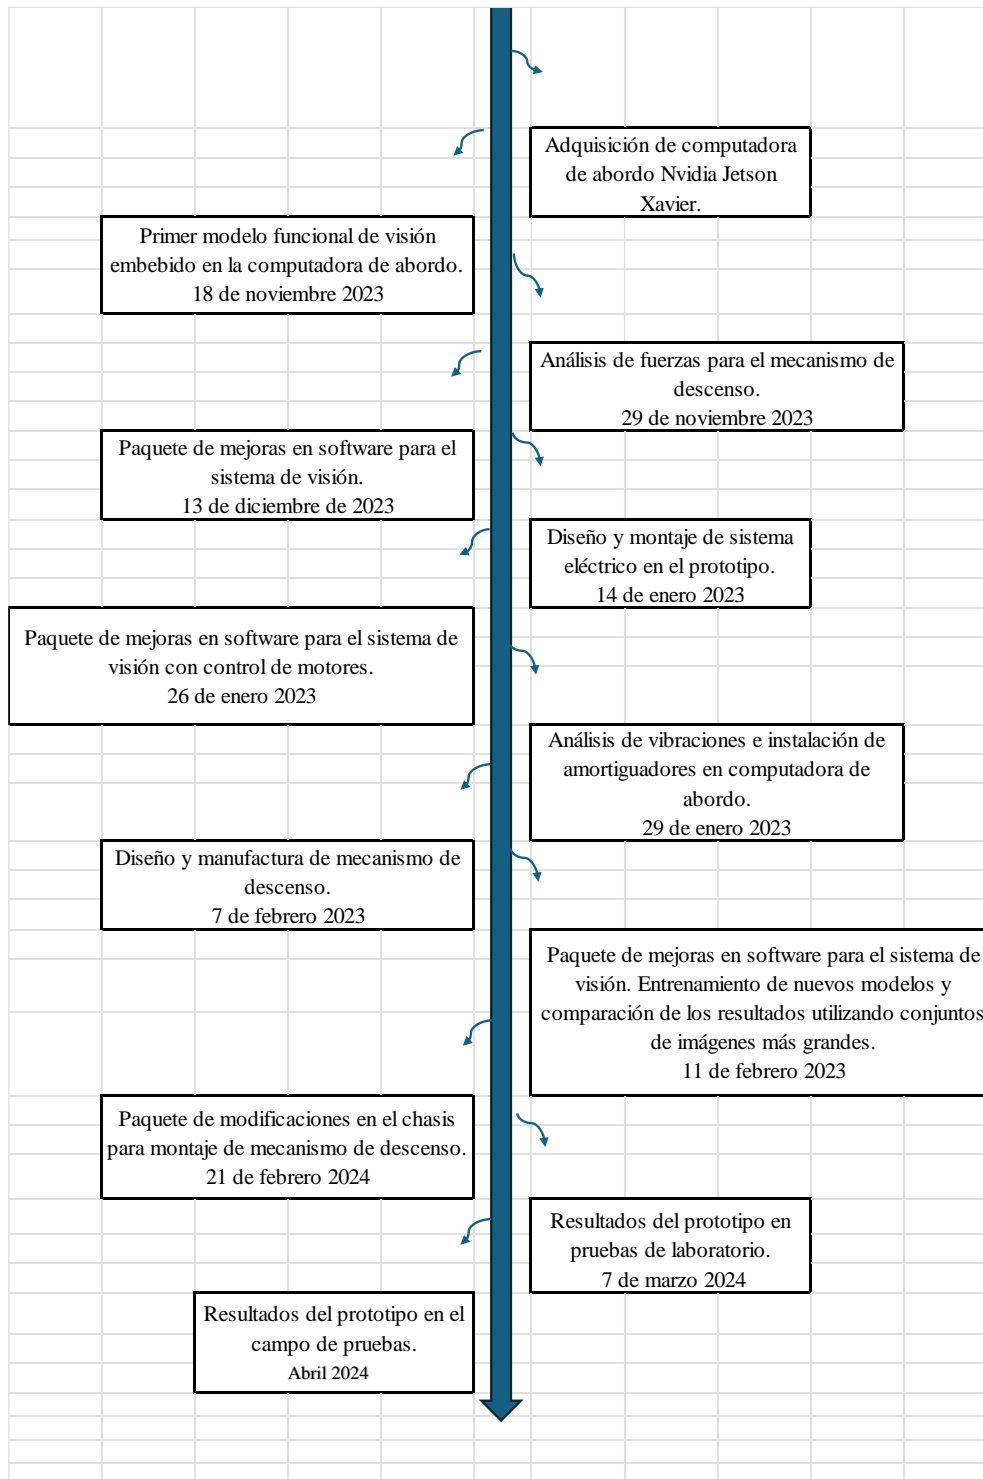
Capítulo 5

Pruebas y resultados

En este capítulo se documentan los experimentos realizados y los resultados obtenidos durante el desarrollo de este trabajo de tesis.

5.1 Mapa cronológico de experimentos





5.2 Características del campo de pruebas

El uso de diseño asistido por computadora en el desarrollo del prototipo facilitó la construcción de los mecanismos necesarios para su operación y permitió gestionar el espacio disponible en el chasis sin la necesidad de modificaciones complejas. Una vez finalizadas las pruebas en laboratorio son necesarias las pruebas de campo para cuantificar los resultados obtenidos durante el entrenamiento de la RNA Mad_Mars.

Las condiciones fueron inicialmente simuladas utilizando la herramienta computacional SolidWorks® como se muestra en la figura 5.1 donde el ensamble final del prototipo desciende sobre un plano inclinado con pendiente de 45 grados.




Figura 5.1 Resultados en simulador, uso de herramientas computacionales en el desarrollo del prototipo.

Se construyó un campo de pruebas con pendientes mayores a 30 grados utilizando grava y rocas para simular el entorno de un planeta rocoso como Marte (figura 5.3). Sin embargo, no fue posible una pendiente homogénea en toda la rampa, las mediciones arrojadas por el sensor LSM6DSL muestran pendientes de hasta 44.6 grados. En la figura 5.2 se pueden comprobar las mediciones que corresponden a diferentes secciones de la rampa. Para los fines prácticos de este trabajo las pendientes mayores a 30 grados son un buen punto de partida.

