

*DIFU*_{100ci@}, Revista de Difusión Científica

Ingeniería y Tecnologías

Vol: 19

Num: 1

Publicación: Enero - Diciembre 2025

ISSN: 2007-3585



Una publicación de la Universidad Autónoma de Zacatecas "Francisco García Salinas"

Directorio

Universidad Autónoma de Zacatecas “Francisco García Salinas”

Dr. Rubén de Jesús Ibarra Reyes, *Rector*

Dr. Ángel Román Gutiérrez, *Secretario General*

M.C. Hans Hiram Pacheco García, *Secretario Académico*

Dr. Carlos Francisco Bautista Capetillo, *Coord. Investigación y Posgrado*

Editor en Jefe

Víktor Iván Rodríguez Abdalá, *Universidad Autónoma de Zacatecas, (México)*

Editores Asociados

Manuel Hernández Calviño, *Universidad de La Habana, (Cuba)*

José Ricardo Gómez Rodríguez, *Universidad Autónoma de Zacatecas, (México)*

Grupo Revisor

Remberto Sandoval Aréchiga, *Universidad Autónoma de Zacatecas, (México)*

Salvador Ibarra Delgado, *Universidad Autónoma de Zacatecas, (México)*

Rodrigo Daniel Méndez Ramírez, *Centro de Investigación Científica y de Educación Superior de Ensenada, (México)*

Leonardo Acho Zuppa, *Universidad Politécnica de Catalunya, (España)*

Miguel Andrés, *Universidad de Valencia, (España)*

Germán Díaz Flores, *Universidad Autónoma de Zacatecas, (México)*

Ramón Parra Michel, *Centro de Investigación y de Estudios Avanzados del IPN, (México)*

Leonel Soriano Equigua, *Universidad de Colima, (México)*

José Luis Álvarez Flores, *Universidad de Colima, (México)*

Fermín Marcelo Rubén Maciel Barbosa, *Universidad de Colima, (México)*

Francisco Rubén Castillo Soria, *Universidad Autónoma de San Luis Potosí, (México)*

Cristian Eduardo Boyain y Goytia Luna, *Universidad Autónoma de Zacatecas, (México)*

Juan Pablo Morales Álvarez, *Instituto Tecnológico de La Paz, (México)*

Daniel Armando Hirles Valles, *Instituto Tecnológico de La Paz, (México)*

Jaime Sánchez García, *Centro de Investigación Científica y de Educación Superior de Ensenada, (México)*

Héctor Alonso Guerrero Osuna, *Universidad Autónoma de Zacatecas, (México)*

Ernesto Iván Sandoval García, *Universidad Autónoma de Zacatecas, (México)*

Fabián García Vázquez, *Universidad Autónoma de Zacatecas, (México)*

Jesús Antonio Nava Pintor, *Universidad Autónoma de Zacatecas, (México)*

Derechos reservados

Editorial

Universidad Autónoma de Zacatecas
“Francisco García Salinas”

Diseño de revista

Víktor Iván Rodríguez Abdalá
José Ricardo Gómez Rodríguez

Derechos Reservados

Universidad Autónoma de Zacatecas
“Francisco García Salinas”

ISSN 2007-3585

DIFU100ci@ (léase difuciencia) es una publicación anual editada por la Universidad Autónoma de Zacatecas, “Francisco García Salinas”, a través de la Unidad Académica de Ingeniería Eléctrica. Jardín Juárez No. 147, Colonia Centro, Zacatecas, Zacatecas, C.P. 98000. Tel. (01 492) 925 6690.

ISSN: 2007-3585 otorgado por el Instituto Nacional de Derecho de Autor.

Las opiniones expresadas por los autores no necesariamente reflejan la postura del editor de la publicación. Queda estrictamente prohibida la reproducción total o parcial de los contenidos e imágenes de la publicación sin previa autorización de la Universidad Autónoma de Zacatecas “Francisco García Salinas” a través de la Unidad Académica de Ingeniería Eléctrica.

<http://www.uaz.edu.mx>

<http://difu100cia.uaz.edu.mx>

difu100cia@uaz.edu.mx

Carta del editor

Sirva la presente para informar una modificación sustancial en el modelo de publicación de Difu100ci@, la cual entrará en vigor a partir del presente año. Esta decisión responde al compromiso de la revista con la mejora continua, la adecuación a los ritmos institucionales y la promoción eficiente de la producción científica en el campo de la ingeniería y las tecnologías.

Con base en lo anterior, Difu100ci@ publicará sus artículos bajo la modalidad de volumen único anual con publicación continua, permitiendo la incorporación inmediata de los trabajos aprobados una vez concluido su proceso editorial.

El objetivo principal de este esquema es brindar una alternativa dinámica que responda a los tiempos de trabajo de las distintas universidades, centros de investigación y colaboradores, facilitando a las y los autores una vía más ágil para la difusión de sus resultados académicos.

Este nuevo formato no implica cambios en la rigurosidad del proceso editorial ni en la política de dictaminación por pares. Por el contrario, representa una mejora sustantiva en la visibilidad de los contenidos, reduce los periodos de espera entre aceptación y publicación, y se alinea con las mejores prácticas internacionales en materia de divulgación científica.

La revista mantendrá su compromiso con la calidad, la transparencia y el servicio a la comunidad científica, propiciando que la investigación se mantenga al alcance de quienes la generan, la consultan y la aplican.

Reiteramos nuestro agradecimiento por la confianza depositada en Difu100ci@ y les extendemos la más cordial invitación a continuar enviando sus contribuciones, participar como evaluadores y promover el uso de este espacio editorial entre sus redes académicas.



Víctor Iván Rodríguez Abdalá
Editor en Jefe

Índice general

Directorio	I
Derechos reservados	II
Carta del editor	III
1. Desarrollo de una aplicación computacional para visualizar y analizar datos del tratamiento con insulina en un adolescente con Diabetes Mellitus Tipo 1	1
2. Desarrollo de un prototipo de geolocalización y procesamiento estadístico en tiempo real para la detección de impactos y volcaduras en automóviles	10
3. Sistema para la obtención y guardado de señales ECG mediante el uso de una tarjeta Raspberry PI	18
4. Análisis Dinámico del Dolor y Predicción de la Cronificación mediante Señales Fisiológicas	24
5. Clasificación de variedades de planta de pitayo usando imágenes multiespectrales	33
6. Estimation of the CARI Vegetation Index from Spectral Signatures of Stenocereus spp. in Southern Zacatecas	42
7. Exploring the Optimal Battery Sizing in Grid-Connected PV Systems: A Comparative Study of PSO and GA in Oax Mx	49
8. Análisis de la antena log-periódica LP0965 para aplicaciones de radar	58
9. Desarrollo de una biblioteca basada en comandos AT para el módulo LoRa RN2903 de Microchip	65

Development of a computational application for visualizing and analyzing insulin treatment data in an adolescent with Type 1 Diabetes Mellitus

Desarrollo de una aplicación computacional para visualizar y analizar datos del tratamiento con insulina en un adolescente con Diabetes Mellitus Tipo 1

J.A. García-Rodríguez *, Jorge I. Cuevas-Chávez ¹, Roberto Carlos Diaz Velazco ¹, Sofía Mireles-S. ¹, G.Y. Cortés-Solares ¹, and Cynthia Mejía ¹

¹ Tecnológico Nacional de México/Instituto Tecnológico de Ciudad Guzmán,
División de Estudios de Posgrado e Investigación,
Av. Tecnológico 100, Ciudad Guzmán, Municipio de Zapotlán el Grande, Jalisco, México, CP. 49100
{julio.gr, M22290910, M22290912, M22290908, M22290907, M22290909}@cdguzman.tecnm.mx

Abstract

In this manuscript, a computational application is developed to analyze the effect of *Lispro* and *Glargine* insulins in an adolescent living with T1DM, who used a FreeStyle[®] sensor over a 14-day monitoring period. The action of both insulins is estimated using pharmacokinetic profiles based on their respective dynamic mathematical models. The results revealed prolonged hyperglycemic episodes and potential inefficiencies in medication. The application aims to be a strategic computational tool for medical professionals in making decisions regarding diabetes management.

Keywords— Type 1 Diabetes Mellitus (T1DM), FreeStyle[®] sensor, *Lispro* insulin, *Glargine* insulin

Resumen

En este manuscrito se desarrolla una aplicación para analizar el efecto de las insulinas *Lispro* y *Glargina* en un adolescente que vive con DMT1 y usó un sensor FreeStyle[®] durante 14 días de experimentación. La acción de ambas insulinas se estima por la programación del perfil farmacocinético a través de su respectivo modelo matemático dinámico. En los resultados se identificaron episodios prolongados de hiperglucemia y posibles ineficiencias en la medicación. Esta aplicación pretende ser una herramienta computacional estratégica para los médicos especialistas en la toma de decisiones sobre el tratamiento de DMT1.

Palabras clave— Diabetes Mellitus Tipo 1 (DMT1), Sensor FreeStyle[®], Insulina *Lispro*, Insulina *Glargina*

I. Introducción

La glucosa es una variedad de azúcar transportada a través de la sangre y sirve como energía para que las células realicen sus funciones biológicas normales. La glucosa es un carbohidrato simple que se encuentra naturalmente en muchas cosas que comemos. Además, el cuerpo humano puede producir glucosa descomponiendo

otros carbohidratos más complejos. El cerebro, los tejidos y los órganos del cuerpo dependen de esta sustancia como su principal fuente de energía. Sin embargo, los tejidos no pueden retener naturalmente la glucosa del torrente sanguíneo. Aquí funciona la hormona insulina que se produce en el páncreas, permitiendo que la glucosa entre en los tejidos y se utilice como energía. Este proceso biológico es extremadamente complejo. Por lo tanto, la insulina es fundamental para el control de la glucosa y

* Autor de correspondencia

el consumo humano [1].

La Diabetes Mellitus (DM) es un padecimiento que se distingue por presentar niveles de glucosa en sangre crónicamente elevados, teniendo como síntoma principal la orina abundante, sed excesiva, pérdida de peso, entre otros. En esta enfermedad existe una deficiencia relativa o absoluta de secreción de insulina pancreática agotando los recursos para controlar el nivel de azúcar en sangre. Hay dos tipos principales de DM, la tipo 1 (DMT1) y la tipo 2 (DMT2). La DMT1 sucede porque el sistema inmunitario ataca y destruye la célula productora de insulina en los islotes de Langerhans del páncreas (déficit absoluto). En DMT2 el cuerpo no utiliza la insulina adecuadamente. Puede aparecer por causas relacionadas a la obesidad, estilo de vida sedentario o carga genética [2]. La DM es un grave problema de salud pública ya que conlleva a complicaciones de corto y largo plazo. La falta absoluta de insulina puede conducir a una situación de cetoacidosis diabética o a un coma hiperglucémico con una gran tasa de mortalidad. La DM es una de las principales causas de ceguera, insuficiencia renal, ataques cardíacos, accidentes cerebrovasculares y amputación de miembros inferiores. La mortalidad por cardiopatía isquémica es entre 2 y 4 veces superior a la de las personas no diabéticas [3].

Un análogo de insulina tiene el propósito de emular la función regulatoria que la insulina humana desempeña. La administración de un análogo de insulina se realiza típicamente mediante inyecciones subcutáneas. Estas dosis son administradas antes de las ingestas de comidas para absorber la glucosa circulante en el torrente sanguíneo y regular los niveles después de la comida [4]. Existen dos tipos principales de insulina utilizada en el tratamiento de DM: la insulina de acción rápida y la insulina de acción prolongada [5], [6]. En los últimos años se han desarrollado insulinas de acción lenta mejoradas como la insulina *Glargina* que tiene un pico de acción de aproximadamente 4 a 7 horas y una duración total de 16 a 22 horas después de la administración [7], [8]. La insulina *Lispro* es uno de los análogos más comúnmente usados para obtener una acción rápida. Suele inyectarse entre 20 y 30 minutos antes de la comida y su acción máxima ocurre entre 1 y 2 horas después de la inyección [9]. Las dosis de insulina son prescritas por el médico basándose en el peso corporal del paciente y generalmente oscila entre 0.4 y 1.0 unidades por kilogramo. La combinación suele ser del 50 % de insulina de acción rápida y el 50 % de insulina de acción prolongada [10]. Las insulinas *Glargina* y *Lispro* pueden administrarse individualmente o combinadas para imitar el aumento natural de la insulina pancreática después de comer y mantener una concentración basal constante.

En este trabajo se desarrolla una aplicación utilizando

Matlab® App Designer para la visualización de seis variables cruciales en el control de la glucemia. Estas variables se basan en datos experimentales recopilados de un adolescente real de 15 años de edad, que vive con DMT1. Se obtuvo el consentimiento informado por escrito tanto de los padres como del propio adolescente para utilizar un sensor de glucosa FreeStyle® durante un periodo de 14 días. El equipo de investigación registró información detallada, incluyendo todas las comidas con sus respectivos horarios, el tipo de insulina administrada (*Lispro* o *Glargina*), la cantidad de insulina, los horarios de las inyecciones y los síntomas generales, a lo largo del experimento. La aplicación computacional extrae esta información de una base de datos creada y genera gráficos representativos de las variables esenciales para el día seleccionado por el usuario. Las variables que se muestran incluyen el nivel de glucosa, la ingesta de carbohidratos, las unidades de insulina *Glargina* y *Lispro*, así como la acción de ambas insulinas. Tal acción se estima por la programación del perfil farmacocinético a través de su respectivo modelo matemático dinámico, desarrollados a detalle en la sección III. El objetivo principal de esta interfaz gráfica es proporcionar una herramienta útil para las personas que viven con DMT1. Además, se busca brindar un respaldo confiable a los médicos especialistas en DMT1, permitiéndoles tomar decisiones más informadas sobre el ajuste de la medicación y la gestión del tratamiento mediante un análisis preciso del comportamiento glucémico facilitado por esta interfaz.

II. Estado del arte

Es un hecho que el tratamiento de la DMT1 ha avanzado significativamente mediante el uso de tecnologías digitales como sensores de monitoreo continuo de glucosa (MCG), aplicaciones móviles y herramientas basadas en inteligencia artificial. Aún así, los pacientes y médicos continúan enfrentando desafíos para integrar y visualizar múltiples fuentes de información clínica como niveles de glucosa, dosis de insulina e ingesta de carbohidratos de manera clara y útil para la toma de decisiones terapéuticas.

Durante las últimas décadas, se han desarrollado modelos matemáticos precisos que representan el comportamiento dinámico del sistema glucosa-insulina. Destacan los modelos propuestos por Dalla Man *et al.* [11] para simular la absorción gastrointestinal de carbohidratos y la respuesta a la insulina del cuerpo humano [12]. Así como el modelo compartimental para la absorción subcutánea de insulina *Glargina* desarrollado por Schiavon *et al.* [13]. Estos modelos han servido como base para simulaciones fisiológicas y para el diseño de algoritmos en el ámbito clínico y experimental.

La comunidad científica ha comenzado a explorar el desarrollo de herramientas computacionales con capacidad predictiva, empleando algoritmos de aprendizaje automático como clasificadores RF (del inglés: *Random Forest*), máquinas de soporte de vectores (SVR, del inglés: *Support Vector Machine*) o redes neuronales artificiales (ANN, del inglés: *Artificial Neural Network*) con el fin de anticipar episodios de hipoglucemia o hiperglucemia [14], [15], [16]. Estas iniciativas suelen apoyarse en datos simulados o en bases de datos clínicos históricos y buscan generar sistemas personalizados de apoyo a decisiones médicas. Aunque muchos de estos desarrollos se encuentran en fases de prueba o validación, representan un paso importante hacia soluciones predictivas aplicables en entornos reales. No obstante, pocas propuestas han logrado integrar en una misma plataforma visualización de datos reales, modelos dinámicos de absorción de insulina y registros detallados de ingesta alimenticia. Esta integración resulta crucial para contextualizar los niveles de glucosa en función del tratamiento administrado y los hábitos alimenticios diarios de los pacientes DMT1.

III. Materiales y métodos

En esta sección se describen a detalle los materiales y métodos que conforman esta propuesta.

III.1. Monitoreo continuo de glucosa (MCG)

Uno de los principales objetivos de investigación en DM ha sido el de proporcionar monitorización continua de la glucosa para que la terapia con insulina se mantenga en niveles normales la mayor cantidad de tiempo posible. Los sensores de glucosa pueden colocarse por vía subcutánea hasta 14 días y se comunican de forma inalámbrica con dispositivos inteligentes como los smartphones [17]. El sensor de glucosa FreeStyle® contiene un transmisor y generalmente se inserta mediante un aplicador en la parte posterior y superficial del brazo. El sensor FreeStyle® y el aplicador pueden verse en la Figura 1. La cánula que se inserta mide 0.4 milímetros de ancho y 5 milímetros de largo. El sensor se comunica de forma inalámbrica con el medidor y la calibración es automática. Las lecturas de glucosa se obtienen sosteniendo el medidor a 4 centímetros del sensor o mediante una aplicación en un teléfono móvil. Los datos se pueden descargar a una computadora [18]. En el diagrama de la Figura 2 se muestra cómo el sensor de glucosa queda pegado en la piel y la cánula es capaz de llegar al fluido intersticial para medir la cantidad de glucosa proveniente del torrente sanguíneo.



Figura 1: Fotografía del Sensor FreeStyle® dentro del aplicador.




Figura 2: Diagrama del sensor de glucosa sobre el tejido subcutáneo.

III.2. Modelos de absorción subcutánea de insulina

Los modelos de absorción subcutánea de insulina de acción prolongada (del inglés: *Long Acting*) y de acción rápida (del inglés: *Short Acting*) fueron obtenidos de los trabajos Michele Schiavon *et al.* en [6] y [13], respectivamente. Estos estudios detallan los modelos de cada tipo de insulina y explican cómo son aplicables a personas que usan insulina.

III.3. Acción rápida

La insulina de acción rápida se utiliza para regular los niveles de glucosa en sangre justo después de las comidas. Ésta se absorbe de manera rápida en el tejido subcutáneo y su perfil de absorción se representa mediante el gráfico por compartimentos de la Figura 3. El modelo describe cómo se absorbe la insulina rápida en el cuerpo después de una inyección subcutánea. El trabajo de Michele Schiavon *et al.* [13] argumenta que en su modelo incluye un retraso de promedio de 7.6 minutos antes de que la insulina comience a distribuirse. Una parte de la insulina pasa directamente al plasma y otra parte va a un segundo compartimento antes de llegar al plasma. Este enfoque logró representar con precisión cómo varía la insulina en la sangre tras la inyección.




Figura 3: Modelo de absorción de insulina de acción rápida.

III.4. Acción prolongada

La insulina de acción prolongada es un tipo de insulina diseñada específicamente para liberarse de manera más lenta hacia el torrente sanguíneo. Ayuda a regular la glucosa durante las comidas del día y el periodo nocturno. El modelo de insulina de acción prolongada publicado por Michele Schiavon *et al.* en [6] es lineal y consta de dos compartimentos. Este modelo matemático representa cómo la insulina glargina en sus formulaciones Gla-100 y Gla-300 se disuelve primero en el sitio de inyección y luego se distribuye entre dos compartimentos antes de llegar al plasma. El modelo se representa en la Figura 4 donde se pueden ver las etapas representadas por ecuaciones matemáticas.

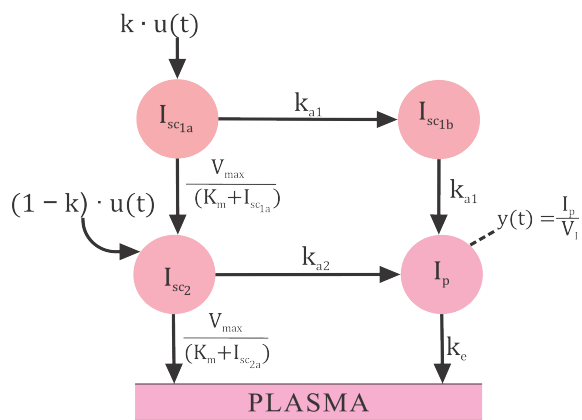


Figura 4: Modelo de absorción de insulina de acción prolongada.

IV. Resultados

La obtención de datos de un sensor de glucosa Freestyle® puede realizarse mediante la aplicación

Freestyle Libre o a través de la plataforma LibreView de Abbott® exclusiva para usuarios de sensores.

IV.1. Monitoreo continuo de glucosa en un adolescente con DMT1

El grupo de investigación que desarrolla el presente artículo obtuvo el consentimiento informado por escrito tanto de los padres como del propio adolescente para utilizar un sensor de glucosa FreeStyle® durante un periodo de 14 días. Se coloca el sensor en la parte trasera del brazo izquierdo del adolescente que vive con DMT1, como se presenta en la Figura 5.



Figura 5: Colocación del sensor Freestyle® en el brazo izquierdo del adolescente DMT1.

El sensor se calibrará dentro de los primeros 60 minutos de manera automática. Después estará listo para monitorear el nivel de glucosa en el fluido intersticial del adolescente. El monitoreo continuo de glucosa se lleva a cabo durante los próximos 14 días y los datos se suben automáticamente a la plataforma LibreView con almacenamiento en la nube. Los datos están disponibles para descargar en formato .csv.

IV.2. Conteo de carbohidratos

Una persona que vive con DM debe seguir un plan de alimentación equilibrado y personalizado. Su estilo de vida y cuidados médicos son extremadamente importantes para mantenerse dentro de un régimen de control. Es crucial cuantificar la ingesta de alimentos, en especial la de los carbohidratos. Todo esto, en conjunto con la actividad física diaria puede ayudar a controlar los niveles de glucosa en la sangre, optimiza la sensibilidad a la insulina y mejora el control de la diabetes, manteniendo un peso saludable. El adolescente

elaboró un registro manual de todos los alimentos consumidos durante los días de experimentación. El Sistema Mexicano de Alimentos Equivalentes (SMAE) es una guía que agrupa los alimentos que contienen carbohidratos, proteínas o grasas. Sirve para ayudar a las personas, especialmente con diabetes, a planear sus comidas [19]. En el conteo de carbohidratos, el SMAE indica cuánta cantidad de un alimento contiene más o menos 15 gramos de carbohidratos. De esta manera, se hace el conteo de carbohidratos por comida y por día usando la guía SMAE. Como resultado se obtiene una base de datos que contiene todos los alimentos consumidos y la cantidad de carbohidratos correspondiente en los 14 días de experimentación. Para este manuscrito, solamente se presentan los datos de dos días que corresponden al 20 de Diciembre de 2023 y 24 de Diciembre de 2023 en las Tablas 1 y 2, respectivamente. Se seleccionaron estos días por evidenciar con mayor claridad la interacción entre glucosa, insulina y carbohidratos en comparación con los demás.

Tabla 1: *Conteo de carbohidratos. Día 20 de Diciembre de 2023.*

Día 1	Alimentos	Carbohidratos (gramos)
Desayuno	2 Molletes de frijoles con queso, 1 taza de papaya y calabacitas.	56.3
Comida	1 Porción de carne asada con chorizo, 1 taza de frijoles y 2 tortillas de maíz.	53.6
Cena	1 Taza de cereal y 1 taza de leche.	61.0
Consumo Total		170.9

Tabla 2: *Conteo de carbohidratos. Día 24 de Diciembre de 2023.*

Día 2	Alimentos	Carbohidratos (gramos)
Desayuno	1 Plato de menudo con 2 tortillas.	37.1
Comida	Picadillo con romeritos y 1 tortilla.	23.6
Cena	2 tamales de carne con 1 vaso de atole.	113.0
Consumo Total		173.7

IV.3. Desarrollo de la aplicación y base de datos

Se desarrolló una aplicación con el objetivo de procesar los datos obtenidos por el sensor de glucosa y poder visualizar las mediciones a cada minuto, junto con la acción de las inyecciones de insulina y el consumo de carbohidratos.

Se obtuvieron las mediciones de glucosa del paciente durante un periodo de 14 días, con un tiempo de muestreo de 15 minutos. Para adquirir el nivel de glucosa en cada minuto del día se utilizó el método de interpolación Spline cúbico. A través de esta técnica se pueden construir funciones polinómicas de tercer grado entre cada par de puntos adyacentes, garantizando que dichas funciones sean suaves y continuas en sus primeras y segundas derivadas. De esta manera, se estimaron los valores faltantes para la aproximación de todos los datos consecutivos. Se realizó el procesamiento de datos en Matlab[®], importando los datos obtenidos por el sensor desde excel e interpolándolos con el comando *spline*.

IV.4. Interfaz gráfica

La aplicación se creó en un entorno de desarrollo interactivo llamado Matlab[®] App Designer, el cual está integrado en el editor de este software. Este entorno permite diseñar de manera sencilla interfaces gráficas de usuario y programar el comportamiento funcional de la aplicación en un mismo espacio. Se opta por usar Matlab[®] App Designer debido a su compatibilidad directa con funciones matemáticas y de procesamiento de datos, así como por su eficiencia para integrar visualizaciones interactivas con rutinas de análisis numérico.

Como se puede observar en la Figura 6, se muestra inicialmente la interfaz gráfica. En esta, podemos apreciar, en primera instancia, un selector que despliega los días de monitoreo de glucosa del paciente DMT1. Dentro de la ventana de la Figura 6, están dos subgráficas (superior e inferior) que proporcionan información adicional sobre el comportamiento de la glucosa del paciente. En la superior se hace referencia al comportamiento de la glucosa e ingesta de alimentos. En la inferior se despliega la acción de las insulinas *Lispro* y *Glargina*, así como a las inyecciones de insulina. Ambas subgráficas tienen un doble eje vertical (eje Y), los cuales presentan dos escalas de información útil. Además, el eje horizontal (eje X) representa la hora del día. Cuando se selecciona una fecha específica, como el 20 de diciembre de 2022, se despliegan en los rectángulos las curvas de información, tal como se muestra en la Figura 7. En la subgráfica superior, se despliega el nivel de glucosa en (mg/dL) en color rosa y cómo cambia su comportamiento a lo largo de las horas del día. También se puede observar en color rojo la ingesta de carbohidratos (CH) que el paciente consumió en una hora específica. El usuario,

que podría ser un médico, puede interpretar los datos de la siguiente manera: aproximadamente a las 7:30 horas, el paciente ingirió su desayuno con un contenido de carbohidratos de alrededor de 55 gramos de CH, lo cual provocó un ligero incremento en la dinámica de la glucosa (curva rosa) del paciente. En la subgráfica inferior de la Figura 7, se muestran diferentes curvas del comportamiento de las inyecciones de insulina y las dosis aplicadas. En el impulso de color verde, se puede apreciar la inyección de la dosis de insulina *Glargina*. La curva punteada color verde es su acción correspondiente. Es decir, la interfaz calcula la curva de acción de la insulina como volumen en miliunidades por mililitro (mU/ml) usando como dato de entrada $u(t)$ la cantidad inyectada por el paciente. Este cálculo se lleva a cabo por

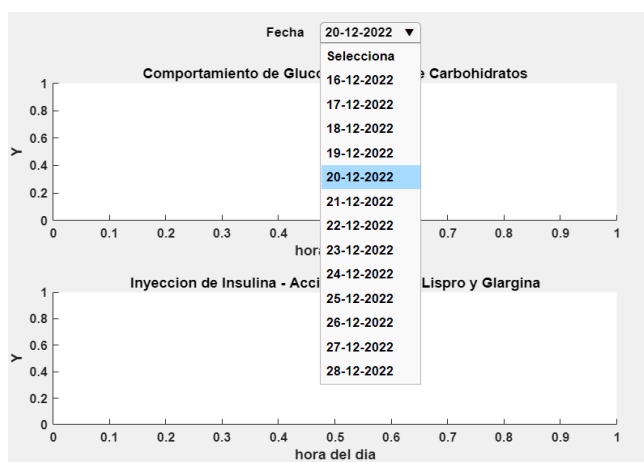


Figura 6: Ventana de la aplicación computacional para seleccionar el día de visualización.

la programación interna de las ecuaciones diferenciales que describen el modelo de absorción prolongada de la Figura 4. Es fácil ver cómo el efecto de la *Glargina* se prolonga a lo largo del día, durante casi 16 horas. Por otro lado, el impulso de color azul muestra las inyecciones de insulina *Lispro*. A diferencia de la *Glargina*, la insulina *Lispro* se aplica varias veces a lo largo del día, normalmente antes de cada comida. La curva punteada azul describe el comportamiento dinámico en volumen de insulina en (mU/ml). De igual forma, por el modelo de absorción rápida de la Figura 3 explicado en la sección 2. Puede observarse fácilmente cómo el efecto dura menos tiempo que la *Glargina*, por este motivo las inyecciones de acción rápida son usadas para compensar la comida y mantener la glucosa controlada. De nuevo, un médico puede interpretar los datos de la siguiente manera: se inyecta la insulina *Glargina* aproximadamente a las 7:15 horas, la concentración de insulina empieza a elevarse lentamente alcanzando el pico máximo a las 13:00 horas. La mínima concentración de *Glargina* es a las 24:00 horas. Respecto a la acción de *Lispro* tiene un máximo a las

8:45 horas y el mínimo a las 13:30 horas. Puede verse claramente cómo la glucosa desciende rápidamente de 175 mg/dL a las 8:45 horas a 70 mg/dL a las 9:50 horas, por la acción de la *Lispro*. Este comportamiento es similar para la comida de las 13:30 horas y la cena de las 20:30 horas. La insulina de acción rápida *Lispro* calculada por la interfaz, describe de manera precisa la compensación en la glucosa real monitoreada continuamente por el sensor. Mientras que la *Glargina* ofrece estabilidad de glucosa con menor impacto durante todo el día.

En la Figura 8 se observa la ventana para el día 24 de diciembre de 2022. Pueden distinguirse 4 comidas, 9:00, 13:00, 17:00 y 20:45 horas. Respecto a las insulinas, el adolescente se inyectó 45 Unidades de *Glargina* a las 8:50 horas, 8 Unidades de *Lispro* a las 8:55 horas, 8 Unidades a las 16:55 horas y 10 Unidades a las 20:40 horas. En este día de experimentación puede verse claramente que la glucosa tuvo periodos prolongados en hiperglucemia, en comparación con la del 20 de diciembre. Es interesante evaluar cómo la dinámica glucémica del 24 de Diciembre tiene pendientes descendentes y ascendentes muy pronunciadas. Los niveles de hiperglucemia alcanzados este día son de riesgo y evidentemente las dosis de insulina no son suficientes para controlar al adolescente. Por lo tanto, la información que proporciona la interfaz que evalúa el efecto de dos tipos de insulina es completamente útil para que el médico especialista sugiera ajustes en la medicación de los diabéticos y de esta manera evitar escenarios de riesgo que puedan conducir a complicaciones más graves.

V. Discusión

La propuesta presentada en este artículo constituye un avance relevante en el desarrollo de herramientas computacionales para la gestión personalizada de la DMT1. A diferencia de las soluciones que se basan sólo en predicción y simulación, la aplicación de este manuscrito se centra en la integración visual de datos reales de un paciente, lo que la convierte en una herramienta interpretativa. Con la referencia de los modelos matemáticos propuestos por Schiavon *et al.* [6], [13] se logró estimar de manera dinámica la acción farmacocinética de las insulinas *Lispro* y *Glargina*. Esta estimación fue representada de forma visual junto con variables esenciales como el nivel de glucosa, la ingesta de carbohidratos y las dosis administradas, lo que facilita el análisis de la respuesta metabólica de una persona que vive con DMT1. La utilidad de esta integración se evidenció en los resultados presentados. Esto es, el día 24 de diciembre, donde se observaron prolongados episodios de hiperglucemia, la visualización permitió identificar rápidamente posibles fallos en la

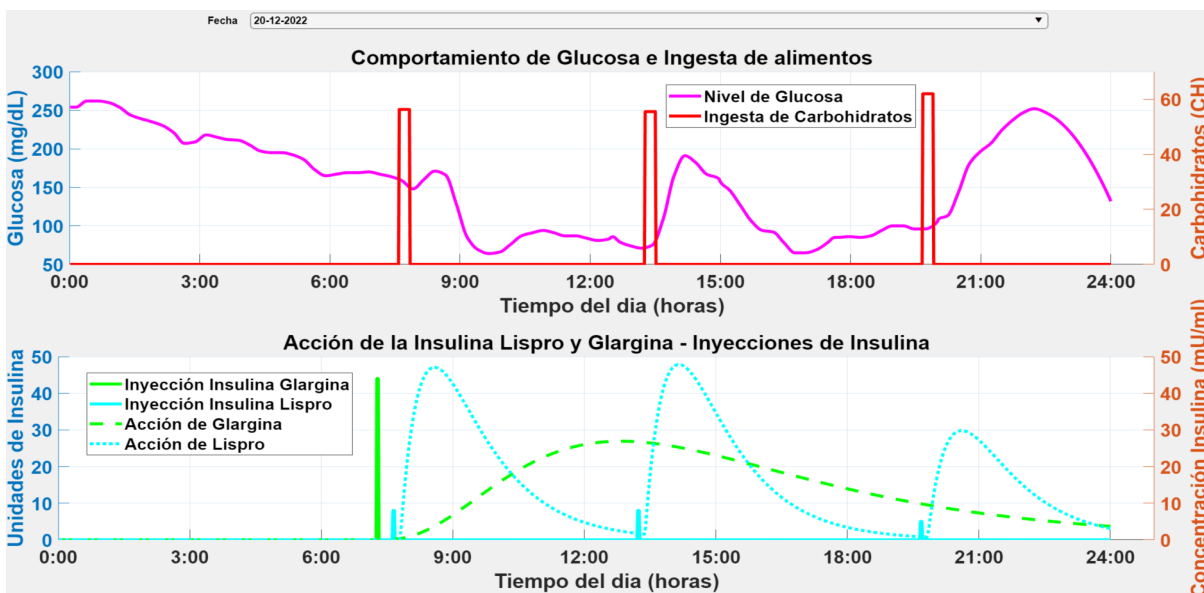


Figura 7: Ventana de la aplicación computacional que describe la dinámica completa de un adolescente DMT1 para el día 20 de diciembre de 2022.

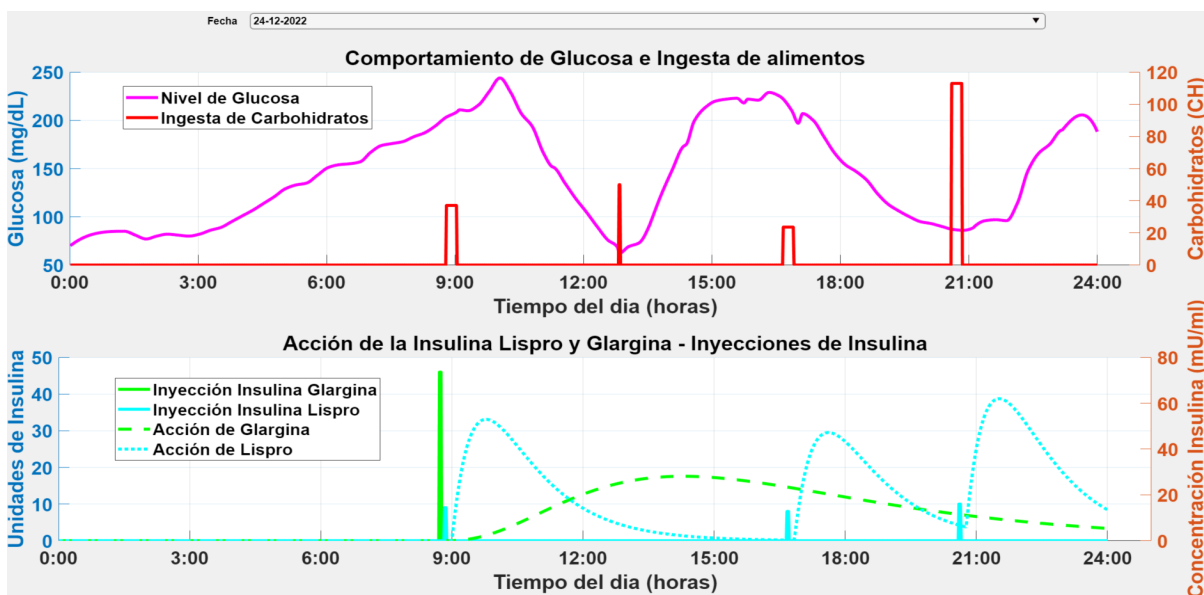


Figura 8: Ventana de la aplicación computacional que describe la dinámica completa de un adolescente DMT1 para el día 24 de diciembre de 2022.

estrategia de tratamiento. Esto es de gran valor para el profesional médico encargado o endocrinólogo. Este tipo de análisis no sería posible sin una representación fisiológica de todos los factores que intervienen en el control glucémico. Desde el punto de vista técnico, el uso de herramientas matemáticas para tratar los datos de glucosa y la implementación de modelos fisiológicos validados ofrece una aproximación interesante para la gestión de la enfermedad. Además, el desarrollo mediante MATLAB® App Designer garantiza una interfaz

robusta, clara y funcional, con enfoque en la usabilidad clínica. Los resultados obtenidos son pertinentes para avanzar hacia desarrollos computacionales enfocados en el análisis personalizado y la representación visual de variables fisiológicas. La propuesta que desarrolla este manuscrito puede fortalecer la toma de decisiones médicas mediante el análisis estructurado de datos reales.

VI. Conclusiones

En el presente artículo se desarrolló una aplicación computacional orientada a la visualización e interpretación de datos de interés en un adolescente que vive con DMT1. A partir de información recolectada mediante un sensor FreeStyle® durante un periodo de 14 días, se integraron distintas etapas de procesamiento, como el análisis de datos de glucosa, el conteo de carbohidratos, la implementación de modelos dinámicos de la acción de la insulina y el diseño de una interfaz gráfica interactiva en MATLAB® App Designer. La herramienta propuesta permite representar de forma conjunta seis variables esenciales para el control glucémico, facilitando una interpretación visual del tratamiento aplicado y del comportamiento metabólico diario del paciente DMT1. El uso de modelos matemáticos fisiológicos validados, junto con datos reales del paciente, permite que la aplicación proporcione información de gran utilidad para el profesional médico, facilitando un análisis estructurado y personalizado del tratamiento. Los trabajos futuros de esta propuesta se orientan hacia plataformas móviles que permitan su implementación en contextos clínicos reales. Asimismo, se plantea incorporar funcionalidades predictivas mediante el uso de algoritmos de aprendizaje automático, así como la posibilidad de adaptar el sistema a otros perfiles de pacientes y a nuevas variables clínicas como actividad física o signos vitales. Estas mejoras podrían fortalecer el valor clínico de la herramienta y su impacto en la toma de decisiones médicas informadas.

Referencias

- [1] Steven E. Kahn, Mark E. Cooper y Stefano Del Prato. «Pathophysiology and treatment of type 2 diabetes: Perspectives on the past, present, and future». English. En: *The Lancet* 383.9922 (2014), págs. 1068-1083. ISSN: 0140-6736. DOI: 10.1016/S0140-6736(13)62154-6.
- [2] Nicole C. Foster et al. «State of type 1 diabetes management and outcomes from the T1D Exchange in 2016-2018». En: *Diabetes Technol. Ther.* 21.2 (2019), págs. 66-72.
- [3] American Diabetes Association. «Introduction: Standards of Medical Care in Diabetes-2020». En: *Diabetes Care* 43.Supplement_1 (dic. de 2019), S1-S2. ISSN: 0149-5992. DOI: 10.2337/dc20-Sint. eprint: https://diabetesjournals.org/care/article-pdf/43/Supplement_1/S1/551683/dc20sint.pdf. URL: <https://doi.org/10.2337/dc20-Sint>.
- [4] Lefever E, Vliebergh J y Mathieu C. «Improving the treatment of patients with diabetes using insulin analogues: current findings and future directions». En: *Expert Opinion on Drug Safety* 20.2 (2021), págs. 155-169.
- [5] Hanne Haahr y Tim Heise. «Fast-acting insulin aspart: a review of its pharmacokinetic and pharmacodynamic properties and the clinical consequences». En: *Clinical Pharmacokinetics* 59 (2020), págs. 155-172.
- [6] Michele Schiavon et al. «Modeling subcutaneous absorption of long-acting insulin glargine in type 1 diabetes». En: *IEEE Transactions on Biomedical Engineering* 67.2 (2019), págs. 624-631.
- [7] Hirsch Irl B. et al. «The evolution of insulin and how it informs therapy and treatment choices». En: *Endocrine reviews* 41.5 (2020), págs. 733-755.
- [8] Owens David R et al. «Clinical relevance of pharmacokinetic and pharmacodynamic profiles of insulin degludec (100, 200 U/mL) and insulin glargine (100, 300 U/mL)—a review of evidence and clinical interpretation». En: *Diabetes & Metabolism* 45.4 (2019), págs. 330-340.
- [9] Dene Simpson et al. «Insulin lispro: a review of its use in the management of diabetes mellitus». En: *Drugs* 67 (2007), págs. 407-434.
- [10] Melo K.F.S. et al. «Short-acting insulin analogues versus regular human insulin on postprandial glucose and hypoglycemia in type 1 diabetes mellitus: a systematic review and meta-analysis». En: *Diabetology & metabolic syndrome* 11.1 (2019), págs. 1-13.
- [11] C. Dalla Man, M. Camilleri y C. Cobelli. «A System Model of Oral Glucose Absorption: Validation on Gold Standard Data». En: *IEEE Transactions on Biomedical Engineering* 53.12 (2006), págs. 2472-2478. DOI: 10.1109/TBME.2006.883792. URL: <https://ieeexplore.ieee.org/document/4015600> (visitado 10-10-2024).
- [12] Chiara Dalla Man, Robert A. Rizza y Claudio Cobelli. «Meal Simulation Model of the Glucose-Insulin System». En: *IEEE Transactions on Biomedical Engineering* 54.10 (2007), págs. 1740-1749. DOI: 10.1109/TBME.2007.893506. URL: <http://ieeexplore.ieee.org/document/4303268/> (visitado 10-10-2024).
- [13] Michele Schiavon, Chiara Dalla Man y Claudio Cobelli. «Modeling subcutaneous absorption of fast-acting insulin in type 1 diabetes». En: *IEEE Transactions on Biomedical Engineering* 65.9 (2017), págs. 2079-2086.

- [14] Maximilian Reymann et al. «Blood glucose level prediction based on support vector regression using mobile platforms». En: vol. 2016. Ago. de 2016, págs. 2990-2993. DOI: 10.1109/EMBC.2016.7591358.
- [15] Juan Li y Chandima Fernando. «Smartphone-based personalized blood glucose prediction». En: *ICT Express* 2.4 (2016). Special Issue on Emerging Technologies for Medical Diagnostics, págs. 150-154. ISSN: 2405-9595. DOI: <https://doi.org/10.1016/j.icte.2016.10.001>. URL: <https://www.sciencedirect.com/science/article/pii/S2405959516301126>.
- [16] Josep Vehí et al. «Prediction and prevention of hypoglycaemic events in type-1 diabetic patients using machine learning». En: *Health Informatics Journal* 26.1 (2020). PMID: 31195880, págs. 703-718. DOI: 10.1177/1460458219850682. eprint: <https://doi.org/10.1177/1460458219850682>. URL: <https://doi.org/10.1177/1460458219850682>.
- [17] David C Klonoff, David Ahn y Andjela Drincic. «Continuous glucose monitoring: a review of the technology and clinical use». En: *Diabetes Research and Clinical Practice* 133 (2017), págs. 178-192.
- [18] Ayman A Al Hayek, Asirvatham A Robert y Mohamed A Al Dawish. «Acceptability of the FreeStyle libre flash glucose monitoring system: the experience of young patients with type 1 diabetes». En: *Clinical Medicine Insights: Endocrinology and Diabetes* 13 (2020), pág. 1179551420910122.
- [19] Ana B. Pérez Lizaur et al. *Sistema mexicano de alimentos equivalentes*. Cuadernos De Nutrición (Fomento De Nutrición y Salud), 2014. ISBN: 9786070079283.

Development of a real-time geolocation and statistical processing prototype for detecting impacts and rollovers in automobiles

Desarrollo de un prototipo de geolocalización y procesamiento estadístico en tiempo real para la detección de impactos y volcaduras en automóviles

Sergio Daniel Rodríguez Suárez ^{*1}, Víktor Iván Rodríguez Abdalá ¹, Salvador Ibarra Delgado ¹, José Ricardo Gómez Rodríguez ¹, Cristian Eduardo Boyain y Goytia Luna ¹, and Fermín Marcelo Rubén Maciel Barboza ²

¹ Universidad Autónoma de Zacatecas, Unidad Académica de Ingeniería Eléctrica,

Posgrado en Ingeniería para la Innovación Tecnológica,

Carretera Guadalajara-Zacatecas, Campus Siglo XXI, La Escondida, Zacatecas, Zacatecas, México, 98160.