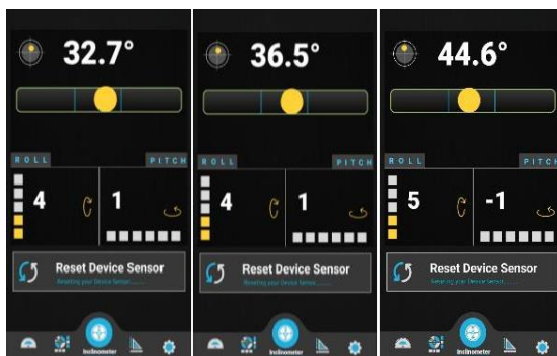


Figura 5.2 Resultados de pendiente, determinados utilizando el sensor LSM6DSL.



Figura 5.3 Resultados de la construcción de campo de pruebas.

5.3 Prototipo INAOE-AI-ROVER-01

Las etapas de construcción del prototipo (Tabla 5.1) muestran las actividades programadas inicialmente para finalizar el prototipo en mayo de 2024. Finalmente se logró concluir el prototipo de forma anticipada en marzo 2024.

Actividad	AÑO 2023					AÑO 2024				
	Agos	Sep	Oct	Nov	Dic	Ene	Feb	Marz	Abr	May
Diseño preliminar modulo de transporte	█	█								
Diseño preliminar modulo de visión	█	█								
Ensamble de chasis		█	█							
Diseño de controlador y etapa de potencia para motor de dirección			█	█						
Diseño de controlador para motor de sistema de locomoción			█	█						
Fabricación y compra de elementos del mecanismo de descenso			█	█						
Ensamble de caja reductora en mecanismo de descenso			█	█						
Prueba de mecanismos en campo				█	█					
Pruebas con sensores LIDAR				█	█					
Desarrollo de algoritmo de IA				█	█					
Integrar estructura de visión en prototipo										
Pruebas de operación sistema de visión										

Tabla 5.1 Actividades programadas para la construcción del Rover, descritas de forma general.

Con la finalidad de describir los elementos que se integran en el prototipo, características y propósito operativo, la figura 5.4 muestra los resultados obtenidos en el ensamble.



Figura 5.4 Prototipo INAOE-AI-ROVER-01. Elementos, características y propósito de operación.

- 1) El sistema de visión está montado sobre una plataforma fija, cuenta con dos cámaras modelo GoPro Hero y un sensor LIDAR modelo A2 que integra un mecanismo para permitir dos grados de libertad.

- 2) Motor de dirección montado sobre una plataforma fija, con un acoplamiento de aluminio para transmitir la fuerza al eje delantero del Rover.
- 3) La computadora principal se resguarda dentro de una caja anclada sobre la plataforma con amortiguadores de goma para evitar vibraciones. Computadora secundaria montada sobre una plataforma de aluminio fija anclada por tornillos.
- 4) Mecanismo de descenso anclado por tornillos al chasis, con un motor DC sin escobillas y tarjeta de control independiente.
- 5) Motor principal de combustión interna 49 centímetros cúbicos monocilíndrico y mecanismo de piñón y cadena para transmitir el torque al eje trasero.
- 6) Mecanismo de dirección y amortiguadores para controlar el ángulo de giro y facilitar el descenso sobre terreno irregular.
- 7) Regulador de voltaje y tarjetas de protección con optoacopladores que suministran la energía necesaria a todos con componentes electrónicos y motores. Se encargan además de proteger las computadoras de a bordo de picos de voltaje por inducción.

5.4 Reducción de la vibración

Si bien la mayoría de los elementos del prototipo están diseñados para soportar la vibración generada por el motor de combustión interna, la computadora principal, los motores para refrigeración y los pines de conexión son especialmente sensibles. Es necesario disminuir la vibración con respecto al chasis tanto como sea posible.

Las vibraciones en la computadora de abordo se midieron utilizando el sensor LSM6DSL determinando picos máximos de 23.49 m/s^2 cuando el motor de combustión interna este acelerado figura 5.5a y de 17.45 m/s^2 cuando el motor se encuentra en marcha sin experimentar aceleración (figura 5.5b).

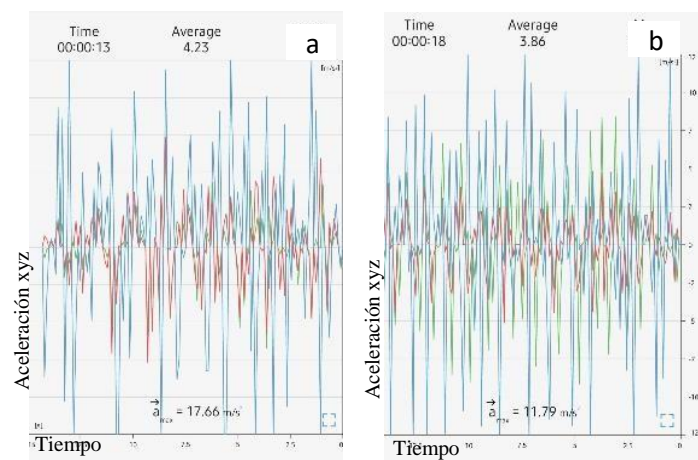


Figura 5.5 Análisis de vibraciones en computadora principal, **a** vibración máxima detectada al encender el motor de combustión interna, **b** vibración máxima detectada con el motor de combustión en marcha bajo aceleración.

Para mejorar estos resultados fueron necesarias dos mejoras en el chasis del prototipo:

- I. Plataforma adicional en el chasis.
- II. Instalación de cuatro amortiguadores de caucho.

Los resultados de las mejoras se pueden apreciar en la figura 5.6a y figura 5.6b respectivamente.