{sdanielrs,abdala,sibarra,jrgrodr,cristian.boyain}@uaz.edu.mx

² Universidad de Colima, Facultad de Ingeniería Mecánica y Eléctrica,

Carretera Colima-Coquimatlán, Coquimatlán, Colima, México, 28400.

fermin_maciel@uacol.mx

Abstract

Impact and rollover detection systems are essential for an immediate response to accidents, but not all vehicles incorporate them. This work presents a prototype based on descriptive statistics programmed in a microcontroller with sensors for geolocation and event detection. Laboratory tests were carried out under normal and impact conditions, which allowed to distinguish events. The results demonstrate that the system identifies them, offering a viable solution.

Keywords— Vehicle impacts, vehicle rollovers, descriptive statistics, embedded systems

Resumen

Los sistemas de detección de impactos y volcaduras son esenciales para una respuesta inmediata ante accidentes, pero no todos los vehículos los incorporan, este trabajo presenta un prototipo basado en estadística descriptiva programada en un microcontrolador con sensores de geolocalización y detección de eventos, se realizaron pruebas de laboratorio en condiciones normales y de impacto, lo que permitió distinguir los eventos, los resultados demuestran que el sistema los identifica, ofreciendo una solución viable.

Palabras clave— Impactos vehiculares, volcaduras vehiculares, estadística descriptiva, sistemas embebidos

I. Introducción

El incremento significativo del parque vehicular y el uso intensivo de los vehículos en las organizaciones, tanto en funciones administrativas como en actividades operativas, ha dado lugar también a tener

un mayor número de incidentes automovilísticos, desde fallas mecánicas, hasta accidentes durante los recorridos, los cuales deben ser atendidos de manera inmediata. En virtud de que la atención a los afectados es tardía, hace que las organizaciones realicen costosas erogaciones para atender las consecuencias, además de verse afectadas las funciones de la misma [1].

* Autor de correspondencia

En estudios sobre accidentes automovilísticos [2, 3, 4] se ha evidenciado que de 2010 a 2019, el número de personas fallecidas y heridas graves en accidentes ha disminuido, observándose que esto se atribuye a una atención más rápida y a las mejoras en los sistemas de seguridad vehicular con que están dotados. Para responder rápidamente a un incidente, se debe conocer la ubicación del vehículo, así como el estado en que se encuentra, para lo cual, estos sistemas proporcionan dicha información, siendo cada vez más comunes en los vehículos modernos, sin embargo, no todos los vehículos se encuentran equipados con ellos, siendo necesario equipar a los que no los tienen.

Los impactos vehiculares son aquellos eventos dinámicos resultantes de la colisión de un automóvil, con un objeto fijo u otro vehículo en movimiento, caracterizado por cambios abruptos de aceleración o desaceleración. Para una volcadura, el vehículo es considerado un cuerpo sólido con un marco de referencia, empleándose el marco de referencia vehicular ISO 8855 [5], que define un eje longitudinal X , un eje lateral Y , así como un eje vertical Z , como se muestra en la Fig. 1. Se considera una volcadura cuando el giro del vehículo en alguno de los ejes X o Y sobrepasa un umbral.




Figura 1: Vehículo sobre marco de referencia ISO 8855

La detección de impactos y volcaduras vehiculares es fundamental para agilizar la respuesta ante accidentes, los sistemas embebidos, que integran sensores inerciales y algoritmos en microcontroladores, ofrecen soluciones compactas y prácticas para esta tarea, además, su demanda crece constantemente debido a la necesidad de mejorar la seguridad.

Con la finalidad de integrar en un vehículo, que carece del sistema de detección, un sistema embebido de detección, que además no interfiera con los sistemas que ya posee, se diseñó un dispositivo embebido, de bajo costo, que detecta eventos de impacto y volcadura, mediante el análisis estadístico en tiempo real del comportamiento dinámico del vehículo, este se diferencia de los sistemas existentes al integrar en un solo dispositivo el procesamiento y el sensado.

Este artículo se estructura de la siguiente forma: la Sección II presenta el panorama de la investigación, la Sección III describe el desarrollo de un nodo de detección, la Sección IV muestra el modelo del sistema y finalmente las secciones V y VI exponen los resultados obtenidos y las conclusiones.

II. Panorama de investigación

De acuerdo con [6], la fabricación de automóviles en México se ha incrementado y por ende la necesidad de contar con dispositivos tecnológicos para mejorar la seguridad de los mismos [7], por lo cual, gracias a las capacidades de los sensores actuales y a un mayor procesamiento computacional en dispositivos de menor tamaño, se puede contar con sistemas embebidos para obtener la ubicación y detectar el comportamiento dinámico del vehículo.

La ubicación de los vehículos es importante para las organizaciones, la manera de realizarlo es diverso y se apoya de los avances tecnológicos existentes [8], entre los que se pueden observar: la Identificación por Radio Frecuencia (RFID, siglas en inglés de Radio Frequency Identification), la ubicación mediante Redes Móviles Celulares y el uso del Sistema de Navegación Global por Satélite (GNSS, siglas en inglés de Global Navigation Satellite System), siendo el sistema GNSS el de mayor tendencia.

La detección de impactos y volcaduras en automóviles es un aspecto de seguridad reconocido como un tema relevante [9], existiendo en la actualidad directivas y objetivos que las empresas armadoras de vehículos deben cubrir y los países deben supervisar que se adopten, a fin de apearse a los objetivos mundiales para incrementar la seguridad en los automóviles y de esta manera disminuir los daños que las personas sufren en los accidentes [7].

En [10, 11, 12, 13, 14] se estudia el uso de GNSS para determinar la ubicación de un vehículo y en [15, 16, 17] se han estudiado los sensores inerciales para obtener el comportamiento de la dinámica del vehículo para determinar eventos como impactos y vuelcos.

A partir del análisis de las fuentes consultadas y el criterio de costo-beneficio, se seleccionó el microcontrolador ESP32, junto con el receptor satelital GPS NEO-6M, la unidad de medición inercial MPU-9250, además de un algoritmo de detección basado en estadística descriptiva, con los cuales es posible construir un nodo para determinar la ubicación de un vehículo y detectar eventos como impactos y volcaduras [18].

III. Diseño del Nodo de detección

La arquitectura propuesta para el nodo se basa en un microcontrolador ESP32, el receptor GPS NEO-6M y el sensor inercial MPU-9250. El ESP32 es el núcleo de procesamiento en un Sistema en Chip (SoC, siglas en inglés de System on a Chip) que incorpora un microprocesador Tensilica Xtensa LX6 de dos núcleos, es un dispositivo programable en múltiples plataformas de desarrollo, una de las presentaciones más utilizada es el ESP32 Devkit [19], la selección de este dispositivo destaca frente a

otros microcontroladores por su equilibrio entre potencia, conectividad y bajo costo.

El receptor satelital GPS NEO-6M es adoptado por su manejo sencillo y funcionalidad adecuada, incorpora un chip de posicionamiento u-blox 6 de 50 canales y antena, proporciona tramas NMEA (siglas en inglés de National Marine Electronics Association) con los datos de ubicación, se conecta al microcontrolador por el puerto UART.

El sensor inercial MPU-9250 es un sensor compuesto por un acelerómetro y giroscopio de 3 ejes, útil para aplicaciones de navegación inercial y medición de comportamiento dinámico, se conecta al microcontrolador por el puerto I2C [20].

El desarrollo del nodo comprende el obtener las coordenadas de ubicación en latitud y longitud, así como medir la aceleración lineal y velocidad angular en los ejes X, Y y Z, datos con los cuales se realiza el análisis estadístico para determinar los eventos de impacto y volcadura. En la Fig. 2 se muestra la interconexión de los dispositivos.

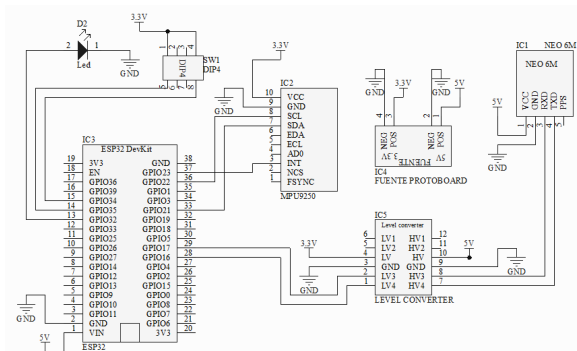


Figura 2: Diagrama de conexión

La programación del nodo se realiza utilizando FreeRTOS, el cual es un sistema operativo de tiempo real diseñado para sistemas embebidos, su gestión de procesos permite la ejecución concurrente de tareas, además de la comunicación entre procesos y manejo de recursos.

Para efectuar las pruebas y mediciones se utilizó un vehículo a escala 1:12, de radio control, con suspensión y control de dirección, como el que se muestra en la Fig. 3, con el cual, bajo condiciones controladas de laboratorio, se recrearon eventos de impacto y volcadura para observar el comportamiento del nodo, así como el desempeño de los algoritmos implementados.

En la Fig. 4 se describe el proceso general propuesto para llevar a cabo el procesamiento y análisis de los datos obtenidos de los sensores.



Figura 3: RC H1 Hurtle, vehículo de pruebas y simulación

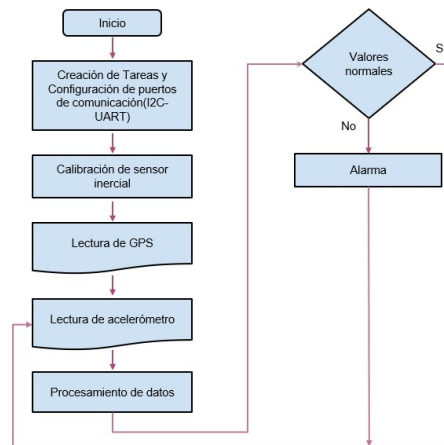


Figura 4: Diagrama de flujo para configuración y detección

IV. Modelo de sistema

IV.1. Detección de impactos

La duración de un impacto vehicular, esto es, desde que hace contacto con el objeto, hasta que se detiene por completo, se denomina Pulso de colisión, el cual varía de acuerdo a factores como la velocidad inicial, la masa del vehículo y el tipo de objeto contra el que se impacta [21], por lo cual no hay un valor fijo. Tomando en cuenta [22], donde se muestran diversos experimentos de impacto con varios tipos de vehículos, en este estudio se considera que el impacto tiene una duración promedio de 120 ms, y que durante este intervalo de tiempo el vehículo sufre cambios bruscos de aceleración, por lo que para detectar el impacto, se debe de ajustar la tasa de muestreo del sensor.

Configurando la tasa de muestreo del sensor inercial MPU9250 a 1,000 Hz, este proporciona $1,000 \frac{\text{muestras}}{\text{seg}}$, debido que estas muestras son datos crudos se aplica un filtro de promedio móvil para suavizar las fluctuaciones y el ruido, reduciéndose a $100 \frac{\text{muestras}}{\text{seg}}$, con este número de muestras se dispone de las 12 muestras que representan los 120 ms del pulso de colisión, de esta manera, con el fin de realizar la detección de cambios abruptos de aceleración, el algoritmo programado toma vectores de 10 muestras (100 ms) para analizarlos estadísticamente mediante la desviación estándar y el rango.

La primera etapa del proceso de análisis consistió en identificar, mediante la experimentación, un dominio de valores de aceleración en condiciones normales (sin impactos), con el fin de aplicarlo para establecer un umbral a partir del cual se pueda diferenciar una condición normal de una anormal (con impacto). Para este proceso se obtuvo una muestra de valores de la magnitud de aceleración, la cual se obtiene con la Ec. (1).

$$|\mathbf{a}| = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (1)$$

En la Fig. 5 se muestra el comportamiento de la magnitud de la aceleración durante un experimento en condiciones normales.




Figura 5: Comportamiento de la magnitud de la aceleración en experimento sin impacto

Posteriormente con los datos de magnitud de aceleración se realizó el siguiente proceso de análisis:

- 1) se forma un vector de 10 valores de magnitud de aceleración x_1, x_2, \dots, x_{10} ,
- 2) se estima la media de este conjunto (Ec. (2)),

$$\bar{x} = \frac{1}{10}(x_1 + x_2 + \dots + x_{10}) \quad (2)$$

- 3) se estima la varianza (Ec. (3)),

$$\sigma^2 = \frac{1}{10} \sum_{i=1}^{10} (x_i - \bar{x})^2 \quad (3)$$

- 4) se estima la desviación estándar (Ec. (4)),

$$\sigma = \sqrt{\frac{1}{10} \sum_{i=1}^{10} (x_i - \bar{x})^2} \quad (4)$$

- 5) se estima el máximo (Ec. (5)) y mínimo (Ec. (6)) del vector para obtener el rango (Ec. (7)),

$$\text{máx}(x_1, x_2, \dots, x_{10}) \quad (5)$$

$$\text{mín}(x_1, x_2, \dots, x_{10}) \quad (6)$$

$$\text{Rango} = \text{máx}(x_1, x_2, \dots, x_{10}) - \text{mín}(x_1, x_2, \dots, x_{10}) \quad (7)$$

Los datos obtenidos fueron analizados mediante la Ec. (8), para observar la densidad de probabilidad normal de los valores calculados de desviación estándar y de rango, conociendo de esta función, que el 99.73 % de probabilidad de aparición de los valores se concentra en el intervalo determinado por $\pm 3\sigma$, llamado intervalo de confianza, se estableció que los valores fuera de este intervalo se pueden interpretar como condiciones de anomalía.

$$f_{|\mathbf{a}|}(a) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(a-\mu)^2}{2\sigma^2}} \quad (8)$$

Efectuándose experimentos en condiciones normales, se calculó la desviación estándar en el intervalo de 0.082 a 0.108, como se ve en la Fig. 6, mientras que para el Rango, en el intervalo de 0 a 0.10, como se observa en la Fig. 7.



Figura 6: Análisis de la desviación estándar




Figura 7: Análisis de rango

Los valores extremos del intervalo de confianza determinados en los experimentos anteriores son los valores de umbral programados en el algoritmo de detección.

Cuando se presentan condiciones de impacto, el comportamiento de la magnitud de la aceleración describe características singulares, las cuales se pueden observar gráficamente en la Fig. 8, donde se puede visualizar un cambio abrupto en los valores de la aceleración.

Aplicando el mismo proceso de análisis hecho para los datos en condiciones sin impacto, se obtienen los valores de desviación estándar y rango fuera de los intervalos determinados por 3σ para condiciones normales, observándose gráficamente estas variaciones en las mediciones




Figura 8: Comportamiento de la magnitud de aceleración en eventos sin y con impacto

sin impacto y con impacto en las gráficas de la Fig. 9 para la desviación estándar y en la Fig. 10 para el rango.




Figura 9: Comparación de la desviación estándar sin y con impacto




Figura 10: Comparación de rango sin y con impacto

IV.2. La detección de volcaduras

Para considerar la inclinación de riesgo de volcadura o a partir de la cual el vehículo se puede considerar volcado, se calcula el ángulo máximo de inclinación lateral (Θ_{max}) de acuerdo al tipo de vehículo, el cálculo se basa en la Ec. (9) [23], que indica un valor de inclinación de riesgo basado en la distancia entre llantas del mismo eje del vehículo y la altura del centro de masa. Para esta investigación se consideró un camión de carga unitario

de tipo C3 (tres ejes, delantero y 2 traseros), de acuerdo a la norma mexicana NOM-012-SCT-2-2017, para el cual la distancia entre llantas del mismo eje es 2 metros y la altura del centro de masa es 1.5 metros.

Los valores de los ángulos son aproximados debido a que el peso y dimensiones de la carga pueden variar.

$$\Theta_{max} = \arctan \frac{T}{2h} = \arctan \frac{2m}{2(1.5m)} = 33^\circ \quad (9)$$

Donde:

- T es la distancia entre ruedas del mismo eje,
- h es la altura del centro de masa del vehículo.

De esta manera cuando los ángulos de inclinación pitch y roll (ver Fig. 1) son superiores a ± 33 grados se considera que es una volcadura, este puede no ser un valor fijo, depende del vehículo, sin embargo el valor calculado en Ec. (9) se pueden tomar como umbral, programado en el algoritmo y a partir del cual el nodo genere una alerta.

Para medir los ángulos de inclinación, el nodo fue sometido a inclinaciones frontal y lateral, observándose en la Fig. 11 los valores de inclinación frontal y en la Fig. 12 los valores de inclinación lateral, hasta superar el umbral.

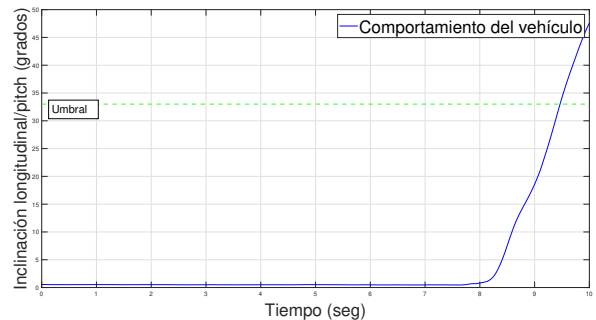


Figura 11: Inclinación longitudinal (Pitch)

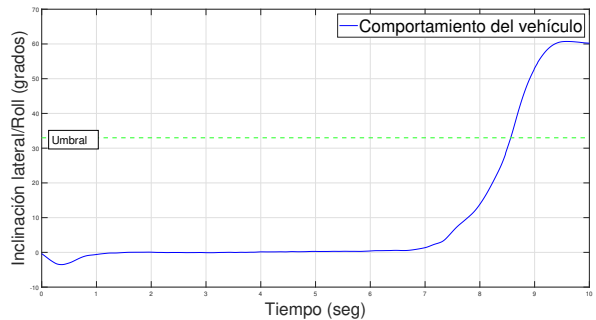


Figura 12: Inclinación lateral (Roll)

V. Resultados

Para la presentación de los resultados, se consideraron 5 experimentos de prueba en condiciones normales y 5 experimentos con impacto.

V.1. Experimentos en condiciones normales

Se realizó la gráfica de las aceleraciones para identificar su respuesta, observándose que coinciden en el comportamiento como se muestran en la Fig. 13.




Figura 13: Aceleraciones en experimentos sin impacto

Posteriormente se procesaron los datos para obtener la desviación estándar y el rango de vectores de 10 muestras, graficándose los resultados con los umbrales encontrados para los valores en condiciones normales, observándose que la mayoría de las lecturas se encuentran dentro del intervalo $\pm 3\sigma$, como se muestra en la Fig. 14 para la desviación estándar y en la Fig. 15 para el rango.

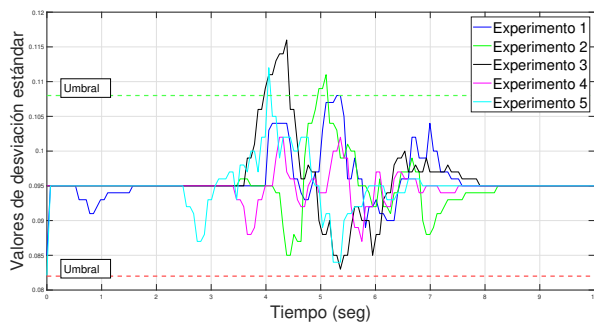


Figura 14: Desviación estándar en experimentos sin impacto

V.2. Experimentos en condiciones de impacto

Aplicando el mismo procedimiento se realizaron los experimentos con impacto, en la Fig. 16 se muestra el comportamiento de la aceleración, como se puede observar en las gráficas obtenidas se percibe un comportamiento diferente a los que se obtuvieron sin impactos,




Figura 15: Rango en experimentos sin impacto

así mismo es posible advertir un comportamiento en el que se presentan cambios abruptos de aceleración con un cierto patrón, donde se deduce que el vehículo sufrió una desaceleración abrupta causada por el impacto.

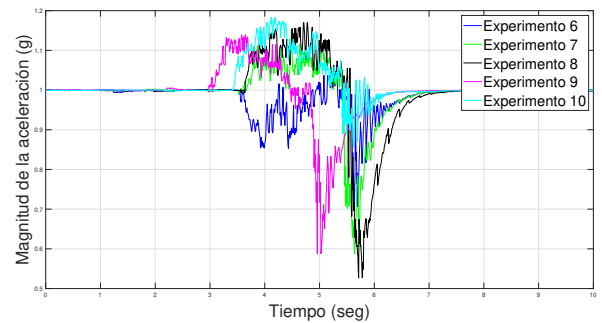


Figura 16: Aceleraciones en experimentos con impacto

En la Fig. 17 se muestra la gráfica de la desviación estándar de los experimentos, observándose que superan con mayor frecuencia los umbrales de condiciones normales.

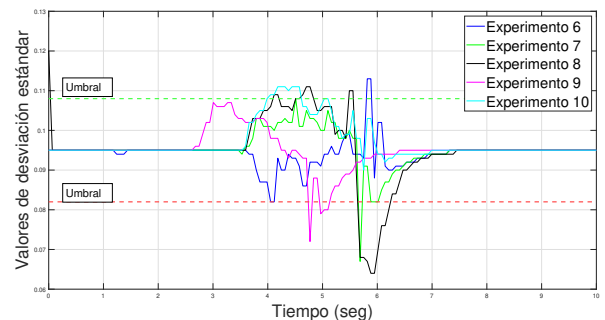


Figura 17: Desviación estándar en experimentos con impacto

En la Fig. 18, se grafican los valores de rango, observándose como las magnitudes pueden superar el umbral para condiciones normales.

Los valores de umbral para impacto y volcadura, deter-

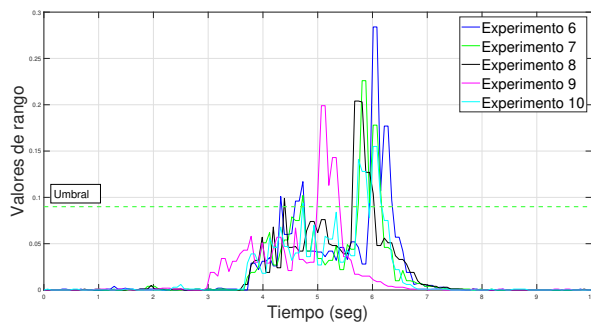


Figura 18: Rango en experimentos con impacto

minados en el análisis, fueron programados en el algoritmo del nodo, son valores fijos, y solo se deben actualizar si se cambia el tipo de vehículo, realizando el análisis y obtención de los nuevos umbrales se forma similar.

VI. Conclusiones

Durante el desarrollo del prototipo para la identificación de impactos y volcaduras, mediante análisis estadístico, se midió en tiempo real las aceleraciones que experimenta un vehículo durante su desplazamiento, los experimentos realizados mostraron que en condiciones normales de operación, –es decir, sin cambios bruscos de aceleración–, el comportamiento de las aceleraciones en los tres ejes (X , Y y Z) varía constantemente dentro de un intervalo, las variaciones que sufren durante el movimiento tienen dos características principales, la primera es que los cambios de magnitud son suaves en el tiempo y la segunda, que la magnitud se mantiene dentro de un intervalo determinado de valores la mayor parte del tiempo.

Al realizar los experimentos con condiciones de impacto, estos salen de los umbrales, por lo cual, para determinar el evento de siniestro se realiza un proceso de decisión basado en los siguientes aspectos: que exista un valor de desviación estándar fuera de los umbrales, que exista un valor de rango superior al umbral y que ocurran en el mismo vector de mediciones analizadas.

Los experimentos con impacto se realizaron utilizando un vehículo a escala, siendo necesario adecuar los valores de umbral en el caso de que sea factible instalar el nodo en un vehículo real, realizando el mismo proceso de análisis a fin de determinar los umbrales específicos para el vehículo utilizado.

Como trabajo futuro es la incorporación de un canal de radiocomunicación para la transmisión de la señal de alerta, de esta manera no solo se contemplaría para un uso en vehículos oficiales, se puede proyectar para uso en flotas de empresas o inclusive en autos particulares, en virtud que no es un sistema invasivo con los sistemas de

los vehículos y puede adaptarse como un accesorio, sin que afecte de ninguna manera a la operación y seguridad de vehículo.

Referencias

- [1] P. Huang et al. «Effect of emergency medical service response time on fatality risk of freeway crashes: Bayesian random parameters spatial logistic approach». En: *Frontiers in Public Health* 12 (2024), pág. 1453788. DOI: 10.3389/fpubh.2024.1453788.
- [2] Fuentes José de Jesús Galindo. «Perfil epidemiológico de los accidentes de tránsito en México, 2010-2019». En: *Horiz. sanitario [online]* 22.1 (mar. de 2023), págs. 45-52.
- [3] INEGI. *Accidentes de Tránsito Terrestre en Zonas Urbanas y Suburbanas (ATUS) 2020-2023*. <https://www.inegi.org.mx/programas/atus/>. 2023.
- [4] SATECH. *¿Cómo impacta un accidente vehicular en tu negocio?* <https://satech.mx/como-impacta-un-accidente-vehicular-en-tu-negocio/>. 2025.
- [5] de la Peña Nelson Arzola y Torres César Andrés Castro. «Análisis del comportamiento dinámico de una suspensión de vehículo independiente de doble horquilla.» En: *LogosCyT [online]* 11.2 (mar. de 2019), págs. 10-33.
- [6] Montoya Godínez et al. «Análisis del mercado interno y externo del sector automotriz en México». En: *Revista cartográfica* 106 (2020).
- [7] Wallbank Caroline et al. «El potencial de los estándares de seguridad vehicular para evitar muertes y lesiones en Argentina, Brasil, Chile y México: actualización 2018». En: *TRL The future of transport* (mar. de 2019).
- [8] Chindhe Gaurav et al. «A Survey on Various Location Tracking Systems». En: *International Research Journal of Engineering and Technology* 5.12 (dic. de 2018), págs. 671-675.
- [9] Noushin Behboudi, Sobhan Moosavi y Rajiv Ramnath. «Recent Advances in Traffic Accident Analysis and Prediction: A Comprehensive Review of Machine Learning Techniques». En: *arXiv preprint arXiv:2406.13968* (2024).
- [10] Andrew R Robinson, Michael Esty y Charles E Tilburg. *A Compact GPS Surface Drifter with LoRa Telemetry and Self-Contained Tracking System*. 2021.

- [11] Alejandro González, José Luis Olazagoitia y Jordi Vinolas. «A low-cost data acquisition system for automobile dynamics applications». En: *Sensors (Switzerland)* 18 (2 feb. de 2018). ISSN: 14248220. DOI: 10.3390/s18020366.
- [12] Norhafizah et al. «An open source LoRa based vehicle tracking system». En: *Indonesian Journal of Electrical Engineering and Informatics* 7 (2 jun. de 2019), págs. 221-228. ISSN: 20893272. DOI: 10.11591/ijeel.v7i2.1174.
- [13] Angie Paola y Marriaga Barroso. *Device design for vehicle tracking with Lora-IoT module oriented to public transport systems in smart cities*. 2021.
- [14] Alejandro Saniger et al. «Mobile data for studying public space, and trips in Mexico City: a study case of six suburban zones». En: *Data & Policy* (2024). URL: <https://www.cambridge.org/core/journals/data-and-policy/article/mobile-data-for-studying-public-space-and-trips-in-mexico-city-a-study-case-of-six-suburban-zones/C913EF8166D0183E517349BF6D15EC24>.
- [15] F. Garcia et al. «Sensor Fusion Methodology for Vehicle Detection». En: *IEEE Intelligent Transportation Systems Magazine* 9.1 (mayo de 2017). doi: 10.1109/MITS.2016.2620398., págs. 123-133.
- [16] Ying Shuh Jing, Dubey Rajiv y Sundarrao Stephen. *Gyroscope for Robot to Sense the Balance*. Dic. de 2018. DOI: 10.35840/2631-5106/4112. URL: <https://doi.org/10.35840/2631-5106/4112>.
- [17] Mazhar Malik Kamal et al. «A Novel Roll and Pitch Estimation Approach for a Ground Vehicle Stability Improvement Using a Low Cost IMU». En: *Sensors* 20.2 (2020). ISSN: 1424-8220. DOI: 10.3390/s20020340. URL: <https://www.mdpi.com/1424-8220/20/2/340>.
- [18] Gabriel Pérez Campoy. «Estudio de la viabilidad de dispositivos IMU low-cost para usos de navegación y rastreo con Arduino/ESP32, y construcción de su prototipo». Tesis de mtría. Universitat Politècnica de Catalunya, oct. de 2023. URL: <https://upcommons.upc.edu/handle/2117/396584>.
- [19] Zerynth. *DOIT ESP32 DevKit v1*. Zerynth. 2017. URL: https://olddocs.zerynth.com/r2.3.3/official/board.zerynth.doit%5C_esp32/docs/index.html.
- [20] InvenSense. *Register Map and Descriptions MPU 9250*. 1.6. InvenSense. Jul. de 2015.
- [21] Joseph Olberding, Karla Petroskey y Tara Leipold. *Coefficient of Restitution and Collision Pulse Duration in Low-Speed Vehicle-to-Barrier Impacts*. Inf. téc. SAE Technical Paper 2023-01-0624. SAE International, 2023. DOI: 10.4271/2023-01-0624.
- [22] Tso-Liang Teng et al. «Application of Crash Pulse on the Car Crashworthiness Design». En: *Advances in Mechanical Engineering* 9.9 (2017), págs. 1-11. DOI: 10.1177/1687814017700096.
- [23] Thomas D. Gillespie. *Fundamentals of Vehicle Dynamics, Revised Edition*. Warrendale, PA: SAE International, 2021. ISBN: 978-1-4686-0176-3.

System for the acquisition and storage of ECG signals using a Raspberry Pi board

Sistema para la obtención y Almacenamiento de señales ECG mediante el uso de una tarjeta Raspberry Pi

M.J. Hernández Llamas¹, J.U. Muñoz Minjares ², M. López-Ramírez ¹, L.M. Ledezma-Carrillo ¹, and E. Cabal Yopez ^{*1}

¹Universidad de Guanajuato, Campus Irapuato-Salamanca, Departamento de Estudios Multidisciplinarios (DEM), Avenida Universidad, S/N, Col. Yacatitas, Yuriria, Guanajuato, México, 38944.

{mdj.hernandezllamas, educabal,lopez.misael,lm.ledesma}@ugto.mx

²Universidad Autónoma de Zacatecas (UAZ), Unidad Académica de Ingeniería Eléctrica Plantel Jalpa Libramiento Jalpa Km., 156+380, Fraccionamiento Solidaridad, Jalpa, Zacatecas, México, 99600.

ju.muñoz@uaz.edu.mx

Abstract

This work presents a low-cost and high-performance system based on a Raspberry Pi 5 board. The proposed system uses an AD8232 sensor for signal acquisition and an Arduino UNO for analog-to-digital conversion, while the Raspberry Pi handles data processing and user interface management. A Python script was developed to display the ECG signal in real time, apply a band-pass filter (0.5–40 Hz) and a notch filter (60 Hz), and store the processed signal for further analysis. The obtained signals were compared using the Pan-Tompkins algorithm for QRS complex detection. The results confirmed that the acquired signals exhibit the characteristic morphology of an ECG waveform and enable accurate detection of R peaks.

Keywords— Raspberry PI, ECG signal, Acquisition

Resumen

En este trabajo se presenta un sistema de bajo costo y alto rendimiento basado en una tarjeta Raspberry PI 5. El sistema propuesto utiliza un sensor AD8232 para la obtención de las señales y un Arduino UNO para realizar la conversión analógico-digital, mientras que la Raspberry PI se encarga del procesamiento de los datos y la gestión de la interfaz de usuario. Se desarrolló un script en Python capaz de mostrar la señal ECG en tiempo real, aplicar un filtro pasa banda (0.5–40 Hz) y un filtro notch (60 Hz), además de guardar la señal procesada para su posterior análisis. Las señales obtenidas se compararon utilizando el algoritmo Pan-Tompkins para la detección de los complejos QRS. Los resultados confirmaron que las señales obtenidas cuentan con la morfología característica de una señal ECG y permiten la detección precisa de los picos R.

Palabras clave— Raspberry PI, Señal ECG, Obtención

I. Introducción

En la actualidad, millones de personas en el mundo padecen enfermedades cardiovasculares, muchas de las cuales no se detectan a tiempo debido a la falta de acceso a diagnósticos tempranos, especialmen-

te en regiones con recursos limitados. La identificación y el tratamiento de estas condiciones es fundamental para prevenir complicaciones graves a futuro e incluso la muerte de las personas. Es crucial atender este problema porque las enfermedades cardíacas siguen siendo una de las principales causas de mortalidad a nivel mundial y en México, esto de acuerdo a la OMS y al INEGI respectivamente [1].

*Corresponding author

Las señales electrocardiográficas son una de las principales formas para diagnosticar problemas con la salud cardiovascular de las personas, esto debido a su simpleza, y a la poco invasiva que es la prueba. Es posible aprovechar estas ventajas para desarrollar un sistema con un dispositivo pequeño y potente como una tarjeta Raspberry PI que cuenta con una gran capacidad de cómputo como se puede ver a continuación.

La Raspberry ofrece la opción de conectarle una gran cantidad de distintos dispositivos con diferentes propósitos y para distintas aplicaciones en donde se ha demostrado que estas tarjetas tienen la capacidad de manejar sensores, actuadores e incluso algoritmos para procesamiento de información, por ejemplo, en [2] se implementó un algoritmo entrenado para detectar incendios, la tarjeta Raspberry PI es la encargada de controlar los motores y la bomba de agua, cuando se detecta un incendio, la tarjeta se encarga de controlar el motor y la bomba de agua para enviar el agua al lugar indicado. Mientras que en [3] se desarrolló un sistema que logra medir la curva de corriente-voltaje de un panel solar mediante el proceso de carga y descarga de un condensador, así como también sensores para medir la irradiancia y la temperatura del panel. La Raspberry PI es la encargada de recibir la información de los sensores y el capacitor, y al final mostrar esta información en una interfaz implementada en la tarjeta.

Mientras que en [4] desarrollaron un sistema para mantener la mayor eficiencia en los paneles solares cuando están cubiertos por sombra, la Raspberry se encarga de medir voltaje y corriente del panel fotovoltaico y calcular la potencia, con estos datos se alimenta el algoritmo rastreador de máxima potencia (MPPT) y se decide el cómo mantener la relación voltaje/Corriente óptima para las condiciones de sombra actuales.

Otra aplicación para la tarjeta Raspberry PI la podemos encontrar en [5], el objetivo de este trabajo fue medir el haz de luz generado por los rayos X de un aparato dental, usando una pantalla de fósforo, que al ser atravesado por el haz de luz, forma un patrón el cual es grabado por una cámara conectada a la Raspberry PI, demostrando que la tarjeta y la cámara tienen la capacidad de captar el haz de forma adecuada, especialmente en condiciones de oscuridad.

En [6] desarrollaron un dispositivo por medio de una impresión 3D, el objetivo es capturar imágenes de forma automatizada, hacen uso de una tarjeta Raspberry PI que controla una cámara, así como la frecuencia en la que se toman las fotografías y también controla unas tiras LED como iluminación. Por otro lado, en [7] se desarrolló un sistema para monitorear la temperatura en tiempo real, la tarjeta Raspberry PI es la encargada de recibir la información del sensor y procesarla, en este caso convierte los grados Celsius a Fahrenheit y obtiene

el índice de calor.

Otro ámbito en el que se ha utilizado la Raspberry PI, es en la automatización del hogar, como en [8], en este trabajo, la tarjeta recibe información de distintos sensores, por ejemplo, sensores infrarrojos para la detección de personas, sensores de luz, sensores de temperatura y algunos módulos relay para activar dispositivos, mientras que en [9] el sistema se encarga del monitoreo de seguridad de una casa, la tarjeta maneja distintos sensores, por ejemplo, de temperatura, densidad de gas, y una cámara. A su vez, es capaz de enviar alertas por mensaje de texto.

En [10] desarrollaron un sistema para el monitoreo de tractores instrumentados en tiempo real, los datos que se obtienen son: la profundidad de trabajo, la fuerza de tracción, la velocidad de avance, el desplazamiento de la rueda, la tracción y la ubicación GPS, estos datos son procesados por la Raspberry PI y los envía a la nube para almacenar los datos.

Mientras que en [11] se usó la Raspberry PI para determinar cual sonido es el preferido por una especie de ave cantora, se hizo uso de sensores infrarrojos para determinar que sonido se debería reproducir, si el ave permanecía en el lugar escuchando el audio, se tomaba como una muestra exitosa. Otra aplicación para la Raspberry PI, se puede encontrar en [12], se realizó un sistema para detectar concentración de moléculas, la tarjeta es la encargada de controlar la señal eléctrica enviada a los electrodos, y recibir la información del fotomultiplicador de luz, con estos datos calcula la cantidad de molécula presente en la muestra. Otra aplicación se puede ver en [13], se hace uso de la tarjeta para monitorear la formación de espuma de polietileno, para esto se mide la temperatura, la altura de crecimiento de la espuma y la pérdida de masa después de la reacción. De igual forma la tarjeta hace correcciones necesarias en los datos.

Una de las áreas en donde es muy aplicada la tarjeta, es en visión, por ejemplo, en [14] se desarrolló un sistema para la identificación de especies de hormigas en tiempo real, la tarjeta recibe información de sensores de temperatura, humedad, así como la ubicación, y de igual forma controla la cámara con la que se identifican las hormigas. Para la identificación se implementó el algoritmo "You Only Look Once" (YOLO). Otro ejemplo se encuentra en [15], en este trabajo se caracterizan las propiedades de materiales blandos, como el hidrogel, el sistema se desarrolló con piezas impresas en 3D, la tarjeta controla el sistema para inducir movimiento en el material, así como la cámara, y al final realiza el procesamiento para obtener las frecuencias de vibración del gel.

En los trabajos anteriormente mencionados, se puede observar que la tarjeta Raspberry PI ha demostrado tener la capacidad de obtener información de distintos sensores, así como de tener la capacidad de realizar procesamiento de información, debido a esto, este trabajo

busca aprovechar las capacidades de la tarjeta para desarrollar un sistema de bajo costo, portátil y potente que cuente con la capacidad de obtener las señales ECG, procesarlas por medio de un filtrado y posteriormente ofrecer la posibilidad de visualizar las señales en tiempo real, así como guardarlas para que puedan ser analizadas por un especialista que determine la salud del paciente o procesadas para su implementación en la amplia gama de algoritmo de inteligencia artificial que se encuentran disponibles actualmente.

II. Metodología

En la Figura 1 se describen de manera general los dispositivos y algoritmos utilizados para adquirir las señales ECG, detectar los picos R y visualizarlos en una interfaz. Los conceptos teóricos de este diagrama se explican en las secciones más abajo.



Figura 1: Metodología para la visualización y detección de picos de un ECG.

II.1. Señales de electrocardiograma (ECG)

Las señales de un electrocardiograma son una representación gráfica de la actividad eléctrica presente con la actividad del corazón a lo largo del tiempo, cuando el corazón late, se generan impulsos eléctricos, estos impulsos son posibles de captar a través de la piel.

La señal ECG tiene una forma ideal característica. En la Figura 2 se puede observar la forma ideal de la señal, así como de la morfología que tiene esta misma.




Figura 2: Señal ECG ideal.

II.2. Arduino UNO

Uno de los retos para la implementación de distintos sensores en la tarjeta Raspberry PI, es la ausencia de convertidores Analógico-Digital implementados directamente en los pines de la tarjeta, por esto, es necesario hacer uso de un sistema independiente que permita realizar esta tarea, en este caso, se hace uso de un Arduino UNO, este es el encargado de obtener la información del sensor y convertir la información de analógica a digital, posteriormente se envía la información por el puerto serial hacia la tarjeta Raspberry PI.

II.3. Sensor AD8232

Para obtener las señales de electrocardiograma, se hace uso del sensor AD8232, un sensor de 3 derivaciones que permite obtener una señal ECG cercana a la que se obtendría por un equipo médico, este sensor se conecta al convertidor, para pasar la información a la tarjeta Raspberry PI.

II.4. Raspberry PI

Esta es la tarjeta utilizada para obtener la información del sensor, y que es la encargada de aplicar un filtrado a la señal y de manejar la interfaz en la que se puede visualizar la señal en tiempo real, así como guardarla, es una tarjeta Raspberry PI 5 que cuenta con el procesador Broadcom BCM2712 Arm Cortex A76 de 4 núcleos a 2.4 GHz, el modelo más avanzado hasta el momento, y que ofrece la mayor capacidad de cómputo, en concreto, se utiliza la versión que cuenta con 16 GB de RAM. En la Figura 3 se puede observar la tarjeta.




Figura 3: Tarjeta Raspberry PI 5.

II.5. Simulador de señales ECG SKX-2000C

Para comprobar la eficiencia del sistema, las señales obtenidas se compararán con las señales que se pueden

obtener de un simulador de señales ECG profesional, específicamente se planea utilizar el generador SKX-2000C. La Figura 4 corresponde al simulador de señales a utilizar.



Figura 4: Simulador de señales ECG SKX-2000C.

II.6. Filtrado de la Señal ECG

Debido a la posible presencia de distintos tipos de ruidos, se agregó 2 filtros a la señal, el primero es un filtro pasa banda con frecuencias de corte de 0.5 y 40 Hz, y el segundo es un filtro notch, con una frecuencia de corte de 60 Hz, la implementación de estos 2 filtros se realizó en el mismo programa de la interfaz, por lo que se aplican en tiempo real a la señal obtenida; realizar este proceso permite tener una señal más limpia y clara.

II.7. Interfaz

La interfaz se implementó por medio de un código de python el cual se ejecuta directamente en la tarjeta Raspberry PI, la interfaz ofrece visualizar la información proveniente del sensor en tiempo real, y a su vez, permite modificar el rango de muestras que se pueden ver en pantalla al mismo tiempo, este rango va desde 50 hasta 20000 muestras, también se puede activar la visualización de una señal cruda, sin filtrar, así como también ofrece la posibilidad de detener la grabación de la señal, de igual forma, se tiene la opción de guardar la señal ECG filtrada que se este mostrando en ese momento en tiempo real, tomando en cuenta la cantidad de muestras que se hayan seleccionado.

II.8. Algoritmo Pan-Tompkins

El algoritmo Pan-Tompkins es un método ampliamente conocido para detectar los complejos QRS en una señal de electrocardiograma, este fue propuesto por Jiapu Pan y Willis J. Tompkins en 1985. El objetivo principal de este algoritmo es detectar con precisión los picos R, estos picos son los más prominentes en una señal ECG. Debido a estas características, se implementó en las señales obtenidas con el sistema y en las señales generadas por el simulador como una forma de comprobar si las señales cuentan con la morfología típica de este tipo de señales.

III. Resultados

La interfaz desarrollada busca ser lo más amigable posible para el usuario para la representación gráfica de la señal ECG en tiempo real, dentro de esta, las distintas opciones demostraron funcionar de forma eficiente, permitiendo mostrar una gran variedad de cantidad de muestras en pantalla en tiempo real de acuerdo a lo que se necesite, así como guardar los archivos de una forma eficiente en un formato CSV, se eligió este tipo de archivo, debido a la facilidad que se tiene para trabajar con el, facilitando así su posterior análisis con diferentes algoritmos, o por un profesional de la salud. En la Figura 5 se puede observar la interfaz desarrollada para el sistema.




Figura 5: Interfaz para señal ECG.

Para analizar los resultados obtenidos con el sistema desarrollado, se realizó la comparación de las señales guardadas con las señales generadas por un simulador de señales ECG, para esta comparación se hizo uso del algoritmo Pan-Tompkins, el cual permitió la detección del complejo QRS determinando la ubicación de los picos R característicos de las señales ECG. En la Figura 6 se puede observar los picos R correspondientes a la señal obtenida por el sistema, mientras que la Figura 7 corresponde a los picos R encontrados en la señal simulada.




Figura 6: Picos R encontrados en señal obtenida.




Figura 7: Picos R encontrados en señal simulada.

El algoritmo demostró que las señales ECG obtenidas por el sistema tienen la morfología típica de este tipo de señales, se detectaron todos los picos R presentes en la señal, de igual forma, se obtuvieron resultados similares con la señal generada por el simulador.

IV. Conclusión

La tarjeta Raspberry PI demostró tener la capacidad de recibir la información obtenida por el sensor, así como de procesarla en tiempo real, en este caso aplicando filtros, así como de guardar los archivos sin problemas.

El sistema propuesto ofrece una opción económica, potente y versátil para obtener señales ECG filtrada, permitiendo así contar con una señal clara y que mantiene una morfología típica de estas señales. La implementación de un Arduino para hacer uso del convertidor analógico-digital presente en la tarjeta es una opción viable para sortear el problema de la falta de un convertidor de este tipo en la Raspberry PI.

El proyecto ofrece opciones de mejora, gracias a la potencia con la que cuenta la tarjeta, es posible la implementación de un algoritmo de aprendizaje automático para la detección de variaciones en las señales ECG, aunque la eficiencia de estos algoritmos está determinada por el tipo de entrenamiento y el tipo de señales a analizar. En la actualidad existen una gran variedad de bases de datos validadas por expertos en las que se pueden encontrar distintos tipos de patologías.