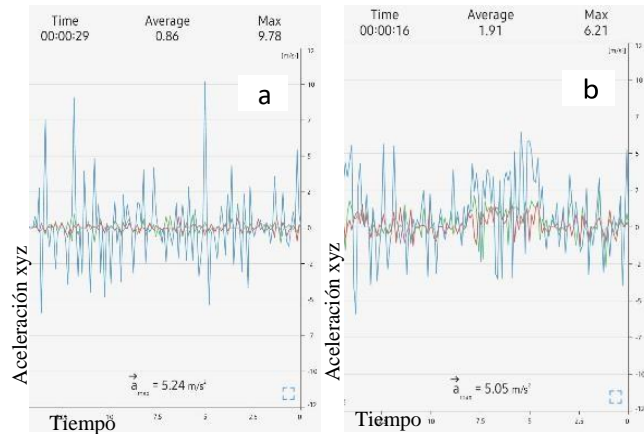


Figura 5.6 Resultados de mejoras para reducir la vibración, **a** con plataforma fija **b** con amortiguadores de caucho.

En conclusión, utilizando el sensor LSM6DSL para medir las vibraciones en los ejes XYZ se logra reducir los picos de 23.49 m/s² a 6.21 m/s² lo que representa una reducción en la vibración de 73.59 %.

5.5 Mecanismo de descenso en cráteres

El mecanismo de descenso está inspirado en como los alpinistas utilizan puntos de anclaje para realizar descenso por paredes verticales. El punto de anclaje para este prototipo fue colocado de forma manual, se trata de una barra de acero con punta de 25 cm y una argolla para conectar la soga de anclaje. Sin embargo, el anclaje puede ser colocado de forma autónoma por los Rovers modernos que cuentan con un brazo mecánico y herramientas para realizar perforaciones en roca.

Una vez colocado el anclaje, el descenso sobre un plano inclinado se vuelve estable, la figura 5.7a muestra el diseño preliminar del mecanismo, la figura 5.7b el mecanismo manufacturado montado en el prototipo y figura 5.7c el prototipo funcional durante los experimentos de descenso en campo de pruebas.




Figura 5.7 A Diseño, B manufactura y C pruebas del mecanismo de descenso.

Para comprobar los resultados obtenidos en el diseño y construcción del mecanismo de descenso fue necesario realizar pruebas bajo diferentes niveles de tensión (ver Tabla 5.2) con la finalidad de obtener la caracterización del mecanismo de descenso y asegurar que los niveles de tensión disponibles en el prototipo satisfacen la demanda de energía durante la operación del Rover en modo descenso (figura 5.8).

Caracterización Mecanismo de descenso				
Prueba	Voltaje (V)	Amperaje (A)	Torque (KG)	Fuerza (N)
1	6	1.5	2	19.62
2	8	1.7	5	49.05
3	10	1.9	7	68.67
4	12	1.9	10	98.1
5	14	2	15	147.15
6	16	2	15	147.15
7	14	2.4	20	196.2
8	20	2.5	30	294.3

Tabla 5.2 Caracterización del mecanismo de descenso durante operación con diferentes niveles de tensión.




Figura 5.8 Caracterización del mecanismo, niveles de tensión y corriente.

Otro dato relevante es el comportamiento de la fuerza total obtenida a la salida del mecanismo de descenso que se ilustra en las figuras 5.9 y 5.10.




Figura 5.9 Caracterización del mecanismo, grafica de fuerza en relación con el voltaje de entrada.




Figura 5.10 Caracterización del mecanismo, grafica de fuerza en relación con el amperaje requerido.

Las pruebas en laboratorio de este mecanismo demuestran que utilizando 14V como alimentación para el motor se pueden mover 30 kg de peso es decir 294 N a la salida del sistema, si bien el mecanismo es simple los resultados obtenidos comprueban que con solo un punto de anclaje es posible mejorar la estabilidad del Rover durante el descenso sobre un plano inclinado, figura 5.7c.

5.6 Red Neuronal Artificial Mad_Mars

El modelo de RNA Mad_Mars es el resultado de una serie de entrenamientos y pruebas utilizando dos conjuntos de imágenes diferentes. El primer conjunto de datos “Nasa Mars Surface” integra fotografías tomadas desde la superficie de Marte por el Curiosity Rover. La figura 5.11a muestra algunos ejemplos de las imágenes de este conjunto. En el segundo conjunto de imágenes “Mad-Max” se observan imágenes capturadas en el desierto de Turquía, un conjunto de datos ampliamente utilizado en el entrenamiento de Rovers por la similitud de este desierto con la superficie marciana (figura 5.11b).



Figura 5.11 Ejemplos de imágenes utilizadas para entrenamiento de la RNA.

Las imágenes se dividieron en tres grupos de entrenamiento (A, B y C). El grupo A consta de 200 imágenes del conjunto de datos Nasa Mars, el grupo B consta de 200 imágenes del conjunto de datos Mad-Max y el grupo C consta de 100 imágenes del conjunto Nasa Mars y 100 imágenes del conjunto Mad-Max. La Tabla 5.3 muestra la distribución de imágenes en cada uno de los grupos.

Grupo	A	B	C
Superficie Marte	200	0	100
Desierto Marroquí	0	200	100
total	200	200	200

Tabla 5.3 Distribución de imágenes para el entrenamiento de RNA.

Las configuraciones en los hiperparámetros utilizados y los modelos de red entrenados también fueron documentados y se listan en la Tabla 5.4.

GPU NVIDIA GTX 1650TI - PROCESADOR INTEL CORE I5 11Gen - DDR 4 RAM 16G								
Configuración Default								
	RNC	Datos train	Num Img	Datos Test	Epocas	Batch Size	Learning Rate	Momentum
1	YoloV8n	Mad_Max	200	Mars_Nasa	60	21	0.001	0.9
2	YoloV8n	Mad_Max	200	Mars_Nasa	60	28	0.001	0.9
3	YoloV8n	Mad_Max	200	Mars_Nasa	60	32	0.001	0.9
4	YoloV8n	Mars_Nasa	200	Mad_Max	60	21	0.001	0.9
5	YoloV8n	Mars_Nasa	200	Mad_Max	60	28	0.001	0.9
6	YoloV8n	Mars_Nasa	200	Mad_Max	60	32	0.001	0.9
7	YoloV8n	Mad_Mars	200	Mad_Mars	60	21	0.001	0.9
8	YoloV8n	Mad_Mars	200	Mad_Mars	60	28	0.001	0.9
9	YoloV8n	Mad_Mars	200	Mad_Mars	60	32	0.001	0.9

Tabla 5.4 Hiperparámetros en el entrenamiento de modelos de RNA y datos del equipo de cómputo.