V. Agradecimientos

Me gustaría extenderle un agradecimiento a la Unidad Académica de Ingeniería Eléctrica Plantel Jalpa de la Universidad Autónoma de Zacatecas, Campus Jalpa, por su contribución, con las señales generadas por el simulador para realizar la comparación de señales ECG. Especial agradecimiento a los maestros Roberto Olivera Reyna y Reynel Olivera Reyna por su trabajo obteniendo las señales del simulador y por compartir el manual del mismo. De igual forma, un agradecimiento a los doctores Jorge Ulises Muñoz Minjares y Eduardo Cabal Yopez por su guía y apoyo durante la realización de este proyecto.

Referencias

- [1] *Enfermedades cardiovasculares*. URL: <https://www.who.int/es/health-topics/cardiovascular-diseases> (visitado 03-09-2025).
- [2] Yuvaraj R et al. «Real-time fire detection and suppression system using YOLO11n and Raspberry Pi for thermal safety applications». En: *Case Studies in Thermal Engineering* 75 (nov. de 2025), pág. 107159. ISSN: 2214157X. DOI: 10.1016/j.csite.2025.107159. URL: <https://linkinghub.elsevier.com/retrieve/pii/S2214157X25014194>.
- [3] P. Casado et al. «Raspberry Pi based photovoltaic I-V curve tracer». En: *HardwareX* 11 (abr. de 2022), e00262. ISSN: 24680672. DOI: 10.1016/j.ohx.2022.e00262. URL: <https://linkinghub.elsevier.com/retrieve/pii/S2468067222000074>.
- [4] Ahmed Fathy et al. «A new implementation of the MPPT based raspberry Pi embedded board for partially shaded photovoltaic system». En: *Energy Reports* 8 (nov. de 2022), págs. 5603-5619. ISSN: 23524847. DOI: 10.1016/j.egyr.2022.04.035. URL: <https://linkinghub.elsevier.com/retrieve/pii/S2352484722007946>.
- [5] Michael Murray, Jackie McCavana y Eamon Loughman. «PyDAP: Automated dental OPG beam area measurement using python and raspberry Pi camera». En: *Physica Medica* 120 (abr. de 2024), pág. 103338. ISSN: 11201797. DOI: 10.1016/j.ejmp.2024.103338. URL: <https://linkinghub.elsevier.com/retrieve/pii/S1120179724001339>.

- [6] Matthew Michael Long et al. «PiRamid: A compact Raspberry Pi imaging box to automate small-scale time-lapse digital analysis, suitable for laboratory and field use». En: *HardwareX* 12 (oct. de 2022), e00377. ISSN: 24680672. DOI: 10.1016/j.ohx.2022.e00377. URL: <https://linkinghub.elsevier.com/retrieve/pii/S2468067222001225>.
- [7] Pradhyut Rajkumar. «Humidity and temperature monitoring using Raspberry Pi via RS232 networking». En: *Array* 27 (sep. de 2025), pág. 100464. ISSN: 25900056. DOI: 10.1016/j.array.2025.100464. URL: <https://linkinghub.elsevier.com/retrieve/pii/S2590005625000918>.
- [8] T Maragatham, P Balasubramanie y M Vivekanandhan. «IoT Based Home Automation System using Raspberry Pi 4». En: *IOP Conference Series: Materials Science and Engineering* 1055.1 (1 de feb. de 2021), pág. 012081. ISSN: 1757-8981, 1757-899X. DOI: 10.1088/1757-899X/1055/1/012081. URL: <https://iopscience.iop.org/article/10.1088/1757-899X/1055/1/012081>.
- [9] I Gusti Made Ngurah Desnanjaya e I Nyoman Alit Arsana. «Home security monitoring system with IoT-based Raspberry Pi». En: *Indonesian Journal of Electrical Engineering and Computer Science* 22.3 (1 de jun. de 2021), pág. 1295. ISSN: 2502-4760, 2502-4752. DOI: 10.11591/ijeecs.v22.i3.pp1295-1302. URL: <http://ijeecs.iaescore.com/index.php/IJECS/article/view/23937>.
- [10] Vijay Mahore et al. «Development and implementation of a raspberry Pi-based IoT system for real-time performance monitoring of an instrumented tractor». En: *Smart Agricultural Technology* 9 (dic. de 2024), pág. 100530. ISSN: 27723755. DOI: 10.1016/j.atech.2024.100530. URL: <https://linkinghub.elsevier.com/retrieve/pii/S2772375524001357>.
- [11] Prateek K. Sahu et al. «A cost-effective Raspberry Pi-based operant playback setup to evaluate auditory preferences in songbirds». En: *Behavioural Processes* (sep. de 2025), pág. 105276. ISSN: 03766357. DOI: 10.1016/j.beproc.2025.105276. URL: <https://linkinghub.elsevier.com/retrieve/pii/S037663572500138X>.
- [12] Laena D'Alton et al. «A simple, low-cost instrument for electrochemiluminescence immunoassays based on a Raspberry Pi and screen-printed electrodes». En: *Bioelectrochemistry* 146 (ago. de 2022), pág. 108107. ISSN: 15675394. DOI: 10.1016/j.bioelechem.2022.108107. URL: <https://linkinghub.elsevier.com/retrieve/pii/S1567539422000585>.
- [13] Harry C. Wright, Duncan D. Cameron y Anthony J. Ryan. «FoamPi: An open-source raspberry Pi based apparatus for monitoring polyurethane foam reactions». En: *HardwareX* 12 (oct. de 2022), e00365. ISSN: 24680672. DOI: 10.1016/j.ohx.2022.e00365. URL: <https://linkinghub.elsevier.com/retrieve/pii/S2468067222001109>.
- [14] Lorenzo Palazzetti et al. «AntPi: A Raspberry Pi based edge–cloud system for real-time ant species detection using YOLO». En: *Ecological Informatics* 91 (nov. de 2025), pág. 103383. ISSN: 15749541. DOI: 10.1016/j.ecoinf.2025.103383. URL: <https://linkinghub.elsevier.com/retrieve/pii/S1574954125003929>.
- [15] Matthew Sands y Jinki Kim. «A low-cost and open-source measurement system to determine the Young's and shear moduli and Poisson's ratio of soft materials using a Raspberry Pi camera module and 3D printed parts». En: *HardwareX* 13 (mar. de 2023), e00386. ISSN: 24680672. DOI: 10.1016/j.ohx.2022.e00386. URL: <https://linkinghub.elsevier.com/retrieve/pii/S2468067222001316>.

Dynamic Pain Analysis and Prediction of Chronicity Using Physiological Signals

Análisis Dinámico del Dolor y Predicción de la Cronificación mediante Señales Fisiológicas

José Manuel Moreno Loera*¹, Juan Manuel López Hernández¹, José Manuel López Villagómez¹, and José Francisco Estrada Segura¹

¹Universidad de Guanajuato, Campus Irapuato Salamanca
Avenida Universidad, S/N, Col. Yacatitas, Yuriria, Guanajuato, México, 38944.
{jm.morenoloera,jmlopez, jm.lopezvillagomez, jf.estradasegura}@ugto.mx

Abstract

This project aims to discover those characteristics that are most significant and sensitive to pain, helping to predict, with greater accuracy and low computational cost, a possible chronification of pain based on the physiological changes corresponding to different intensity levels of the acute stage, using the differences between pain levels in the BioVid Heat Pain database to simulate a chronification of pain through linear regression, and classifying them with a Random Forest to obtain the most representative features of chronic and acute pain. A prediction accuracy of 94% was obtained using only 14 features extracted from Electrocardiogram (ECG) and Galvanic Skin Response signals, thanks to the robustness against overfitting in small data samples that Support Vector Machines handle.

Keywords— Pain, GSR, Chronification

Resumen

Este proyecto pretende descubrir aquellas características más significativas y sensibles al dolor, que ayuden a predecir con más exactitud y con un bajo costo computacional, una posible cronificación de dolor basándose en los cambios fisiológicos respecto a los diferentes niveles de intensidad de la etapa aguda, utilizando las diferencias entre los niveles de dolor de la base de datos BioVid Heat pain para simular una cronificación del dolor con la regresión lineal y clasificándolas con un Random Forest para obtener las características más representativas del dolor crónico y agudo. Obteniendo una precisión del 94% de predicción mediante solo 14 características obtenidas de las señales de Electrocardiograma y de la Respuesta galvánica de la Piel, gracias a la robustez hacia el sobreajuste en pequeñas muestras de datos que las Maquinas de Soporte Vectorial manejan.

Palabras clave— Dolor, GSR, Cronificación

I. Introducción

El dolor se puede interpretar como alteraciones físicas involuntarias como movimientos repetitivos y semi-involuntarios sin un claro propósito y que pueden repetirse de manera idéntica en cada ocasión, indicando que algo se encuentra mal dentro del cuerpo

humano o fuera en el entorno de este [1]. Además, que suele ser una experiencia de carácter subjetivo dependiendo del grado de dolor que una persona puede tolerar. Sin embargo, existe la posibilidad de realizar mediciones objetivas y no tan invasivas del dolor mediante biosensores combinados con técnicas de Aprendizaje Automático (Machine Learning, ML por sus siglas en inglés) [2], utilizando las señales fisiológicas derivadas de la actividad

*Corresponding author

del corazón como lo son el electrocardiograma (ECG), la variabilidad de la frecuencia cardiaca (VFC), presión del volumen sanguíneo (PVS), fotopleletismografía (Photoplethysmography, PPG por sus siglas en inglés) o la señal fisiológica llamada respuesta galvánica de la piel (Galvanic Sking Response, GSR por sus siglas en inglés), la cual refleja cambios en la conductancia eléctrica de la piel mediante las glándulas sudoríparas, gracias a que se sabe que el dolor implica procesos cognitivos y qué es posible medir estos con señales fisiológicas [3].

Todas estas respuestas fisiológicas son controladas por el sistema nervioso simpático, el cual se encarga de preparar al cuerpo para acciones de respuestas rápidas ante situaciones que causen estrés o se perciban como peligrosas, siendo las señales fisiológicas la manera en la que nuestro cuerpo reacciona ante los estímulos del entorno.

Nayely Vianey Salazar Trujillo, la coordinadora del Grupo de Cuidados Paliativos del Seminario de Estudios sobre la globalidad en Pregrado de la Facultad de Medicina de la UNAM [4], mencionó que existen dos categorías fundamentales de dolor: el dolor agudo y el dolor crónico. Define que el dolor agudo es consecuencia de un daño tisular específico y su duración por lo general suele ser de menos de tres meses, cesando una vez la lesión o causa que la origina deja de producirse. Mientras que el dolor crónico se extiende de tres a seis meses, volviéndose independiente de su causa, la cual surgió como un dolor agudo desde el principio, convirtiéndose en un dolor relacionado a una posible enfermedad crónica de dolor continuo, o el dolor se vuelve episódico durante lapsos largos. Durante esta transición el sistema nervioso autónomo sufre una serie de cambios neurofisiológicos y autonómicos (alteraciones en la VFC, reactividad simpática y regulación emocional). Por lo que, analizar las diferencias entre los momentos de dolor agudo y no dolor nos permite observar cómo es que el organismo responde a estímulos nociceptivos (estímulos potencialmente dañinos para los tejidos), y determinar si la respuesta muestra patrones de disfunción o desadaptación, siendo indicativos de un riesgo de cronificación.

Diferenciar entre un dolor crónico y uno agudo puede ser clave para la salud del paciente ya que, de acuerdo con el Instituto Nacional de Geriátrica [5], en 2018 realizó una investigación donde estimaron que cuatro de cada diez personas mayores en México sufren de dolor crónico y más de la mitad de las personas que fallecieron dentro del país registraron un dolor crónico en su último año de vida. Además de que un reciente estudio realizado por científicos en Reino Unido comprobó que el dolor crónico puede aumentar el riesgo de padecer presión arterial alta [6]. Analizaron casos de 206,000 adultos de entre 40 a 69 años durante 13 años, si bien las respuestas fueron mediante autoevaluación y de una sola vez, pudieron relacionar que el dolor crónico generó depresión en los

pacientes, y a su vez la depresión permitió que desarrollaran presión arterial alta, donde el 10 % de ellos desarrolló hipertensión. A su vez detectaron que el dolor afectaba de diferente manera dependiendo de su localización en el cuerpo, descubriendo que el dolor crónico distribuido por todo el cuerpo se asoció a un 75 % más de riesgo de desarrollar presión arterial alta comparado con los que no presentaron dolor, mientras que el dolor concentrado en el abdomen incrementa el riesgo solo en un 43 %.

En 2019, la Organización Mundial de la Salud (OMS) realizó la actualización de la Clasificación Internacional de Enfermedades (CIE-11), donde el dolor crónico se clasificó en siete grupos [7]:

1. Dolor crónico primario: Se caracteriza por una discapacidad funcional (interferencia en las actividades de la vida diaria) o estrés emocional no explicable, planteándose como una enfermedad por sí misma.
2. Dolor crónico por cáncer: Siendo un dolor propio del cáncer o que se origina por el tratamiento para combatirlo.
3. Dolor crónico postquirúrgico o postraumático: Aparece o aumenta luego de un procedimiento quirúrgico que puede persistir más allá del proceso de curación.
4. Dolor crónico neuropático: Aparece cuando se presenta una lesión o enfermedad en el sistema nervioso somatosensorial (a nivel periférico o central). Presentando una reacción exagerada a un estímulo doloroso (hiperalgesia), o una reacción dolorosa ante un estímulo que no debería causar dolor (alodinia).
5. Dolor bucofacial o cefalea: Malestares ubicados en la cara y que lastiman la cavidad oral por falta de limpieza o daños en las estructuras que conectan la mandíbula. Con una duración de al menos 2 horas por día.
6. Dolor visceral crónico: De origen dudoso y se desarrolla en los órganos internos de las cavidades torácica, abdominal y pélvica, además de la región de la cabeza o cuello.
7. Dolor crónico musculoesquelético secundario: Dolor que surge de los huesos, articulaciones, músculos, columna vertebral, tendones o tejidos blandos. Producido por espontaneidad o por un movimiento.

Tomando en cuenta el grupo 2 de la CIE-11, en otro estudio que se realizó a pacientes con cáncer [8] se demostró que, mientras la enfermedad progresaba, el dolor también lo hacía, generando un dolor constante, e irónicamente el dolor ayudaba a empeorar la salud del paciente, no solo por la enfermedad si no por el dolor en sí.

El síndrome de Takutsu o síndrome del corazón roto es una cardiomiopatía aguda que se caracteriza por el repentino y temporal debilitamiento del músculo del corazón, debido a estrés emocional o físico y que causa dolor en el pecho [9], este síndrome es bastante peligroso, así

como el dolor torácico no traumático, el cual es una de las razones más frecuentes de visitas médicas de emergencia, que podría bien desencadenar en una isquemia cardíaca, la cual es causada por la reducción del suministro de sangre al corazón [10]. En este caso, el dolor torácico perteneciente al grupo 6 de la CIE-11 se caracteriza por episodios recurrentes del mismo, originando un dolor crónico conocido como angina de pecho estable, y que desaparece durante el reposo o administración de medicamentos. En casos como la isquemia cardíaca es importante el tiempo de reacción para tratarla, y para ello es preciso detectar lo antes posible sus patrones ya conocidos, dónde visualmente se sabe que durante cualquier tipo de esfuerzo físico, estrés o frío aparece el dolor torácico, mientras que mediante la señal fisiológica de ECG se pueden apreciar igualmente patrones típicos como el descenso del segmento ST (1-3 mm) de la señal durante el esfuerzo físico, o la inversión simétrica de la onda T después de la experiencia. Esto por mencionar un ejemplo de lo que el dolor crónico podría ocasionar ya que, si no se trata, el dolor agudo puede convertirse en dolor crónico.

Estudios previos han desarrollado sistemas que incorporan señales fisiológicas multimodales, incluyendo videograbaciones de las expresiones faciales de los participantes [11, 12], el problema de estos sistemas es su poca practicidad a la hora de implementarlos en los entornos cotidianos. Derivado de esto, se buscó una manera menos invasiva pero igualmente eficiente, destacando las señales ECG y GSR por su fácil incorporación a dispositivos portátiles más ergonómicos para el usuario como los relojes inteligentes Google Pixel Watch 2 y 3 [13], los cuales ya pueden medir el pulso cardíaco en la muñeca y la actividad electrodérmica (EDA) de la piel, la cual incluye ya a las señales GSR. Además, en [14] utilizaron las señales ECG, GSR y las Electromiografías (EMG) utilizando también la base de datos BioVid, construyeron diferentes modelos de Machine Learning, incluidos el modelo de Regresión Lineal, Regresión de Soporte Vectorial (RSV), Redes Neuronales y el de Aumento Extremo de Gradiente. Esto con el fin de seleccionar el modelo que mejor pudiera predecir la intensidad del dolor dentro de los 4 niveles que la base Biovid maneja, obteniendo los mejores resultados con el modelo de RSV utilizando solo 3 características de las señales GSR, que fueron las que más información importante proporcionaron para la estimación de los niveles de intensidad. Logrando entre todos los resultados, un error medio absoluto (Mean Absolute Error, MAE por sus siglas en inglés) de 0.93.

La mayoría de los trabajos realizan una clasificación binaria [15], es decir, dolor o no dolor, limitando el fenómeno gradual y subjetivo que es el dolor, sin capturar como es que el dolor evoluciona con el tiempo ni su posible transición hacia la cronificación. Estudios previos han

demostrado que, durante el dolor agudo, la frecuencia cardíaca aumenta y la amplitud del PPG disminuye [16], obteniendo una sensibilidad (o recall en inglés) del 60 % y en especificidad (verdaderos negativos) un 72 %.

En sujetos sin cronificación, se espera que a mayor intensidad de dolor haya un cambio fisiológico que sea proporcional, dónde el sistema nervioso reacciona a cada incremento del estímulo de dolor. Pero en el caso contrario de que una persona presente una posible cronificación, significa que los cambios fisiológicos dejaron de responder a las variaciones de intensidad, interpretándose como una desensibilización central, dónde el sistema nervioso se mantiene en un estado constante de activación, sin importar si el estímulo incrementa o no.

Por lo que en este trabajo de investigación busca encontrar las características que mejor describan la relación entre las características fisiológicas y el dolor, mediante la regresión lineal. Para posteriormente descubrir las características más determinísticas durante el proceso de dolor agudo como del dolor crónico mediante un algoritmo más complejo para características no tan lineales como lo es el Random Forest, que se ha demostrado relaciona de una manera eficiente señales fisiológicas con respuestas cognitivas [17]. Y finalmente evaluar con una Máquina de Soporte Vectorial (Support Vector Machine, SVM por sus siglas en inglés) para evitar las redundancias ya que las SVM controlan mejor el sobreajuste que se pudiera dar por la pequeña cantidad de los datos.

II. Metodología

Para el análisis de los diferentes grados de dolor, así como de la simulación de una posible cronificación, se utilizó la base de datos BioVid [18]. Este conjunto de datos se compone de 87 sujetos de entre 18 – 65 años, seleccionados mediante un proceso que contempló que cumplirían con un buen estado de salud, principalmente que no tuvieran alguna enfermedad dermatológica, neurológica y sin trastornos del dolor crónico, no tomar medicamentos que alteraran la percepción del dolor, no consumir alcohol antes de la sesión, tener piel íntegra en la zona del antebrazo donde se aplicaría el calor, y claramente ser voluntario, además de firmar en consentimiento informado aprobado por el comité de ética de la Universidad pública Alemana Ulm. Además, se excluyeron casos en dónde el sujeto padecía de diabetes, problemas cardiovasculares importantes, enfermedades psiquiátricas graves, piel sensible, problemas de termorregulación o fiebre, o que tuviera algún historial de epilepsia.

A los participantes se les indujo dolor mediante calor en el antebrazo derecho controlado por un termode Peltier, en este caso el Thermode TSA-II. El protocolo consistió en identificar primeramente el nivel térmico de cada participante antes de comenzar el registro de

la base de datos, en donde cada participante evaluó el dolor que sentían en ciertas temperaturas para ajustar las mismas mediante un método de calibración adaptativa. Logrando así una compensación para la sensibilidad de cada individuo, es decir, adaptar los distintos niveles de temperatura a nivel individual para provocar la misma intensidad de dolor en todos los participantes, y así evitar un posible daño tisular en algún sujeto que soportase un menor grado de temperatura que otro. Obteniendo 4 niveles de intensidad (PA1 – PA4, y BL1) de entre 32 – 48°C dependiendo de los participantes, pero sin ser peligroso o intolerable, PA1 que representa la menor intensidad de dolor, seguido de PA2, PA3 y PA4, dónde este último representa la intensidad más alta de dolor, además cuenta con una línea base tomada como cero inducciones de dolor llamada BL1. Cada intensidad de dolor fue estimulada 20 veces durante 4 segundos de calor aplicado y pausas de 8 a 12 segundos, utilizadas para extraer BL1. La intensidad de dolor se designó a partir de una autoevaluación a los sujetos previamente, para determinar el umbral de tolerancia al dolor soportada por cada uno, evitando así daños perjudiciales. La base de datos se compone de 4 partes (A, B, C, y D), en dónde la obtención de datos que se midieron fueron las señales fisiológicas EEG, ECG, GSR, además de videograbaciones de las expresiones faciales de los sujetos, entre otras señales fisiológicas más, pero para el desarrollo de este trabajo, solo se utilizaron las señales ECG y GSR de la parte A del conjunto de datos, así como estudios previos la han utilizado [11, 19].

II.1. Extracción de características

Se extrajeron las características principales de ECG más representativas del índice parasimpático RMSSD, PNN50, SDNN [3], entre otras. Así como también de la señal GSR a cada sujeto de manera individual.

Además, se utilizaron las 22 características canónicas de series de tiempo llamadas Catch22 [20], extraídas de una librería extensa llamada hctsa con 7,658 características de series de tiempo posibles, siendo las 22 características más relevantes que capturan las propiedades más importantes de datos temporales, como la autocorrelación, distribución de valores y patrones de fluctuación. Utilizando estas características para representar de manera más compacta y útil para tareas de clasificación, agrupamiento o detección de anomalías, además de que genera un menor coste computacional. Evaluaron el desempeño individual de cada característica de que tan bien permite distinguir clases, evaluadas en 93 conjuntos de datos diferentes de la base UEA/UCR obteniendo así un criterio general.

Las señales GSR, a diferencia de las señales ECG tienen una dinámica lenta y transitoria, es perfecta para aplicarse directamente las 22 características canónicas de

series de tiempo por lo que se ha decidido utilizar estas características específicamente para esta señal.

II.2. Regresión Lineal Y Random Forest

Puesto que se quiere observar si el modelo es capaz de detectar una posible falta de adaptabilidad al dolor (cronificación), se utiliza un método de regresión lineal entre las derivadas temporales (deltas) de los 4 niveles de dolor principales (PA1, PA2, PA3 y PA4), esto con el fin de simular una tendencia a una posible cronificación.

Debido a que la ausencia de la relación lineal entre los incrementos de la intensidad del dolor y las variaciones fisiológicas, se interpretan como una disminución de la sensibilidad del sistema nervioso autónomo ante los estímulos nociceptivos. Por lo que el patrón plano con tendencia a cero que se aprecia en la Figura 1, sugiere una posible cronificación del proceso de dolor, ya que las respuestas fisiológicas dejan de ajustarse ante la percepción del dolor.

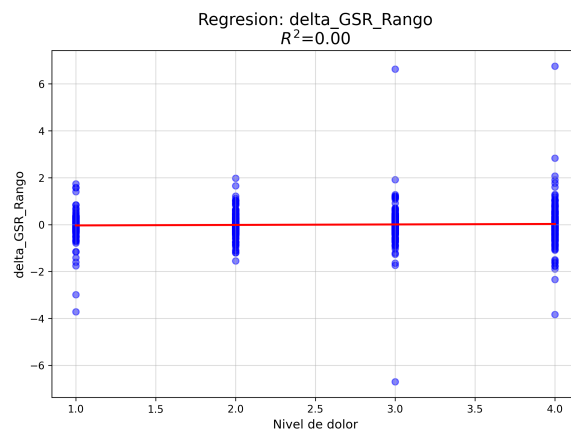


Figura 1: Regresión Lineal aplicada a las diferencias entre los niveles de dolor (PA4-PA3, PA3-PA2, PA2-PA1, PA1-BL), determinando no linealidad, es decir igual a falta de adaptabilidad al dolor.

Todas las características utilizadas, sin excepción demostraron esta tendencia a cero, sin embargo, como se aprecia en la Figura 2, se obtuvo una lista de características de las señales más sensibles al dolor mediante el método de la Importancia basada en Reducción de Impureza de Random Forest, el cual toma cada característica (RMSSD, SDNN, etc) por separado en sus nodos, las divide utilizando la medida Gini Impurity determinando que tantas mezclas de clases o impurezas hay en el nodo, para conseguir el nodo más puro posible o que separe mejor las clases con cada división. A pesar de no representar una importancia bastante alta (el valor 1.0 se toma como el más alto en la gráfica y por ende significa que hay una relación bastante directa, pero en la Figura 2 se aprecia que el valor máximo alcanzado es 0.04), aún logran captar diferencias sutiles en las etapas de dolor.

Otorgando la mayor información posible dentro de un sistema con poca variabilidad fisiológica.

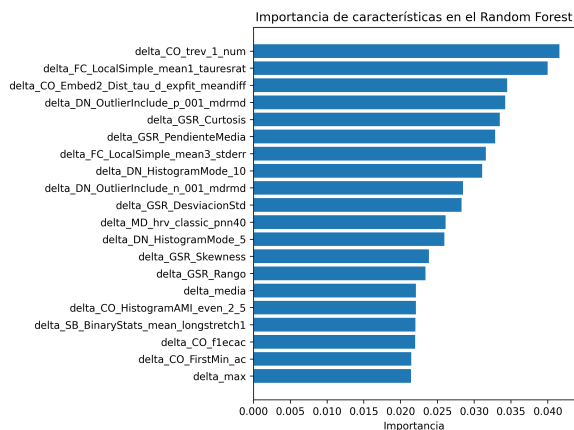


Figura 2: Lista de características más sensibles al dolor crónico.

El mismo procedimiento se realizó con las diferencias entre los niveles de dolor y no dolor (baseline). Detectando una tendencia entre cada uno, mostrado en la Figura 3.

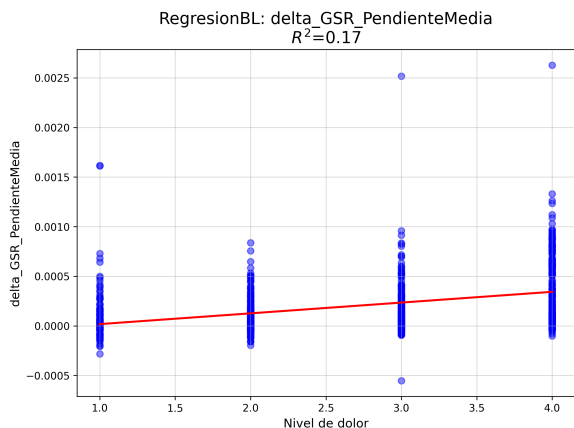


Figura 3: Regresión Lineal aplicada a los niveles de dolor respecto al baseline (PA4-BL1, PA3-BL1, PA2-BL1, PA1-BL1) demostrando la linealidad de cero dolor a las diferentes intensidades, demostrando el dolor agudo.

En esta etapa si existe una relación lineal clara, demostrando la diferencia de cada nivel de dolor, posteriormente se aplicó un Random Forest para obtener las características de manera no lineal que mejor representan esta etapa, buscando las mismas o la mayoría de las características que se obtuvieron en la Figura 2. Obteniendo las siguientes características de la Figura 4.

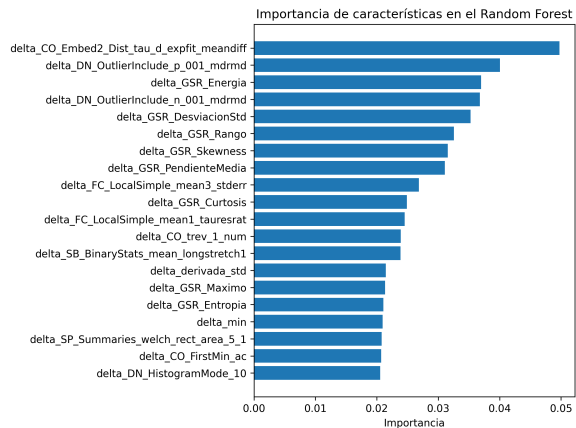


Figura 4: Lista de características más sensibles al dolor agudo.

III. Resultados

Se puede apreciar que tanto en la Figura 2 como en la Figura 4 existen ciertas características similares dentro de las 20 más relevantes, aunque con diferente nivel de importancia. En la Tabla 1 se colocaron las características compartidas por ambas clases de dolor que se encuentran tanto en la Figura 2 como en la Figura 4, con el fin de utilizar esas características para clasificar correctamente ambas clases de dolor, ya que son las que presentaron un nivel de sensibilidad más alto.

Tabla 1: Características compartidas

Num	Agudo y Cronificación
1	delta_CO_trev_1_num
2	delta_FC_LocalSimple_mean1_taresrat
3	delta_CO_Embed2_Dist_tau_d_expfit_meandiff
4	delta_DN_OutlierInclude_p_001_mdmd
5	delta_GSR_Curtosis
6	delta_GSR_PendienteMedia
7	delta_FC_LocalSimple_mean3_stderr
8	delta_DN_HistogramMode_10
9	delta_DN_OutlierInclude_n_001_mdmd
10	delta_GSR_DesviacionStd
11	delta_GSR_Skewness
12	delta_GSR_Rango
13	delta_SB_BinaryStats_mean_longstretch1
14	delta_CO_FirstMin_ac

El comportamiento de las 14 características en ambos estados es diferente, en el dolor agudo, suelen comportarse con transiciones rápidas y asimétricas, picos altos, varianza elevada. Mientras que en el dolor crónico son fluctuaciones más lentas y menos asimétricas, de activación sostenida, presenta menos picos, periodos planos más largos y patrones repetitivos.

Dando la pauta para analizar específicamente esas listas y determinar si existe cronificación o no. Además de demostrar que la señal GSR es mucho más relevante que la ECG, por lo que el sistema puede simplemente

utilizar la señal GSR, reduciendo el costo computacional de manera eficiente.

Por lo tanto, al encontrar las mismas características con valores distintivos cuando es un dolor agudo o cuando es un dolor crónico, se obtiene la ventaja de que, al analizar las características, estas serán las mismas siempre, por ello se tomaron las 14 características compartidas de la Tabla 1 para evaluar su predicción a pesar de sus bajos puntajes de importancia.

En [15] se realizó un marco de trabajo multimodal utilizando también solo señales EDA y ECG, el cual incluye un proceso combinado de los modelos de Redes Convolucionales Completas y Memoria a Corto y Largo plazo (Long Short-Term Memory, LSTM por sus siglas en inglés) con mecanismo de atención. Consiguiendo una precisión del 87.52 % utilizando la base Biovid, pero solo comparando de manera binaria entre No dolor y Dolor intenso. Si bien no se menciona las características que los llevaron a obtener esos resultados, [14] analizó las 3 mejores características de EDA o GSR que le otorgaron su mejor predicción otorgándole un 83.30 % de precisión, las cuales también obtuvimos dentro de las más importantes:

1. delta_CO_Embed2_Dist_tau_d_expfit_meandiff.
2. delta_DN_OutlierInclude_p_001_mdrmd.
3. delta_DN_OutlierInclude_n_001_mdrmd.

III.1. Evaluación con SVM

Para determinar si las características pueden separar de manera correcta el dolor agudo del dolor crónico, se propuso como evaluador el modelo de SVM, separando los datos de entrenamiento a 80 % y prueba 20 %, específicamente con las 14 características de la Tabla 1. Para ello las diferencias obtenidas previamente en la regresión lineal se juntaron en un mismo conjunto, conformando dos grupos compuestos por los mismos sujetos, unos pertenecientes al dolor crónico simulado y otros pertenecientes al dolor agudo detectado, tal como se muestra en el ejemplo de la Tabla 2.

Tabla 2: Conjunto de datos de dolor crónico y dolor agudo para entrenar el modelo SVM

Sujeto	Tipo
Sujeto01	Agudo
Sujeto01	Crónico
Sujeto02	Agudo
Sujeto02	Crónico

Al probar el rendimiento de la SVM se obtuvo un resultado bastante alto con el conjunto de pruebas del 20 %, que en este caso fueron 18 sujetos evaluados, resultando

en la matriz de confusión de la Figura 5, donde las filas conforman las clases verdaderas y las columnas las clases clasificadas, demostrando que el modelo logró clasificar 16 de 18 casos de dolor agudo correctamente y en el dolor crónico identificó correctamente a los 18 sujetos. Demostrando una sensibilidad del 88.9 % y especificidad del 100 % en la clase de dolor agudo y en la clase del dolor crónico se logró una sensibilidad del 100 % pero una especificidad del 88.9 % debido a los 2 falsos negativos que presentó la clase del dolor agudo. Los cuales pueden deberse a que las señales fisiológicas de esos dos participantes presenten picos fuera de lo común (outliers) y por ello sus respuestas no son similares a las del resto del grupo, tal como se mostró en la Figura 3, donde se puede apreciar que en los Niveles 1.0, 3.0 y 4.0 la característica GSR_PendienteMedia presenta una actividad más alta de un sujeto.

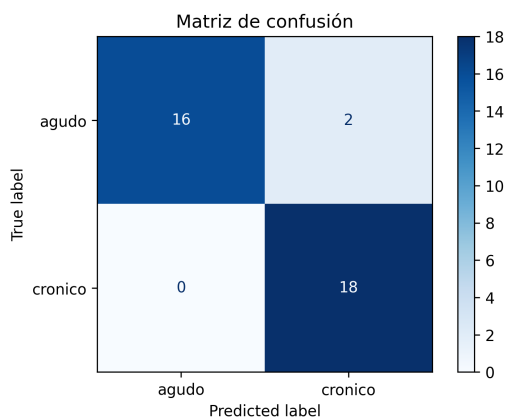


Figura 5: Matriz de confusión del desempeño del modelo SVM

En la Tabla 3 se muestra un desglose más específico de las métricas de nuestro modelo. Obteniendo una precisión de clasificación del modelo en general (accuracy) del 94 %.

Tabla 3: Desglose de las métricas que evalúan el desempeño del modelo SVM en el conjunto de prueba

Nombre	precision	Sensibilidad	Especificidad	F1-Score
Agudo	1.00	0.89	1.0	0.94
crónico	0.90	1.00	0.89	0.95
accuracy	0.94			

Mientras que en la Tabla 4 se comparan con los trabajos que mejores resultados han obtenido utilizando la base de datos Biovid para la detección del dolor agudo. En el

caso de [14], sus resultados no se dividen en Especificidad y Sensibilidad, por lo que solo podemos comparar la precisión (accuracy), además [15] realiza una comparación de otros modelos en su trabajo, siendo el suyo el que mejor resultados da con la combinación de señales ECG y GSR. Y en dónde nuestro modelo logró superarlo en el desempeño de predicción del dolor agudo.

Tabla 4: Comparación de resultados de trabajos

Referencia	Método	Accuracy	Sensibilidad	Especificidad	F1 Score
Pouromran	SVR	0.83			
Farmani	CrossMod Transformer	0.87	0.84	0.89	0.87
Este trabajo	SVM	0.94	0.89	1.0	0.94

IV. Conclusiones y Discusión

Se observó una mayor respuesta a la sensibilidad del dolor con las señales GSR, predominando más que las señales ECG, al igual que los trabajos presentados en la Tabla 4, dónde se utilizaron casi las mismas características, solo que en nuestro caso utilizamos 14 y no solo 3 lo que nos aportó más información a la hora de realizar la clasificación.

La regresión lineal nos permitió comprender y obtener de una manera más entendible la relación que las características desempeñan en cada etapa de dolor, además nos permitió crear un entorno de simulación para experimentar una cronificación simulada sin exponer a pacientes que sufren de dolor crónico real. Aunque en este trabajo no se realizó una discriminación por tipo de enfermedad crónica, es importante mencionar algunas de las relaciones que las características obtenidas tienen con algunas enfermedades, para tomar en cuenta en un posible trabajo futuro (Nota: el nombre de las características se sustituyó por el orden numérico de la Tabla 1):

1. Fibromialgia: Trastorno crónico que se caracteriza por el dolor muscular generalizado y la fatiga; los patrones que se presentan en algunas de las 14 características de acuerdo con [21] son:
 - a) (10): variabilidad alta.
 - b) (11): distribución menos simétrica.
 - c) (1): asimetría en transiciones.
2. Artritis reumatoide: Enfermedad donde el sistema inmune ataca a las articulaciones; los patrones que

se presentan en algunas de las 14 características de acuerdo con [22] son:

- a) (6): tendencia estable pero sostenida.
- b) (8): valores basales elevados.
- c) (14): autocorrelación mayor (patrones repetidos).
- d) (13): segmentos largos estables.

3. Dolor lumbar crónico: Dolor que persiste en la parte baja de la espalda por más de 3 meses; los patrones que se presentan en algunas de las 14 características de acuerdo con [23] son:

- a) (10): variabilidad moderada.
- b) (11): distribución más simétrica (pocos picos).
- c) (6): tendencia suave.
- d) (1): transiciones menos abruptas.

Posteriormente al utilizar Random Forest, se logró una mejor clasificación de las características, ya que estas al provenir de sistemas biológicos regulados por retroalimentaciones múltiples, es decir, fluctuaciones caóticas causadas por variaciones de los latidos, ruido por movimiento o respiración de los participantes, no son lineales y son muy complejas, por lo que el modelo de Random Forest fue perfecto para este caso ya que cada árbol de decisión crea divisiones del espacio de las características basándose en umbrales. Lo que lo convierte en un método bastante robusto al ruido fisiológico.

Finalmente la inclusión de la SVM maximizó el margen entre las dos diferentes clases de dolor manejadas con las pocas características utilizadas, ayudando a identificar los cambios más sutiles de cada característica y evitando el sobre ajuste que se pudiera dar si se utilizaran otros modelos de clasificación que requieren de más muestras como el Random Forest, al cual se le entrenó con el conjunto de datos completo y nos simplificó a las pocas características que posteriormente la SVM se encargó de evaluar, esto con el fin de evitar posibles redundancias.

Si bien los resultados en general, son buenos, la muestra de 86 sujetos y el corto tamaño de las ventanas de tiempo de 5.5 segundos que nos proporciona la base de datos Biovid no son suficientes para poder generalizar características que son bastante subjetivas, por depender de la persona, su actividad física, su alimentación, su edad (ya que tanto la actividad cardíaca como la electrodérmica tienden a responder más lento a mayor edad), su temperamento, su resistencia mental al dolor, que si bien el rango de edad es bastante amplio (18 — 65 años) son muchas las variables que pueden influir en cada persona de cada edad, y tomando en cuenta que solo se obtuvieron datos de 86 sujetos, eso quiere decir que si se tuviera que tomar mínimo una persona de cada edad, máximo solo podrían evaluar a 2 personas por edad.

Aunado a lo anterior, también se tiene que tomar en cuenta que la muestra es obtenida de personas completamente sanas, por lo que un reto sería determinar a una persona con alguna enfermedad como diabetes, que suelen tener la presión alta.

Por lo que la propuesta a futuro sería utilizar este modelo entrenado en hospitales o clínicas particulares aprovechando el equipo de registro de señales ECG y GSR que manejan, para corroborar si el algoritmo detecta correctamente la clase a la que el paciente pertenece, pero enfocándonos en aquellos con un diagnóstico de dolor crónico, y dependiendo de la evaluación determinar si el modelo funciona, mediante el diagnóstico previo del propio paciente.

Si el modelo predice correctamente la presencia del dolor crónico, el siguiente paso consistiría en almacenar esas características extraídas del paciente para analizarlas más clínicamente y observar los cambios específicos en cada una de ellas, ampliando así el modelo para lograr predecir qué tipo de enfermedad crónica es la presentada, y no solo demostrar si existe cronificación o no. Sin embargo, en el caso de que el modelo no lograra detectar con precisión si se trata de un dolor crónico o agudo, se tendrá que contemplar crear una base de datos nueva ahora si con pacientes reales que sufren de algún dolor crónico. Claramente se tendría que realizar un protocolo donde solo se monitorearán señales ECG y GSR, el cual contemplará realizar el proceso de obtención de datos mediante los propios instrumentos de las clínicas o mediante un reloj inteligente como el Google Pixel Watch, sin estímulos inducidos de manera artificial, solo realizar movimientos o acciones que, de ser posible, le intensifiquen el dolor y tomar esas muestras por un lapso de 10 minutos máximo dentro de la clínica o de ser posible, tomar una muestra de 24 horas de su día cotidiano para obtener más robustez y posteriormente presentar el protocolo ante un comité de ética, en el cual estos mismos pacientes que fueron evaluados erróneamente por el modelo puedan participar de manera voluntaria. En la Figura 6 se muestra a manera de diagrama de flujo, el procedimiento a llevarse a cabo para el posible trabajo a futuro.

Referencias

- [1] P. Silva y R. Sebastião, «Using the Electrocardiogram for Pain Classification under Emotional Contexts,» *Sensors*, vol. 23, p. 1443, January 2023.
- [2] B. D. Winslow, R. Kwasinski, K. Whirlow, E. Mills, J. Hullfish y M. Carroll, «Automatic detection of pain using machine learning,» *Frontiers in Pain Research*, vol. 3, November 2022.
- [3] P. Nicolini, G. Malfatto y T. Lucchi, «Heart Rate Variability and Cognition: A Narrative Systematic Review

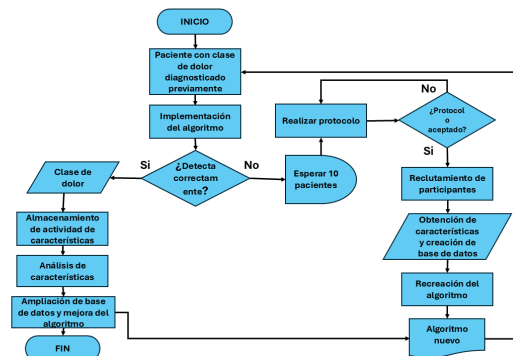


Figura 6: Diagrama de flujo de un posible trabajo futuro

of Longitudinal Studies,» *Journal of Clinical Medicine*, vol. 13, p. 280, January 2024.

[4] P. Herrera y D. Rojas, Dolor crónico, un problema subestimado - UNAM Global — unamglobal.unam.mx, 2024.

[5] «Boletín INGER - Diciembre 2018,» calameo.com. [Online]. Available: <https://www.calameo.com/read/00547996024f658fa5fec>

[6] P. Qin, F. K. Ho, C. A. Celis-Morales y J. P. Pell, «Chronic Pain and Hypertension and Mediation Role of Inflammation and Depression,» *Hypertension*, November 2025.

[7] OMS, Clasificación Internacional de Enfermedades Undécima Revisión (CIE-11), Ginebra: Organización Mundial de la Salud, 2022.

[8] S. Moscato, P. Cortelli y L. Chiari, «Physiological responses to pain in cancer patients: A systematic review,» *Computer Methods and Programs in Biomedicine*, vol. 217, p. 106682, April 2022.

[9] G. La Vecchia, L. Leo, A. M. Leone y R. A. Montone, «When chest pain is not what it seems: time for right diagnosis and right treatment—a case report,» *European Heart Journal - Case Reports*, vol. 9, August 2025.

[10] C. A. Swenne y C. C. ter Haar, «Context-independent identification of myocardial ischemia in the prehospital ECG of chest pain patients,» *Journal of Electrocardiology*, vol. 82, p. 34–41, January 2024.

[11] P. Werner, A. Al-Hamadi, R. Niese, S. Walter, S. Gruss y H. Traue, «Automatic Pain Recognition from Video and Biomedical Signals,» 2014.

[12] M. Kächele, P. Thiam, M. Amirian, P. Werner, S. Walter, F. Schwenker y G. Palm, «Multimodal Data Fusion for Person-Independent, Continuous Estimation of Pain Intensity,» de *Engineering Applications of Neural Networks*, Springer International Publishing, 2015, p. 275–285.

[13] Especificaciones técnicas de Pixel Watch 3, modelos de 45 mm y 41 mm. [Online]. Available: https://store.google.com/es/product/pixel_watch_3_specs?hl=es

[14] F. Pouromran, S. Radhakrishnan y S. Kamarthi, «Exploration of physiological sensors, features, and machine learning models for pain intensity estimation,» PLOS ONE, vol. 16, p. e0254108, July 2021.

[15] J. Farmani, G. Bargshady, S. Gkikas, M. Tsiknakis y R. F. Rojas, «A CrossMod-Transformer deep learning framework for multi-modal pain detection through EDA and ECG fusion,» Scientific Reports, vol. 15, August 2025.

[16] D. F. Jhang, Y. S. Chu, J. H. Cai, Y. Y. Tai y C. C. Chuang, «Pain Monitoring Using Heart Rate Variability and Photoplethysmograph-Derived Parameters by Binary Logistic Regression,» Journal of Medical and Biological Engineering, September 2021.

[17] T. Boljanić, N. Miljković, L. B. Lazarevic, G. Knezevic y G. Milašinović, «Relationship between electrocardiogram-based features and personality traits: Machine learning approach,» Annals of Noninvasive Electrocardiology, vol. 27, November 2021.