Los resultados para cada uno de los grupos se pueden observar en las gráficas de pérdida para los datos de entrenamiento y validación con una relación de 80 a 20. Adicionalmente el modelo YoloV8 imprime los resultados de la segmentación en las imágenes de validación lo que permite observar los resultados del entrenamiento.

5.6.1 Resultados del entrenamiento grupo A

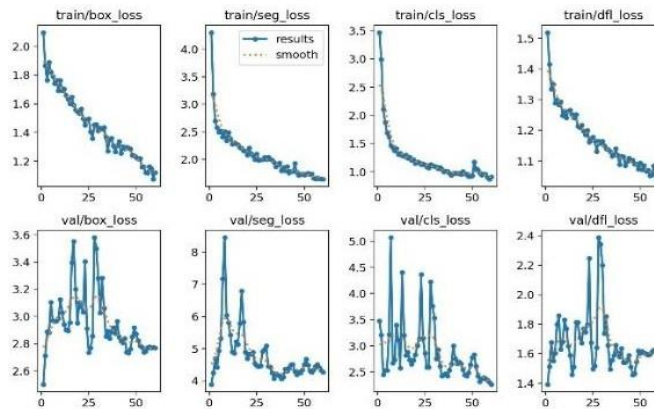


Figura 5.12 Gráficas de pérdida durante entrenamiento y validación del grupo A.

Las gráficas de pérdida de la figura 5.12 representan los resultados en las imágenes de prueba de las figuras 5.13a y 5.13b se observan errores en el reconocimiento de patrones, imágenes donde no se realiza ninguna detección e imágenes donde toda la escena se detecta como un obstáculo. Podemos cuantificar los resultados como **5 de 16** imágenes segmentadas correctamente en el grupo A.




Figura 5.13 Comparación de imágenes segmentadas de forma manual vs resultados de la segmentación por un modelo de RNA grupo A.

5.6.2 Resultados del entrenamiento grupo B




Figura 5.14 Graficas de perdida durante entrenamiento y validación del grupo B.

Las gráficas de perdida de la figura 5.14 representan los resultados en las imágenes de prueba de las figuras 5.15a y 5.15b se observa que ninguna de las detecciones es correcta. Podemos cuantificar los resultados como **0 de 16** imágenes segmentadas correctamente en el grupo A

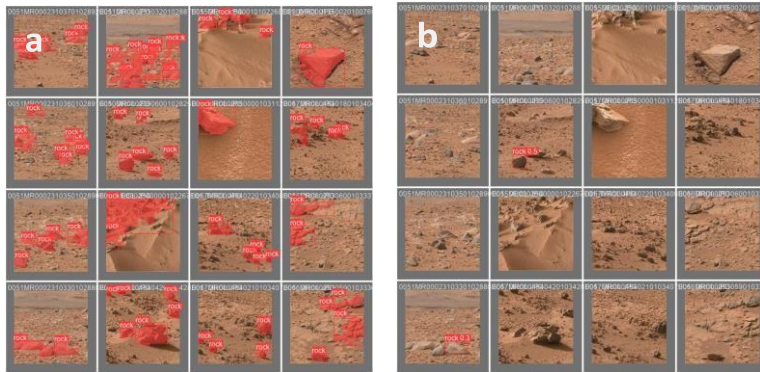


Figura 5.15 Comparación de imágenes segmentadas de forma manual vs resultados de la segmentación por un modelo de RNA grupo B.

5.6.3 Resultados del entrenamiento grupo C

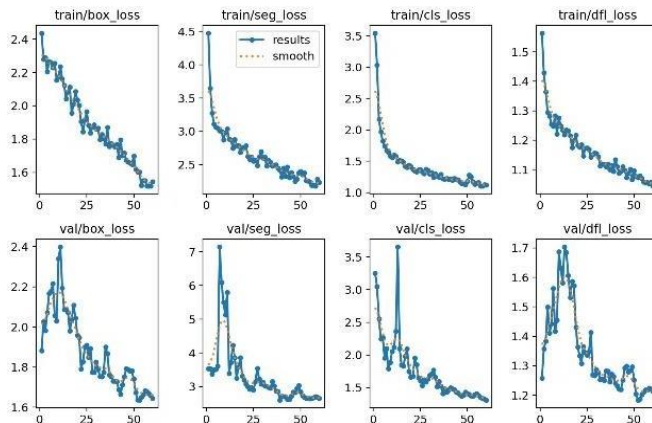


Figura 5.16 Graficas de perdida durante entrenamiento y validación del grupo C.

Las gráficas de pérdida de la figura 5.16 representan los resultados en las imágenes de prueba de las figuras 5.17a y 5.17b, de los resultados obtenidos en el entrenamiento de los tres grupos podemos confirmar que el grupo C presenta mejores resultados en la identificación de obstáculos.

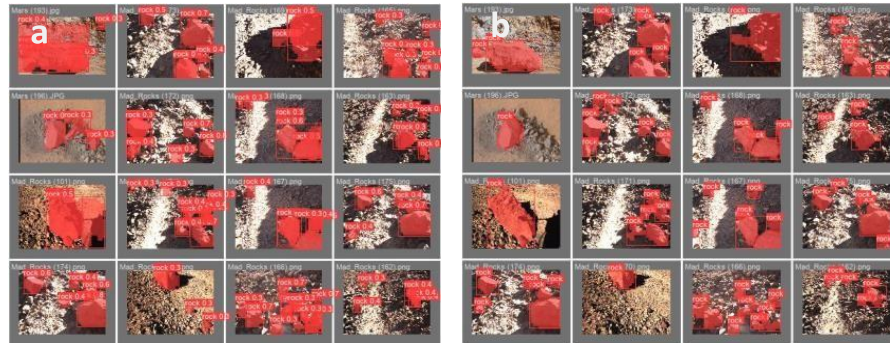


Figura 5.17 Comparación de imágenes segmentadas de forma manual vs resultados de la segmentación por un modelo de RNA grupo C.