[18] S. Walter, S. Gruss, H. Ehleiter, J. Tan, H. C. Traue, S. Crawcour, P. Werner, A. Al-Hamadi y A. O. Andrade, «The biovid heat pain database data for the advancement and systematic validation of an automated pain recognition system,» de 2013 IEEE International Conference on Cybernetics (CYBCO), 2013.

[19] P. Werner, A. Al-Hamadi y S. Walter, «Analysis of facial expressiveness during experimentally induced heat pain,» de 2017 Seventh International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW), 2017.

[20] C. H. Lubba, S. S. Sethi, P. Knaute, S. R. Schultz, B. D. Fulcher y N. S. Jones, «catch22: CAnonical Time-series CHaracteristics: Selected through highly comparative time-series analysis,» Data Mining and Knowledge Discovery, vol. 33, p. 1821–1852, August 2019.

[21] G. A. Reyes del Paso y P. de la Coba, «Reduced activity, reactivity and functionality of the sympathetic nervous system in fibromyalgia: An electrodermal study,» PLOS ONE, vol. 15, p. e0241154, October 2020.

[22] R. Badry, R. M. Gamal, M. M. Hassanien, M. A. El Hamed, N. Hammam y B. M. El Fawal, «Sympathetic skin response in patients with systemic sclerosis and rheumatoid arthritis,» The Egyptian Journal of Neurology, Psychiatry and Neurosurgery, vol. 54, November 2018.

[23] A. Bonnet y J. Naveteur, «Electrodermal Responses to Words in Chronic Low Back Pain Patients: A Comparison Between Pain Descriptors, Other Emotional Words, and Neutral Words,» The Clinical Journal of Pain, vol. 22, p. 686–691, October 2006.

Classification of Pitayo Plant Varieties Using Multispectral Images

Clasificación de variedades de planta de pitayo usando imágenes multiespectrales

Rodrigo Rivera-Romero ^{*1}, Rosa Janette Pérez-Chimal ¹, Claudia Angélica Rivera-Romero ^{2,3}, Jorge Ulises Muñoz-Minjares ², Hayde Peregrina-Barreto ³, Humberto Pérez-Espinosa ³, and Iván Alfonso Reyes-Portillo ²

¹ Universidad Autónoma de Zacatecas, Unidad Académica de Ingeniería Eléctrica, Posgrado en Ingeniería para la Innovación Tecnológica, Ramón López Velarde # 801, Centro, Zacatecas, Zac., México, 98000.

{r.rivera, r.perez}@uaz.edu.mx

² Universidad Autónoma de Zacatecas, Unidad Académica de Ingeniería Eléctrica, Plantel Jalpa, Libramiento Jalpa Km., Fraccionamiento Solidaridad, Jalpa, 156+380, Jalpa, Zac., 99601, México.

{c.a.riveraromero, ju.munoz}@uaz.edu.mx

³ Instituto Nacional de Astrofísica, Óptica y Electrónica, Coordinación de Ciencias Computacionales, Luis Enrique Erro #1, Tonantzintla, Puebla, México, 72840.

{hperegrina, humbertop}@inaoep.mx, ivan.reyes@upslp.edu.mx

Abstract

This study addresses the classification of *Stenocereus queretaroensis* (pitayo) varieties according to fruit color using multispectral images obtained with a DJI Mavic 3M drone. A dataset with spectral features was built to train five machine learning models. The best results were achieved with the Decision Tree and Logistic Regression models, reaching an accuracy of 70%, demonstrating that the integration of multispectral imagery, NDVI, and artificial intelligence represents a promising tool for agricultural monitoring and the characterization and classification of plants.

Keywords— *Stenocereus queretaroensis*, multispectral imaging, vegetation indices, color spaces, NDVI images

Resumen

Este estudio aborda la clasificación de variedades de *Stenocereus queretaroensis* (pitayo) según el color del fruto mediante imágenes multiespectrales obtenidas con un dron DJI Mavic 3M. Se construyó un conjunto de datos con características espectrales para entrenar cinco modelos de aprendizaje automático. Los mejores resultados se lograron con el Árbol de Decisión y la Regresión Logística, alcanzando una exactitud del 70 %, evidenciando que la integración de imágenes multiespectrales, NDVI e inteligencia artificial son herramientas prometedoras para el monitoreo agrícola y la caracterización de plantas.

Palabras clave— *Stenocereus queretaroensis*, imágenes multiespectrales, índices de vegetación, espacios de color, imágenes NDVI

I. Introducción

El cultivo de *Stenocereus queretaroensis* (pitayo) ha despertado un creciente interés por su valor comercial, su potencial agroindustrial y su notable adaptación a climas semiáridos.

Diversos estudios han contribuido al entendimiento de esta especie desde perspectivas ecológicas, fisiológicas y tecnológicas. En [1] evaluaron el potencial reproductivo de esta especie en parcelas del municipio de Tabasco, Zacatecas, determinando que su éxito reproductivo depende de la disponibilidad de agua y de condiciones ambientales específicas, lo cual aporta bases para su conservación

* Autor de correspondencia

y aprovechamiento. Por su parte, en [2] analizaron fenotipos de pitaya de distintos colores, destacando que las variedades rojas presentan mejores atributos de firmeza y peso, lo que refuerza la importancia de la caracterización morfológica y físico-química para la selección de ejemplares.

Otros autores, como [3], estudiaron la composición química de los frutos de *Stenocereus thurberi*, evidenciando que el color del fruto se asocia con su contenido mineral y antioxidante. De manera complementaria, en [4] enfatizaron la viabilidad del cultivo de *S. queretaroensis* en regiones áridas y su potencial para la agricultura sostenible con bajos insumos de agua y energía. En el ámbito tecnológico, en [5] se exploró el uso del dron DJI Mavic 3 Multispectral para la generación de índices espectrales como NDVI (Índice de Vegetación de Diferencia Normalizada), NDRE y NDWI, demostrando la capacidad de estas herramientas para evaluar la salud de la vegetación mediante sensores multispectrales.

Asimismo, en [6] aplicaron esta tecnología al monitoreo de cultivos de papa, logrando identificar condiciones de estrés y deficiencias nutricionales a partir de imágenes RGB y NIR. Estos estudios evidencian el potencial de los drones y la teledetección multispectral en la agricultura de precisión. En cuanto a la caracterización del fruto, en [7] analizaron pigmentos y antioxidantes en tres variedades de *S. queretaroensis*, relacionando sus propiedades químicas con su valor nutricional. Finalmente, en [8] desarrollaron un sistema de clasificación de frutos de café mediante procesamiento digital de imágenes, obteniendo un 96.88 de precisión, lo que demuestra la eficacia de las técnicas de visión artificial y el aprendizaje automático en la clasificación agrícola.

En conjunto, estos antecedentes respaldan la necesidad de aplicar herramientas de visión computacional y análisis espectral en el estudio del pitayo. La identificación del color del fruto representa un desafío de ingeniería relevante, ya que las diferencias entre variedades no son perceptibles en etapas juveniles. Por lo tanto, el objetivo de este trabajo es desarrollar un modelo de clasificación temprana de variedades de *Stenocereus queretaroensis* en función del color de su fruto, utilizando imágenes RGB y NDVI obtenidas mediante la cámara multispectral de un dron y procesadas con técnicas de aprendizaje automático.

En este trabajo, se presentan los primeros resultados derivados del análisis de imágenes multispectrales para la identificación de las variedades de las plantas de *Stenocereus queretaroensis*. En esta propuesta se trabajó con imágenes multispectrales NDVI, RED y NIR generadas por software propietario del dispositivo de captura y la generación de nuevas imágenes NDVI creadas por el procesamiento con imágenes RED y NIR. Por estos medios, se extrajeron las características espectrales formadas con los



Figura 1: Cultivo de plantas de pitayo y la distribución de las plantas para la adquisición de las imágenes multispectrales por planta.

valores de los píxeles de las imágenes para lograr diferenciar las variedades de plantas. Estas características fueron probadas con cinco modelos de aprendizaje automático, de los cuales dos modelos destacaron por su desempeño y estabilidad, alcanzando niveles de exactitud cercanos al 70 % en los escenarios de clasificación binaria. Con estos resultados se evidencia que la información multispectral constituye una herramienta prometedora para el manejo de plantas y su caracterización entre variedades.

II. Metodología

El desarrollo de este estudio se estructuró en etapas que permitieron abordar de forma sistemática la clasificación de variedades de pitayo a partir de imágenes multispectrales.

II.1. Muestreo y adquisición de las imágenes multispectrales

El estudio se realizó en un huerto ubicado en la comunidad de Guadalupe Victoria, municipio de Jalpa, Zacatecas, México (21.717515° N, 102.976155° W), a una altitud aproximada de 1,750 m s.n.m. El sitio presenta un clima semiárido, con temperaturas que oscilan entre 20 y 33 °C. El huerto cuenta con un total de 143 plantas de *Stenocereus queretaroensis*, de las cuales se seleccionaron 109 ejemplares para el muestreo, considerando su estado de desarrollo y salud. Estas tienen una edad aproximada de cuatro años y presentan una distribución equilibrada de las tres variedades de fruto que se buscan identificar: rojo, naranja y amarillo. En la Figura 1, se presenta la imagen general del huerto y la vista aérea de la misma, donde se aprecia la disposición e identificación de cada planta seleccionada para el estudio.

Las imágenes se capturaron utilizando un dron DJI Mavic 3M [9], equipado con una cámara RGB de 20 megapíxeles con sensor CMOS de 4/3" y un sistema multispectral formado por cuatro cámaras independientes que registran información en las bandas verde (560 nm), roja (650 nm), borde rojo (730 nm) e infrarrojo cercano o NIR (860 nm) de una forma estática a una distancia




Figura 2: Procedimiento de captura de cada planta de pitayo, considerando la altura en función de una distancia promedio (1 a 4 metros) para lograr obtener la imagen completa del pitayo.

del pitayo. Lo que permite la adquisición simultánea de imágenes en espacio de color RGB e imágenes multiespectrales de alta resolución. Estas características permiten el análisis de las plantas para el cálculo de índices de vegetación, como el NDVI entre otros y el estudio de la variabilidad espectral entre variedades de plantas basados en el color de fruto.

El muestreo se realizó mensualmente de enero a mayo, bajo condiciones adecuadas de iluminación. Debido a las diferencias en altura y desarrollo entre las plantas de *Stenocereus queretaroensis*, la distancia del dron respecto a cada planta se ajustó individualmente, con el propósito de mantener una vista perpendicular y un campo de visión uniforme en todas las capturas. Cabe mencionar que el dron no se utilizó en vuelo autónomo, sino como plataforma estacionaria de captura, posicionándolo manualmente a distintas alturas y orientaciones según las características de cada ejemplar. Como se muestra en la Figura 2, la toma de imágenes se efectuó del lado iluminado de cada planta y a una altura media entre la base y la parte superior, garantizando una representación completa de su estructura y la homogeneidad espacial de las imágenes adquiridas.

El software del dron DJI Mavic 3M genera automáticamente composiciones del NDVI a partir de las bandas espectrales capturadas por el sensor multiespectral. Estas composiciones, junto con las imágenes RGB, se muestran en la Figura 3, la cual presenta los diferentes tipos de imágenes proporcionadas por el sistema del dron (RGB, Verde, Rojo, Borde Rojo, NIR y NDVI automático).

Además, se realizó el cálculo del NDVI mediante procesamiento digital de imágenes, utilizando las bandas NIR y Roja obtenidas por el sensor multiespectral. El cálculo del NDVI se basa en la ecuación 1 [10].




Figura 3: Imágenes generadas por el dron DJI Mavic 3M: RGB, NDVI automático, Verde (Green), Infrarrojo Cercano (NIR), Rojo (Red) y Borde Rojo (RedEdge).

$$\text{NDVI} = \frac{(\text{NIR} - \text{Red})}{(\text{NIR} + \text{Red})} \quad (1)$$

donde NIR representa la reflectancia en la banda del infrarrojo cercano y corresponde a la reflectancia en la banda roja del espectro visible. El valor resultante de NDVI varía entre -1 y $+1$, donde los valores cercanos a -1 indican superficies sin vegetación o con baja actividad fotosintética, y los valores próximos a $+1$ reflejan alta densidad vegetal y vigor biológico. Por lo tanto, se obtuvo un nuevo conjunto de datos complementario basado en el cálculo del NDVI para obtener valores por píxel de forma independiente a los datos generados por el dron. La Figura 4 muestra una comparación visual entre el NDVI generado automáticamente por el sistema del dron y el NDVI calculado mediante procesamiento digital, en la que se aprecia una mayor variación en el contraste espectral y una mayor riqueza de información radiométrica en el método personalizado. Esta comparación permitió evaluar la calidad espectral y la precisión espacial entre ambos enfoques, además de ampliar la base de datos empleada en los análisis de clasificación y caracterización de las plantas.

II.2. Región de interés y extracción de características

Se identificaron tres puntos principales, considerando las regiones de interés (región basal o tallo, región media y región superior) en cada una de las plantas de pitayo. Se extrajo un punto de interés central de cada imagen NDVI generada, definido como un nuevo conjunto de datos. Estos datos se consideraron como nuevas características principales de las imágenes [11]. Esta distribución permitió representar diferencias estructurales verticales y capturar variaciones espectrales asociadas al desarrollo y densidad del tejido vegetal. Los valores espectrales de cada punto (base, medio y superior) fueron extraídos




Figura 4: a) Imagen NDVI con las regiones de interés para identificar los puntos centrales de cada región en formato JPG generado por el software del dron, b) imagen NDVI calculada con los puntos de interés en formato TIFF, obtenido mediante la ecuación basada en las bandas NIR y Rojo del sistema multiespectral.

y almacenados en otro nuevo conjunto de datos junto con el identificador de la planta y variedad y el tipo de imagen (NDVI automático y NDVI calculado). La Figura 4 muestra la ubicación de las regiones de interés (ROIs) en las imágenes NDVI, donde se aprecian los puntos específicos correspondientes a cada zona estructural de las plantas.

A partir del muestreo realizado entre enero y mayo, se registraron 109 ejemplares de *Stenocereus queretaroensis*, de los cuales 72 correspondieron a la variedad roja, 22 a la variedad naranja y 15 a la variedad amarilla. Con el propósito de equilibrar el número de muestras por clase y garantizar un análisis estadístico uniforme, se implementó un proceso de aumento de datos (data augmentation en inglés) para las variantes con menor representación. Este procedimiento consistió en extraer múltiples puntos dentro de las mismas ROIs de cada planta de pitayo, preservando la representatividad espectral del ejemplar y ampliando el conjunto de datos sin introducir ruido o redundancia significativa. De este modo, se homogenizó la cantidad de registros para las tres categorías de color consideradas (rojo, amarillo y naranja), en todas las imágenes NDVI.

Con los puntos extraídos se generó un nuevo conjunto de datos integrando el identificador de la planta (variedad de color), el tipo de imagen y los valores de los píxeles extraídos de cada ROI. Esta organización facilitó el manejo posterior de la información y la trazabilidad del proceso. A partir de este punto el procesamiento de los datos se efectuó mediante dos métodos diferenciados según el tipo de imagen:

- **Método 1.** De las imágenes NDVI generadas por software, los valores obtenidos dentro de cada ROI se encontraban en formato RGB, teniendo como base estos valores y con el propósito de analizar la influencia del espacio de color en la respuesta espectral y mejorar la sensibilidad de los clasificadores, se efectuaron conversiones a distintos espacios de color,

transformando las imágenes desde el formato RGB hacia HSV (Hue, Saturation, Value), CIE Lab* (Luminosidad, eje verde, eje azul), YCbCr (Luminancia y componentes de crominancia) y escala de grises [12]. Posteriormente, los valores en escala de grises fueron reescalados linealmente conforme a la ecuación 2, la cual permite convertir un rango discreto de intensidad (por ejemplo, 0–255 o 0–180) al intervalo normalizado de NDVI entre -1 y +1. Finalmente, se aplicó una normalización general de tipo reescalado lineal sobre los valores derivados de cada espacio de color (Figura 5), con el fin de escalar todas las variables al mismo rango de comparación y evitar sesgos en el proceso de entrenamiento de los modelos de clasificación [10].

$$NDVI = 2 \times \left(\frac{I - \min}{\max - \min} \right) - 1 \quad (2)$$

donde I representa el valor de intensidad del píxel en escala de grises, mientras que \min y \max son los valores mínimo y máximo posibles en la escala original correspondientes a las ROIs base, medio y superior.

- **Método 2.** En el segundo enfoque, correspondiente a las NDVI calculadas, los valores obtenidos de las imágenes derivadas de las bandas NIR y Roja ya se encontraban en escala de grises, por lo que se aplicó la misma ecuación de normalización para mantener la consistencia entre ambos conjuntos de datos (Figura 6). Este método permitió obtener valores NDVI independientes del procesamiento automático del dron, proporcionando un control más preciso sobre la calibración radiométrica y la respuesta espectral por píxel.

En las figuras 5 y 6 se muestran los diagramas esquemáticos del procesamiento y extracción de características aplicado a las imágenes multiespectrales para cada método. En el Método 1, se ilustra el flujo correspondiente a las NDVI automáticas, que incluye la conversión de RGB a escala de grises y la transformación a valores NDVI, y la conversión a diferentes espacios de color HSV, CIE Lab y YCbCr [13]. En el Método 2, se representa el proceso aplicado a las imágenes NDVI calculadas, donde los valores se derivan directamente de las bandas multiespectrales originales mediante la ecuación estándar (ecuación 1).

Finalmente, todos los valores NDVI resultantes fueron normalizados y organizados en un conjunto de datos final, para su integración en diferentes modelos de aprendizaje automático. Los datos multimodales generados con el Método 1, se sometieron a un proceso de normalización para homogeneizar las escalas de los datos, minimizar el sesgo entre conjuntos y garantizar la estabilidad de los clasificadores empleados en las etapas posteriores de análisis.



Figura 5: Metodología para la adquisición de datos multimodales con las imágenes en diferentes espacios de color y las imágenes NDVI automáticas (Método 1).




Figura 6: Metodología para la adquisición de datos de las imágenes NDVI calculadas mediante las imágenes NIR y Rojo (Método 2).

II.3. Modelos de aprendizaje automático

Para el entrenamiento y evaluación de los nuevos conjuntos de datos, se propone el uso de modelos de aprendizaje automático de forma binaria como una primera fase de prueba experimental para los datos generados con el Método 1, con la finalidad de identificar las variedades de las plantas de pitayo de acuerdo al color de fruto. Para estos modelos, se propuso una división del conjunto de datos, de un 80 % de las muestras para el entrenamiento y validación y el 20 % restante para las pruebas, para garantizar la representatividad proporcional de cada una de las clases de color. Se emplearon cinco algoritmos de clasificación supervisada ampliamente utilizados en problemas de reconocimiento de patrones descritos a continuación.

- El algoritmo KNN clasifica las muestras en función de la distancia euclidiana entre vectores de características, asignando la clase predominante entre los k vecinos más cercanos. Este método no requiere una fase de entrenamiento compleja, pero su desempeño depende significativamente de la selección óptima del parámetro k y del tipo de métrica utilizada [12, 14].
- Las Máquinas de Soporte Vectorial (SVM) construyen hiperplanos de separación que maximizan el margen entre clases, utilizando funciones kernel (lineal, polinómico o radial) para proyectar los datos en espacios de mayor dimensión cuando las fronteras no son linealmente separables. Su robustez y capacidad de generalización las hacen adecuadas para conjuntos de datos con alta dimensionalidad [15, 12].

- El método Random Forest (RF) combina múltiples árboles de decisión entrenados de manera aleatoria sobre subconjuntos del conjunto de datos, integrando sus predicciones mediante votación. Este enfoque de aprendizaje por ensamble mejora la estabilidad y reduce la varianza del modelo, ofreciendo un equilibrio entre precisión y resistencia al sobreajuste (overfitting en inglés) [15, 16].
- La Regresión Logística (LR), aunque originalmente desarrollada para problemas binarios, se adapta eficazmente a clasificación multiclase mediante estrategias de one-vs-all en inglés. Modela la probabilidad de pertenencia de una muestra a una clase específica utilizando la función sigmoide, lo que permite interpretar los resultados de forma probabilística [17, 18].
- El Árbol de Decisión (DT) genera una estructura jerárquica de decisiones mediante reglas de partición basadas en medidas de pureza como la ganancia de información o el índice Gini. Este modelo es intuitivo, de fácil interpretación y útil para identificar las variables más influyentes en el proceso de clasificación [19, 20].

Los modelos obtenidos fueron comparados según su precisión y capacidad de generalización, con el propósito de identificar el algoritmo con mejor desempeño en la clasificación de las variedades de *Stenocereus queretaroensis*.

II.4. Evaluación de desempeño de los modelos

El rendimiento de los clasificadores se evaluó utilizando métricas estándar del aprendizaje supervisado, como la exactitud (accuracy en inglés), la precisión (precision en inglés), sensibilidad (recall en inglés) y puntuación F1 (F1-score en inglés). Cada una de estas métricas indica la eficacia del modelo: i) accuracy: cuantifica la proporción de predicciones correctas respecto al total de observaciones, ii) precision: mide la exactitud de las predicciones positivas, es decir, qué porcentaje de los elementos clasificados como positivos son realmente correctos, iii) recall: evalúa la capacidad del modelo para identificar correcta-

Tabla 1: Métricas de evaluación de los modelos de clasificación, dónde se definen del cálculo de las matrices de confusión considerando los valores de *TP* - verdaderos positivos, *TN* - verdaderos negativos, *FP* - falsos positivos, *FN* - falsos negativos.

Parámetro	Fórmula
Accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$
Precision	$\frac{TP}{TP + FP}$
Recall	$\frac{TP}{TP + FN}$
F1-score	$2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$

mente todos los elementos positivos reales, y iv) F1-Score: combina la precisión y recall en una media armónica que refleja el equilibrio entre ambos. Las fórmulas correspondientes y la descripción de los parámetros involucrados se presentan en la Tabla 1, la cual resume las métricas utilizadas para la evaluación cuantitativa del desempeño de los modelos de clasificación.

Adicionalmente, se calculó la matriz de confusión, para tener una representación bidimensional que presenta los aciertos (verdaderos positivos) y errores (verdaderos negativos) por clase, facilitando el análisis detallado del comportamiento del modelo al clasificar por variedad de planta con base al color del fruto (fruto rojo, fruto amarillo y fruto naranja). Estos parámetros permiten cuantificar la exactitud global, la sensibilidad por clase y la consistencia entre las clases predichas y las clases reales.