5.7 Resultados del modelo Mad_Mars

Durante las pruebas de laboratorio el modelo de RNA del grupo C fue ejecutado sobre la computadora de abordo NVIDIA Jetson Xavier. Entregando resultados satisfactorios en el seguimiento de objetos en tiempo real figura 5.18.




Figura 5.18 Seguimiento de objetos utilizando el modelo entrenado con datos del grupo C.

Por el contrario, al utilizar imágenes con obstáculos en el campo de pruebas (figura 5.19) los resultados no fueron satisfactorios, la exposición directa a la luz solar afecta los resultados de detección. Este hecho se comprueba experimentando con el modelo de detección en diferentes horarios como se muestra en la Tabla 5.5.



Figura 5.19 Imágenes de entrada, campo de pruebas en diferentes horarios.

	RNC	Fotos	hora	Filtro	Exactitud
1	Yolo_Mad_Mars	20	9 hrs	0	35%
2	Yolo_Mad_Mars	20	14hrs	0	60%
3	Yolo_Mad_Mars	20	18 hrs	0	50%
4	Yolo_Mad_Mars	20	14 hrs	Mars	90%

Tabla 5.5 Comparación de los resultados de detección de objetos en diferentes horarios.

Los resultados finales de estos experimentos se mejoran un 30% al aplicar el filtro “Mars” que reduce el brillo y aumenta el contraste en las imágenes de entrada, lo que mejora la detección de obstáculos en escena.

5.8 Discusión de los resultados

Este proyecto presenta un prototipo funcional de Rover como resultado principal de la investigación y podría ser comparado con algunas de las propuestas en desarrollo descritas en el capítulo 3 en cuanto al mecanismo utilizado para realizar el descenso sobre un plano inclinado. Sin embargo, al realizar esta comparación también tendríamos que comparar las características del sistema de locomoción.

Los sistemas de locomoción utilizados tanto en Rovers que se encuentran operativos como los prototipos en desarrollo son más robustos que el sistema de locomoción utilizado para este estudio. A pesar de esta desventaja mecánica la estabilidad del sistema mejora considerablemente, permitiendo el descenso de nuestro prototipo sobre un plano inclinado con pendientes de hasta 44 grados, un valor que se encuentra 14 grados sobre la pendiente máxima considerada como segura por los Rovers más sofisticados probados en Marte.

Por otro lado, la barrera de los 30 grados en el descenso de pendientes es en realidad producto de una medida de seguridad adicional del JPL con la finalidad de resguardar los Rovers marcianos de cualquier falla catastrófica. En la Tierra los gemelos de los Rovers Curiosity y Perseverance han probado que pueden descender por pendientes de hasta 45 grados gracias a las características de sus sistemas de auto navegación y locomoción.

Podríamos pensar que la aportación de este subsistema de descenso se ve minimizada por los sistemas de locomoción Rocker-Bogie. Sin embargo, la barrera de los 30 grados en Marte es una realidad y debe ser superada. Por esta razón nuestro sistema utiliza elementos del sistema de visión disponibles en los Rovers modernos y propone un nuevo mecanismo para mejorar la estabilidad, de tamaño reducido y anclado al chasis con dos tornillos. Un subsistema compatible con cualquier Rover sin importar la configuración de su sistema de locomoción.

Los resultados obtenidos en el sistema de visión por computadora en cuanto a detección, clasificación y segmentación de escenas se pueden comparar con el aprendizaje esperado en un modelo de Yolo como se expone en [9]. Por el contrario, lograr estos resultados en un sistema de visión por computadora embebido fue desafiante, no solo por las limitaciones de hardware donde fue necesario probar computadoras fabricadas por Raspberry®, Odroid® y NVIDIA® hasta alcanzar el resultado deseado. Sino que, además, trabajar con conjuntos de datos limitados o restringidos como imágenes tomadas desde la superficie de Marte, convirtió el desarrollo del modelo Mad_Mars en todo un reto.

Capítulo 6

Conclusiones y trabajo a futuro

La propuesta del subsistema de descenso descrito en esta investigación aporta una mejora para los Rovers que ya se encuentran en operación, al permitirles aumentar la estabilidad durante el descenso sobre un plano inclinado. El subsistema requiere en su mayoría de instrumentos que ya se encuentran instalados y considera solo una modificación en el chasis para acoplar un nuevo mecanismo.

También es útil para quienes se encuentran en la etapa de desarrollo de nuevas propuestas de vehículos robóticos para la exploración y quieren mejorar la estabilidad de su prototipo durante el descenso sobre un plano inclinado usando nuevos sistemas de locomoción.

Los resultados obtenidos durante el entrenamiento de la red Mad_Mars pueden ser mejorados con conjuntos de datos más grandes, donde la clase obstáculo incluya zonas de arena, grava, bache, mina, barranco etc. Sin embargo, se demostró que podemos utilizar los datos de misiones en otros planetas para entrenar redes neuronales artificiales de Rovers construidos y probados en la Tierra, lo que es muy favorable en el campo de la visión por computadora donde una mayor cantidad de datos por lo general mejora los resultados del entrenamiento.

Con sistemas de visión y locomoción simples pero funcionales, el prototipo AI-ROVER-01 desarrollado durante esta investigación puede ser utilizado para probar algoritmos de visión por computadora y navegación autónoma, un área de investigación de gran interés científico en constante desarrollo.

¿Es posible habitar otros planetas? ¿Existe o existió vida en otro lugar del sistema solar?

Los Rovers ayudan a comprender más sobre nuestro sistema solar y sus orígenes, debemos continuar mejorando esta tecnología para llegar a lugares cada vez más distantes donde probablemente encontraremos respuesta a estas y otras preguntas.

El universo es inmenso y queda mucho por descubrir

Trabajo a futuro

Algunas ideas para trabajo a futuro son presentadas a continuación.

- Mejorar los resultados obtenidos por la red Mad_Mars.
- Cambiar el sistema de locomoción por una configuración Rocker Bogie.
- Eliminar el motor a gasolina e instalar en su lugar un motor eléctrico.
- Desarrollar software para optimización de las trayectorias.
- Mejorar el sistema de visión con radares y cámaras que aumenten la precisión de los datos de entrada.
- Construir un brazo con al menos 3 articulaciones para programar tareas de minería.

Bibliografía

- [1] Asad, H., Shrimali, V. R., & Singh, N. (2020). *The Computer Vision Workshop The Computer Vision Workshop: Develop the skills you need to use computer vision algorithms in your own artificial intelligence projects*. Packt Publishing.
- [2] Baig, M. R., Joseph, T. V., Sadvilkar, N., Silaparasetty, M. K., & Anthony So. (2020). *The Deep Learning Workshop The Deep Learning Workshop: Learn the skills you need to develop your own next-generation deep learning models with TensorFlow and Keras*. Packt Publishing.
- [3] Beer, G. (2021). *Dinámica Mecánica Vectorial Para Ingenieros*. McGraw-Hill Companies, (12ava ed.).
- [4] Beer, G. (2021). *Estática mecánica Vectorial Para Ingenieros*. McGraw-Hill Companies, (12ava ed.).
- [5] Lakdawalla, E. (2018). *The design and engineering of curiosity: How the mars rover performs its job* (1a ed.). Springer International Publishing.
- [6] Shanmugamani, R. (2018). *Deep Learning for Computer Vision: Expert techniques to train advanced neural networks using TensorFlow and Keras*. Packt Publishing.
- [7] Shishko, R., Aster, R., & Cassingham, R. C. (2018). *NASA Systems Engineering Handbook*. Franklin Classics.
- [8] *Teoría de máquinas y mecanismos*. (2020). Editorial Universidad de Sevilla.
- [9] Wojke, N., Bewley, A., & Paulus, D. (2017). *Simple online and realtime tracking with a deep association metric*. 2017 IEEE International Conference on Image Processing (ICIP).
- [10] Velasco-Regulez, Borja & Cerquides, Jesús. (2023). *Hydranet: A Neural Network for the Estimation of Multi-Valued Treatment Effects*. 10.3233/FAIA230655.
- [11] Li, B., Xiao, H., & Tang, L. (2024). *ASAM: Boosting Segment Anything Model with adversarial tuning*, <https://segment-anything.com/>.

- [12] F. Pourpanah et al., "A Review of Generalized Zero-Shot Learning Methods," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 45, no. 4, pp. 4051-4070, 1 April 2023.
- [13] Alice Stanboli, & Kiri Wagstaff. (2017). Mars surface image (Curiosity rover) labeled data set (1.0.0) [Data set]. Zenodo.
- [14] Q. Li, S. Dong, D. Zhang and X. Wang, "Research on the Lidar-based Recognition and Location Method for Depalletizing Targets" 2020 Chinese Automation Congress (CAC), Shanghai, China, 2020, pp. 683-687.

Anexos

Índice de figuras


Figura 1.1 Llanta de Rover y sus daños a lo largo del tiempo	10
Figura 2.1 Fotografía de Marte, clasificación de imágenes según su contenido	11
Figura 2.2 Fotografías de Marte, conjunto de datos 2.2a escenas con obstáculos, 2.2b escenas sin obstáculos.	12
Figura 2.3 Fotografías de Marte, A imagen de entrada en un modelo de disparo cero, B imagen de salida en un modelo de disparo cero.	12
Figura 2.4 Fotografías de Marte, conjunto de datos y sus anotaciones para realizar segmentación semántica, los objetos de interés son rocas y fueron identificadas mediante la herramienta web Open Data Annotation.	13
Figura 2.5 Sistemas LIDAR, adquisición de datos bidimensionales. 2.5a Primera versión del prototipo durante las pruebas con el sensor LIDAR como único elemento del sistema de visión. 2.5b Visualización de nube de puntos 2D utilizando la herramienta ARviz de ROS.	14
Figura 2.6 Arquitectura Hydranet, donde Z es la capa de representación. El modelo $k+2$ corresponde con los resultados potenciales del modelo $k+1$, $Q(k, \cdot)$ y $G(\cdot)$ la puntuación generalizada estimada.	16
Figura 2.7 Sojourner Rover y su sistema de locomoción Rocker-Bogie.	16
Figura 2.8 Sistemas de locomoción, configuración Rocker-Bogie.	17
Figura 2.9 Sistemas de locomoción, vehículos de cuatro ruedas con tracción solo en uno de sus ejes.	18
Figura 3.1 Rover Perseverance, misión en Marte activa desde 2021.	19
Figura 3.2 Vehículos robóticos exploradores de software modular unificado.	20
Figura 3.3 Prototipo DuAxel para el descenso sobre un plano inclinado.	21
Figura 3.4 Prototipo Lemur, exploración sobre pendientes de 90 grados.	21
Figura 4.1 Diseño mecánico, vista inferior del prototipo AI-ROVER-01.	22
Figura 4.2 Diseño mecánico, vista lateral reducida del prototipo AI-ROVER-01.	23
Figura 4.3 Diseño mecánico, Diagrama de fuerzas.	23
Figura 4.4 Diseño eléctrico, distribución de cargas instaladas y cambios de voltaje.	25
Figura 4.5 Diagrama de circuito, tarjeta 1 optoacopladores.	26
Figura 4.6 Diagrama de circuito, tarjeta 2 optoacoplador y relevador.	26


<i>Figura 4.7 Diagrama de operación en computadoras de abordo, el vector A representa las tareas que pueden ser ejecutadas en la computadora principal y el vector B los valores que son calculados en la computadora secundaria según los datos de entrada recibidos.</i>	<i>28</i>
<i>Figura 4.8 Software de visión, Seguimiento de objetos en escena.</i>	<i>29</i>
<i>Figura 4.9 Software de visión, resultados del algoritmo Sort en el seguimiento de objetos (Simple online and realtime tracking with a deep association metric, Bewley [9]).</i>	<i>29</i>
<i>Figura 5.1 Resultados en simulador, uso de herramientas computacionales en el desarrollo del prototipo.</i>	<i>32</i>
<i>Figura 5.2 Resultados de pendiente, determinados utilizando el sensor LSM6DSL.</i>	<i>32</i>
<i>Figura 5.3 Resultados de la construcción de campo de pruebas.</i>	<i>32</i>
<i>Figura 5.4 Prototipo INAOE-AI-ROVER-01.</i>	<i>33</i>
<i>Figura 5.5 Análisis de vibraciones en computadora principal, A vibración máxima detectada al encender el motor de combustión interna, B vibración máxima detectada con el motor de combustión en marcha bajo aceleración.</i>	<i>34</i>
<i>Figura 5.6 Resultados de mejoras para reducir la vibración, A con plataforma fija B con amortiguadores de caucho.</i>	<i>35</i>
<i>Figura 5.7 A Diseño, B manufactura y C pruebas del mecanismo de descenso.</i>	<i>35</i>
<i>Figura 5.8 Caracterización del mecanismo, niveles de tensión y corriente.</i>	<i>36</i>
<i>Figura 5.9 Caracterización del mecanismo, grafica de fuerza</i>	<i>36</i>
<i>Figura 5.10 Caracterización del mecanismo, grafica de fuerza en relación con el amperaje requerido.</i>	<i>36</i>
<i>Figura 5.11 Ejemplos de imágenes utilizadas para entrenamiento de la RNA.</i>	<i>37</i>
<i>Figura 5.12 Graficas de perdida durante entrenamiento y validación del grupo A.</i>	<i>38</i>
<i>Figura 5.13 Comparación de imágenes segmentadas de forma manual vs resultados de la segmentación por un modelo de RNA grupo A.</i>	<i>38</i>
<i>Figura 5.14 Graficas de perdida durante entrenamiento y validación del grupo B.</i>	<i>38</i>
<i>Figura 5.15 Comparación de imágenes segmentadas de forma manual vs resultados de la segmentación por un modelo de RNA grupo B.</i>	<i>38</i>
<i>Figura 5.16 Graficas de perdida durante entrenamiento y validación del grupo C.</i>	<i>39</i>
<i>Figura 5.17 Comparación de imágenes segmentadas de forma manual vs resultados de la segmentación por un modelo de RNA grupo C.</i>	<i>30</i>
<i>Figura 5.18 Seguimiento de objetos utilizando el modelo entrenado con datos del grupo C.</i>	<i>40</i>
<i>Figura 5.19 Imágenes de entrada, campo de pruebas en diferentes horarios.</i>	<i>40</i>

Índice de tablas


<i>Tabla 4.1 Requerimientos eléctricos, componentes electrónicos y su consumo energético.</i>	<i>25</i>
<i>Tabla 5.1 Actividades programadas para la construcción del Rover.</i>	<i>33</i>
<i>Tabla 5.2 Caracterización del mecanismo de descenso durante operación con diferentes niveles de tensión.</i>	<i>36</i>
<i>Tabla 5.3 Distribución de imágenes para el entrenamiento de RNA.</i>	<i>37</i>
<i>Tabla 5.4 Hiperparámetros en el entrenamiento de modelos de RNA</i>	<i>37</i>
<i>Tabla 5.5 Comparación de los resultados de detección de objetos en diferentes horarios.</i>	<i>40</i>


Planos mecánicos






Instituto Nacional de Astrofísica Óptica y Electrónica

COLABORADORES		FECHA	Proyecto :
DIBUJ.	Ing. Emmanuel León Soto	5 de mayo del 2024	
DIRECT.	Dr. Leopoldo Altamirano R.	Escala 1:13	Subsistema de descenso en cráteres para Rovers planetarios
		Número piezas: 106	
		Número mecanismos: 4	
		MATERIALES: Chasis de tubo de hierro fundido, aluminio mecanizado, filamento ABS impresión 3D.	N.º DE DIBUJO
			Prototipo INAOE-AI-RÓVER-01
			






Instituto Nacional de Astrofísica Óptica y Electrónica

COLABORADORES		FECHA	Proyecto :
DIBUJ.	Ing. Emmanuel León Soto	5 de mayo del 2024	
DIRECT.	Dr. Leopoldo Altamirano R.	Escala 1:2	
		Número piezas: 1	N° DE DIBUJO
		Número mecanismos: 0	
		MATERIALES: Filamento ABS impresión 3D.	Soporte Lidar






Instituto Nacional de Astrofísica Óptica y Electrónica

COLABORADORES		FECHA	Proyecto :
DIBUJ.	Ing. Emmanuel León Soto	5 de mayo del 2024	
DIRECT.	Dr. Leopoldo Altamirano R.	Escala 1:2	
		Número piezas: 1	
		Número mecanismos: 0	
		MATERIALES: Filamento ABS impresión 3D.	N.º DE DIBUJO
			Soporte Lidar 2





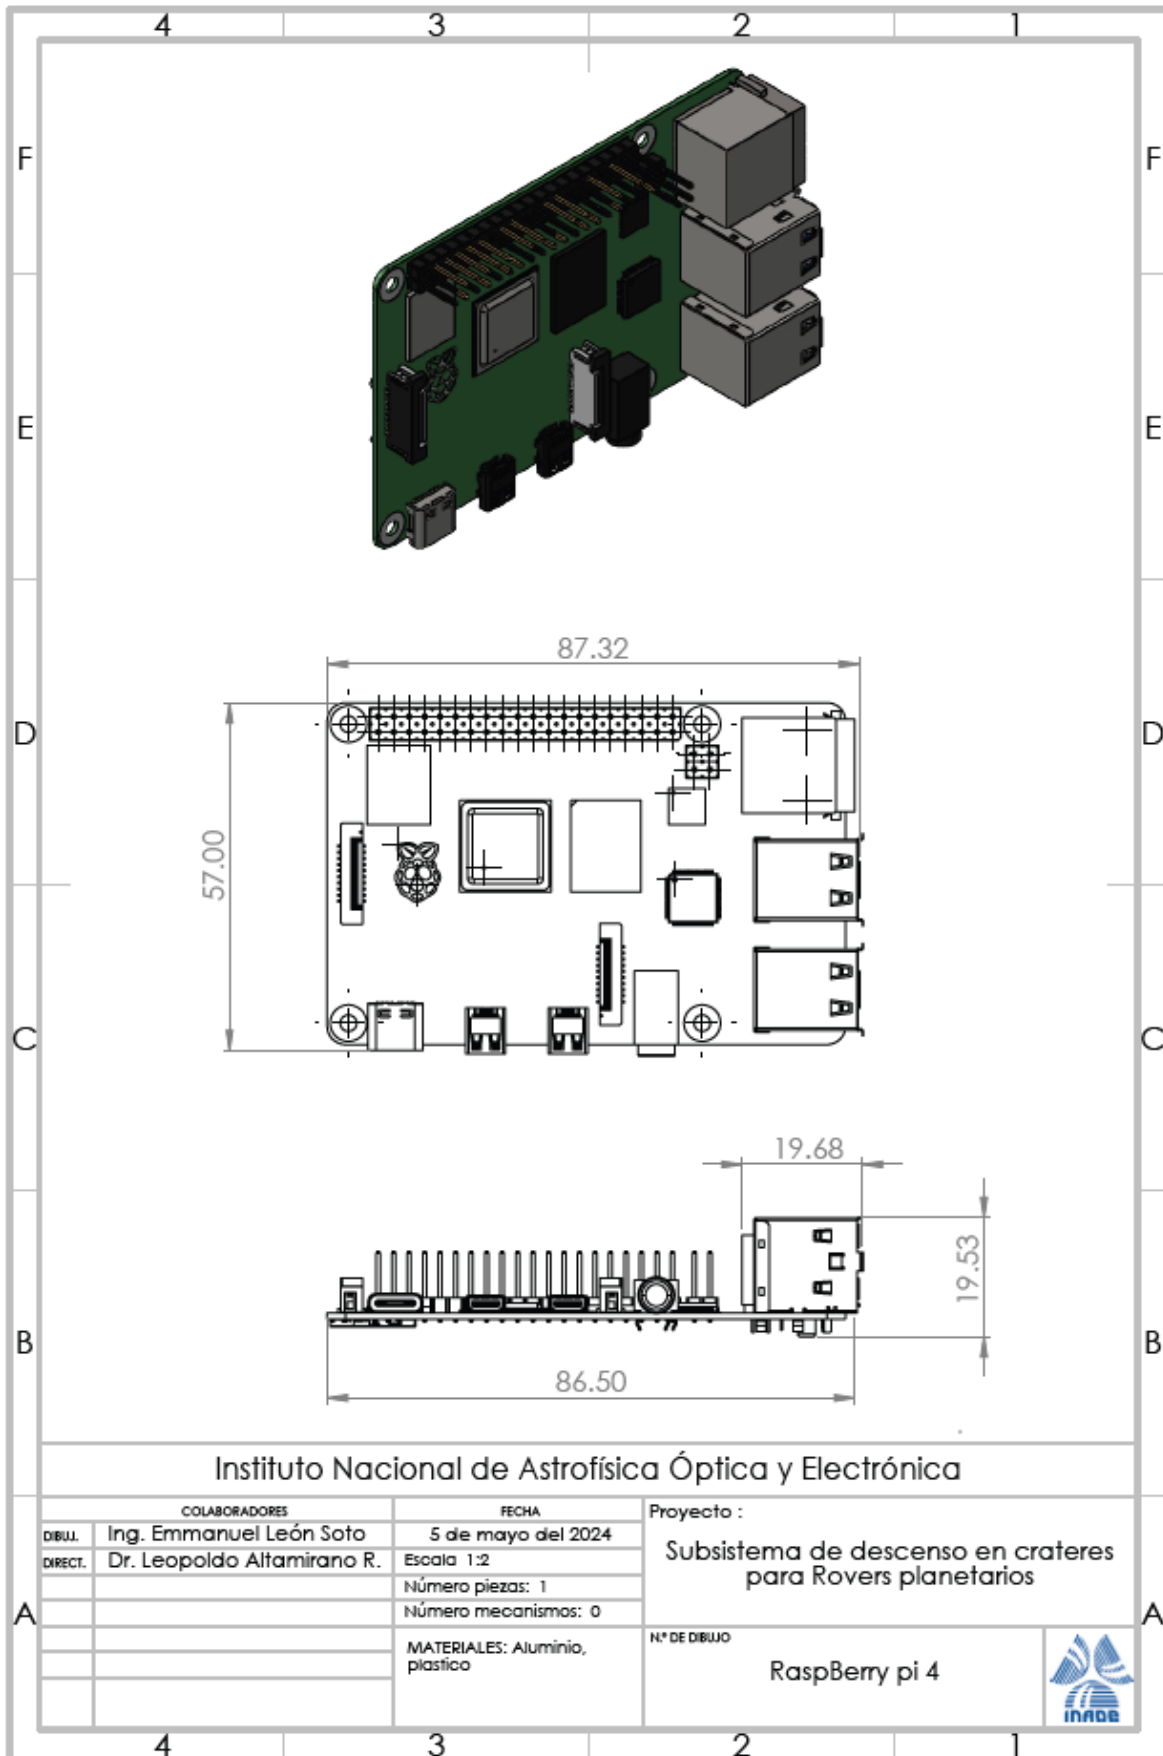
Instituto Nacional de Astrofísica Óptica y Electrónica


COLABORADORES		FECHA
DIBUJ.	Ing. Emmanuel León Soto	5 de mayo del 2024
DIRECT.	Dr. Leopoldo Altamirano R.	Escala 1:2
		Número piezas: 1
		Número mecanismos: 0
		MATERIALES: Aluminio, plástico


Proyecto :
Subsistema de descenso en cráteres
para Rovers planetarios


N° DE DIBUJO
NVIDIA JETSON XAVIER











Instituto Nacional de Astrofísica Óptica y Electrónica

COLABORADORES		FECHA	Proyecto :
DIBUJ.	Ing. Emmanuel León Soto	5 de mayo del 2024	
DIRECT.	Dr. Leopoldo Altamirano R.	Escala 1:4, 1:2	
		Número piezas: 7	
		Número mecanismos: 1	
		MATERIALES: Aluminio Mecanizado, tubo de hierro fundido.	N° DE DIBUJO
			Elementos del mecanismo de dirección