Los procedimientos descritos permitieron generar los primeros resultados de clasificación con el conjunto de datos generador con el Método 1 como una primer fase experimental. Entre los resultados, se busca una base sólida con el uso de los modelos de aprendizaje automático para determinar su aplicabilidad en la identificación de variedades de pitayos.

III. Resultados

Se realizaron tres procesos de clasificación binaria para las combinaciones de colores amarillo–naranja, amarillo–rojo y naranja–rojo, con el propósito de evaluar la capacidad de los modelos entrenados a partir de los valores NDVI y los espacios de color. Entre los resultados obtenidos, la clasificación amarillo–naranja presentó el desempeño más equilibrado y estable en comparación con las otras dos combinaciones, por lo que se seleccionó como caso representativo para el análisis visual y la interpretación de las métricas de desempeño.




Figura 7: Matriz de confusión del modelo de Regresión Logística para la clasificación binaria amarillo–naranja.




Figura 8: Matriz de confusión del modelo de árbol de decisión (Decision Tree) para la clasificación binaria amarillo–naranja.

En la Figura 7 se presenta la matriz de confusión del modelo Árbol de Decisión (Tree en inglés), donde se observa una distribución equilibrada de aciertos en ambas clases. El modelo logró una correcta identificación de la mayoría de las muestras amarillas y naranjas, mostrando una proporción similar de verdaderos positivos y negativos.

Por su parte, la Figura 8 muestra la matriz de confusión del modelo de Regresión Logística, que también alcanzó resultados satisfactorios, aunque con una ligera reducción en la precisión respecto al modelo Árbol de Decisión. En ambos casos, los errores de clasificación se concentraron en las muestras con valores espectrales intermedios, lo que indica una posible superposición entre las características de ambas variedades.

La Figura 9 presenta las curvas ROC (Receiver Operating Characteristic en inglés) correspondientes a los clasificadores evaluados. Estas curvas permiten visualizar la relación entre la tasa de verdaderos positivos (TPR) y la tasa de falsos positivos (FPR) para distintos umbrales de decisión. Un mayor área bajo la curva (AUC) representa un mejor desempeño del modelo. En este caso, los clasificadores Árbol de Decisión y Regresión Logística




Figura 9: Curvas ROC (Receiver Operating Characteristic) y AUC (Area Under curve), métricas para evaluar la capacidad de un modelo de clasificación binaria. El resultado es un rendimiento aleatorio aproximado para los modelos de regresión logística y el árbol de decisión.

exhibieron las curvas más próximas al vértice superior izquierdo, lo que refleja una mejor capacidad de discriminación entre las clases amarillo y naranja en comparación con los demás algoritmos.

La Figura 10 muestra la comparación general de métricas de clasificación (Accuracy, Precision, Recall y F1-Score) obtenidas por los diferentes métodos supervisados. De manera general, los modelos Árbol de Decisión y Regresión Logística mantuvieron valores más altos en todas las métricas, evidenciando un equilibrio entre la cantidad de aciertos totales y la capacidad de detección de cada clase. En contraste, los métodos KNN, SVM y RF presentaron mayores variaciones entre precisión y sensibilidad, lo que indica que su desempeño fue más dependiente de la distribución espectral de las muestras.

En cuanto a las otras dos clasificaciones binarias (amarillo-rojo y naranja-rojo), los resultados mostraron un comportamiento menos equilibrado, con una mayor tendencia del modelo a clasificar correctamente solo una de las dos clases. En particular, las muestras de color rojo fueron las que presentaron mayor confusión con las naranjas, posiblemente debido a la similitud de sus respuestas espectrales en las bandas visibles y del infrarrojo cercano.

Estos resultados confirman que la separación entre las clases amarillo-naranja representa el escenario más adecuado para el análisis comparativo de los clasificadores y la validación del sistema de identificación de variedades.

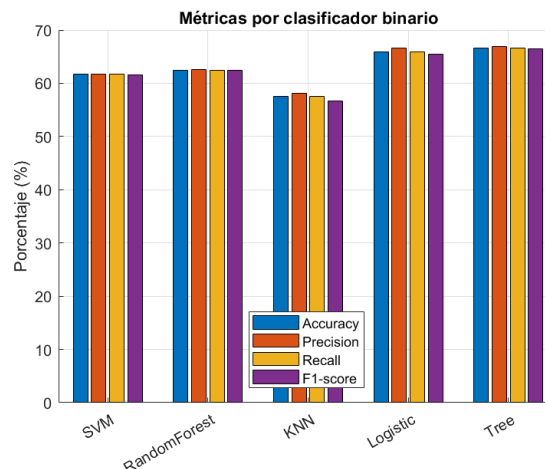


Figura 10: Comparación de las métricas de desempeño (Accuracy, Precision, Recall y F1-Score) para los modelos de clasificación evaluados.

IV. Conclusión

Este estudio demostró la utilidad de caracterizar las imágenes multiespectrales para su uso con modelos de aprendizaje supervisado para la identificación de variedades de *Stenocereus queretaroensis* (pitayo) en función del color del fruto. Mediante la integración de información multimodal con valores en diferentes espacios de color y un índice de vegetación, es posible discriminar entre variedades de plantas, lo cual puede ser de apoyo también para determinar otras condiciones en las plantas.

Los modelos de Árbol de Decisión y Regresión Logística alcanzaron los mejores resultados, con una exactitud cercana al 70 %, evaluada con métricas como el F1-score y recall. Esto demuestra que los métodos estadísticos y basados en árboles pueden capturar adecuadamente patrones espectrales en etapas de desarrollo de las plantas.

En el trabajo a futuro se busca mejorar estos resultados, aumentando el número de experimentos y ampliando el conjunto de datos multimodales con el cálculo de más índices de vegetación partiendo de las imágenes en la banda verde, rojo, borde y NIR. Entre las limitaciones observadas en esta primera fase, el tamaño del conjunto de datos y las condiciones controladas de captura que restringieron algunos parámetros a definir de forma constante dentro de las condiciones experimentales, como el tamaño de las plantas y el cuidado controlado en los escenarios agrícolas más complejos. Por lo tanto, en este primer reporte, el enfoque se centró sólo en la clasificación binaria de las variedades disponibles.

Como trabajo futuro, se propone ampliar el conjunto de datos incorporando variabilidad y distintos estados fenológicos de la planta en desarrollo, esto con la finalidad de hacer un diagnóstico de enfermedades o plagas,

así como extender el análisis a un enfoque multiclase. Además, es posible integrar por medio de las imágenes características morfológicas, patrones binarios o de textura, con base al análisis de regiones de interés para buscar mejores características.

Adicionalmente, se busca validar los modelos en condiciones reales de campo y avanzar hacia el desarrollo de sistemas automatizados de monitoreo, que sirvan como herramientas de apoyo en la domesticación y mejoramiento genético de la planta del pitayo, para lograr su cuidado y protección así como su reproducibilidad, siendo un cultivo endémico de alto consumo y valor agroindustrial.

Agradecimientos

La Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) financió esta investigación mediante el proyecto de la Convocatoria de Ciencia de Frontera con el identificador CF-2023-I-2021. Además, agradecemos por las becas de maestría y doctorado, otorgadas a Rodrigo Rivera-Romero (No. CVU 1017277) y a Rosa Jannette Pérez Chimal (No. CVU 290119), respectivamente.

V. Referencias

Referencias

- [1] O. Solís-Márquez et al. «Potencial reproductivo de *Stenocereus queretaroensis* (Cactaceae) de San José de Cosalima, Zacatecas». En: *Revista Mexicana de Biodiversidad* 89.2 (2018), págs. 553-563.
- [2] Eduardo Campos-Rojas et al. «Evaluación de plantas de pitaya (*Stenocereus* spp) de poblaciones naturales de Monte Escobedo, Zacatecas». En: *Revista Chapingo. Serie Horticultura* 17.3 (2011), págs. 245-252. ISSN: 1027-152X.
- [3] Jeny Hinojosa-Gómez y María D. Muy-Rangel. «Caracterización fisicoquímica y compuestos bioactivos en los frutos de pitaya (*Stenocereus thurberi*) de cuatro colores». En: *TIP. Revista especializada en ciencias químico-biológicas* 26 (2023), e561.
- [4] Eulogio Pimienta-Barrios et al. «Ethnobotany, Productivity, and Ecophysiology of Pitaya (*Stenocereus queretaroensis*)». En: *Journal of the Professional Association for Cactus Development* 2 (1997), págs. 29-47.
- [5] Oren Nardi. *Developing High-Resolution Spectral Indices from Mavic 3M Multispectral Imagery*. Remote sensing study at Cal Poly Humboldt using DJI Mavic 3M. 2024.
- [6] Viviana A. Berrío, Jemay T. Mosquera y Diego F. Alzate. «Uso de drones para el análisis de imágenes multiespectrales en agricultura de precisión». En: *@LIMENTECH, Ciencia y Tecnología Alimentaria* 13.1 (2015), págs. 28-40. ISSN: 1692-7125.
- [7] Chelsy Denise Gutiérrez Valdivia, Jacinto Bañuelos Pineda y Lucía Barrientos Ramírez. «Extracción, cuantificación y caracterización de betacianinas y betaxantinas en pulpa de tres variedades de pitaya (*Stenocereus queretaroensis* (Weber) Buxb)». En: *AGRIS* (2020).
- [8] Zulma Sandoval y Flavio Prieto. «Procesamiento de imágenes para la clasificación de café cereza». En: *Prospectiva* 7.1 (2009), págs. 67-73. ISSN: 1692-8261.
- [9] DJI. *DJI Mavic 3M – Specifications*. Accessed: 2025-10-15. DJI. 2025. URL: <https://enterprise.dji.com/mavic-3-m/specs>.
- [10] J. W. Rouse et al. «Monitoring vegetation systems in the Great Plains with ERTS». En: *Third Earth Resources Technology Satellite-1 Symposium*. Vol. 1. NASA SP-351. Washington, D.C.: NASA, 1974, págs. 309-317.
- [11] Libao Zhang y Shiyi Wang. «Region-of-Interest Extraction Based on Local-Global Contrast Analysis and Intra-Spectrum Information Distribution Estimation for Remote Sensing Images». En: *Remote Sensing* 9.6 (2017), pág. 597. DOI: 10.3390/rs9060597.
- [12] Claudia Angélica Rivera-Romero et al. «Recognition in the early stage of powdery mildew damage for cucurbits plants using spectral signatures». En: *Biosystems Engineering* 252 (2025), págs. 144-158. ISSN: 1537-5110.
- [13] Claudia Angélica Rivera-Romero et al. «Early-Stage Identification of Powdery Mildew Levels for Cucurbit Plants in Open-Field Conditions Based on Texture Descriptors». En: *Inventions* 9.1 (2024). ISSN: 2411-5134.
- [14] Nouf Alhassoun et al. «Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications made to enhance the exact kNN techniques». En: *Journal of Big Data* 11.1 (2024), págs. 1-36.
- [15] Trevor Hastie, Robert Tibshirani y Jerome Friedman. «A comprehensive comparison of random forests and support vector machines». En: *Statistics and Computing* 9.3 (2009), págs. 1-20.

- [16] H. Chen et al. «Comparative Analysis of Logistic Regression, Gradient Boosted Trees, Support Vector Machine, and Random Forest». En: *International Journal of Nutritional Research and Development* (2023).
- [17] Zhou Zhang et al. «Comparison between traditional logistic regression and machine learning models for clinical predictions». En: *Frontiers in Medicine* 11 (2024), pág. 1496869.
- [18] Maher Maalouf. «Logistic regression in data analysis: An overview». En: *International Journal of Data Analysis Techniques and Strategies* 3.3 (2011), págs. 281-299.
- [19] Haoran Liu et al. «Decision trees: from efficient prediction to responsible AI». En: *Nature Machine Intelligence* 5 (2023), págs. 611-619.
- [20] Danladi Moses Mienye y Nober T Jere. «A Survey of Decision Trees: Concepts, Algorithms and Applications». En: *International Journal of Computer Science and Information Security* 21.6 (2023), págs. 1-12.

Estimation of the CARI Vegetation Index from Spectral Signatures of *Stenocereus queretaroensis* in Southern Zacatecas

Estimación del índice de vegetación CARI a partir de firmas espectrales del *Stenocereus queretaroensis* en el sur de Zacatecas

R.J. Pérez-Chimal¹, CA Rivera-Romero², R. Rivera-Romero¹, and JU Muñoz-Minjares^{*2}

¹ *Universidad Autónoma de Zacatecas, Posgrado en Ingeniería para la Innovación Tecnológica, Carr. Zacatecas-Guadalajara Km. 6, Zacatecas, Zacatecas, México. C.P. 98160. {r.perez, r.rivera}@uaz.edu.mx*

² *Universidad Autónoma de Zacatecas, Unidad Académica de Ingeniería Eléctrica Plantel Jalpa, Fraccionamiento Solidaridad, Jalpa, Zacatecas, México. C.P. 99600. {c.a.riveraromero, ju.munoz}@uaz.edu.mx*

Abstract

This work addresses the lack of protocols for estimating vegetation indices in *Stenocereus queretaroensis*, a species of ecological and productive importance in southern Zacatecas. The objective was to analyze its spectral response over several months to identify indices capable of distinguishing physiological states and growth stages. Spectral signatures were collected in the field using a portable spectrophotometer from January to June, evaluating 109 plants. As a result, calculations of the CARI vegetation index are presented, showing differences associated with chlorophyll and carotenoid content, confirming its usefulness as a reliable indicator.

Keywords— Spectrophotometry, Vegetation indices, *Stenocereus* spp., Spectral signatures

Resumen

En este trabajo se aborda la falta de protocolos para la estimación de índices de vegetación en *Stenocereus queretaroensis*, especie de importancia ecológica y productiva en el sur de Zacatecas. El objetivo fue analizar su respuesta espectral durante varios meses para identificar índices capaces de diferenciar estados fisiológicos y etapas de crecimiento. Se recolectaron firmas espectrales en campo con un espectrofotómetro portátil, de enero a junio, evaluando 109 plantas. Como resultado se presentan los cálculos del índice de vegetación CARI que presenta las diferencias asociadas al contenido de clorofila y carotenoides, confirmando su utilidad como indicadores fiables.

Palabras clave— Espectrofotometría, Índices de vegetación, *Stenocereus* spp., Firmas espectrales

I. Introduction

Light is a fundamental factor for vegetation. When solar radiation reaches a plant, a portion is absorbed by pigments and cellular structures, another portion is transmitted through the tissues [1], and a fraction is reflected outward. These optical processes

particularly: absorption, transmission, and reflectance, describe the physical interactions between plants and electromagnetic radiation. Plants reflect and absorb radiation differentially according to their physiological and biochemical status. For example, within the visible spectrum, reflectance may vary around 400–450 nm (blue), 500–550 nm (green), or 600–700 nm (red), while in the near-infrared region (NIR; 700–900 nm) reflectance

* Autor de correspondencia

typically increases due to leaf internal structure. The relationship between the intensity of radiation reflected at each spectral band constitutes the spectral signature, which enables the characterization of physiological and structural properties of vegetation [2].

The spectral signatures analysis not only allows for understanding the fundamental optical processes in plants but also opens the possibility of applying them to species of ecological and productive interest. The interpretation of reflectance across different wavelengths becomes a key tool for identifying the physiological state of plants and, consequently, for designing non-invasive monitoring strategies [3]. In this context, it is important to focus attention on species such as cacti of the genus *Stenocereus spp.*, whose environmental and economic significance demands more precise and systematized characterization methods.

In Mexico, the genus *Stenocereus spp.* includes cactus species characterized by their resistance to extreme temperature conditions, low water requirements, and fruits with high mineral content and antioxidant properties [4, 5]. However, the phenological monitoring of *Stenocereus queretaroensis* shows limitations that have hindered its systematic study. Among the main challenges are the absence of standardized protocols for the physiological characterization of this species, the variability in spectral response associated with different developmental stages, and the difficulty of assessing tissue condition without resorting to destructive methods [6]. These limitations restrict the possibility of conducting accurate evaluations under controlled conditions, highlighting the need to develop non-invasive and reproducible methodologies for its analysis.

Altogether, the interaction of light with plant tissues, the potential of spectral signatures, and the relevance of the genus *Stenocereus spp.* emphasize the need to establish methodological strategies that enables a more precise and non-invasive analysis of its physiology. Establishing standardized protocols will not only contributes to the scientific understanding of these species but will also provides applicable tools for sustainable management, conservation, and productive use of their resources.

This study examines the temporal variation of the spectral response of *Stenocereus queretaroensis* with the aim of calculating vegetation indices that enables non-invasive assessment of its physiological status. In addition, a phenological classification approach based on spectral signatures is developed to identify changes and growth stages under controlled conditions. The working hypothesis proposes that specific indices derived from spectral signatures can reliably discriminate among the different physiological states of *Stenocereus queretaroensis*, thereby providing a robust tool for its monitoring.

II. Literature Review

II.1. Spectral Reflectance

Spectral reflectance is a key optical property of plants and refers to the fraction of electromagnetic radiation reflected at different wavelengths of the spectrum (Equation 1). This phenomenon is fundamental for studying vegetation health and physiological condition, as different plant organs—such as leaves, stems, and flowers—reflect varying proportions of light depending on their structural and biochemical characteristics [7]. In reflectance studies, broad-spectrum incident light is typically used, focusing on specific wavelength ranges such as the visible and near-infrared regions [8].

$$R = \frac{I_r}{I_i} \quad (1)$$

where R represents the spectral reflectance (expressed as a percentage or on a scale from 0 to 10), I_r is the intensity of light reflected by the sample, and I_i is the intensity of the incident light on the sample [9].

Reflectance in vegetation is influenced by a wide range of internal and external factors. Internal factors includes leaf structure, maturity, pigmentation, nutritional status, anatomy, and water content; while external factors involves solar exposure, phyllotaxy, and the presence of diseases [8, 10]. In [8] emphasized the importance of pigment composition, leaf anatomy, and environmental conditions such as turgor and evapotranspiration, all of which directly affect the reflectance signal.

The study of spectral reflectance has become essential in precision agriculture, as it enables the evaluation of crop health, species identification, and biodiversity monitoring [11]. Each plant exhibits a unique spectral pattern depending on its physiological condition or growth stage: healthy green plants typically show higher reflectance in the near-infrared region and lower reflectance in the red band, while stressed plants display the opposite pattern [12].

II.2. Spectral Signatures

Spectral signatures represents the characteristic pattern of absorption, reflection, and transmission of electromagnetic radiation by a material, acting as a distinctive “fingerprint” that allows for its identification and characterization. In plants, these signatures are influenced by chemical composition and physiological status, resulting in variations in reflectance related to chlorophyll, water, and other pigments [13]. They are commonly represented graphically, illustrating the relationship between wavelength and reflected intensity (Figure 1).

Spectral signatures are powerful tools in vegetation studies because they make it possible to assess plant

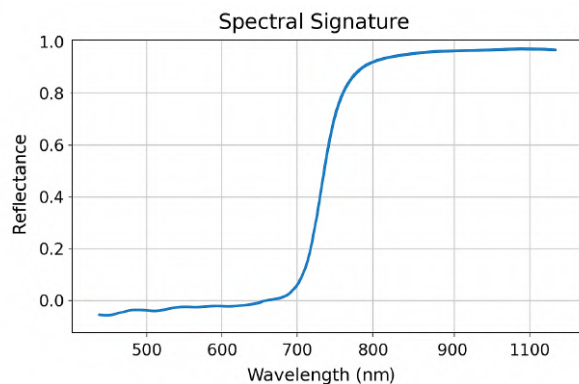


Figure 1: Graphical representation of a spectral reflectance signature.

health, detect diseases, estimate water content, identify species, and analyze environmental stress effects. Their acquisition is carried out using instruments such as spectrometers and radiometers [14]. A healthy plant typically presents a pronounced peak in the green band and high reflectance in the near-infrared region, whereas a stressed plant exhibits reduced infrared reflectance and greater red reflectance [15, 12]. These differences provide valuable information about physiological processes without the need for destructive sampling.

II.3. Vegetation Indices

Vegetation indices are mathematical formulations designed to exploit the information derived from the optical properties of plants. By combining reflectance values from specific spectral bands, these indices allow precise and non-invasive estimation of parameters such as chlorophyll content, plant vigor, photosynthetic activity, and water status [16]. Among the most widely used indices are NDVI, EVI, SAVI, GNDVI, and NDRE (Table 1). Their application in agriculture, ecology, and environmental conservation enables non-destructive monitoring of crops, early detection of water or nutrient deficiencies, and timely decision-making for sustainable management [17, 3, 18].

The protection and cultivation of endangered plant species, along with the application of remote sensing in precision agriculture, have become strategic areas aimed at optimizing resources, ensuring food security, and preserving biodiversity [27, 28].

III. Methodology

The studied cultivation site is located along the road to Guadalupe Victoria in the municipality of Jalpa, Zacatecas, Mexico (21.717515° N, 102.976155° W) (Figure

2), at an approximate altitude of 1750 m a.s.l., under semi-arid temperate climate conditions. Although a detailed soil analysis was not performed, the presence of local crops such as maize, maguey, and nopal, along with naturally occurring pitayos, suggests moderate soil fertility typical of a semi-arid area, sufficient to support both cultivated and native species.

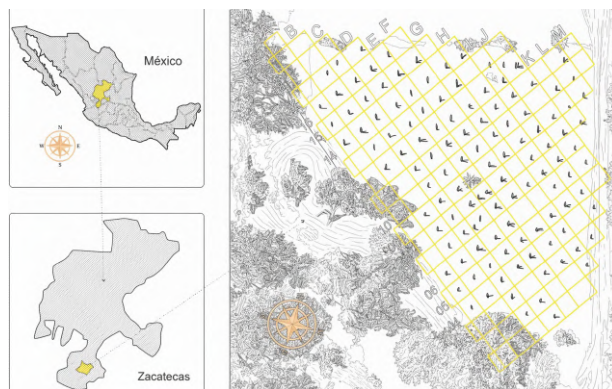


Figure 2: Representation of the sampling site location.

The analyzed specimen corresponds to *Stenocereus queretaroensis*, a columnar cactus that can reach up to 10 m in height and form tree-like structures through branched stems. It produces nocturnal pinkish-white flowers and fruits known as “pitayas de mayo”, which exhibit morphological and chromatic variability in pulp, shape, and weight (100–300 g). Stems feature 6–8 ribs with a specific arrangement of radial and central spines, flowers present reddish buds and a white perianth, and fruits have sweet pulp, deciduous yellow spines, and black seeds. Its geographic distribution is concentrated in southern Zacatecas. Figure 3 shows a *Stenocereus* (pitayo) specimen that serves as a representative reference of the plants present in the plot.

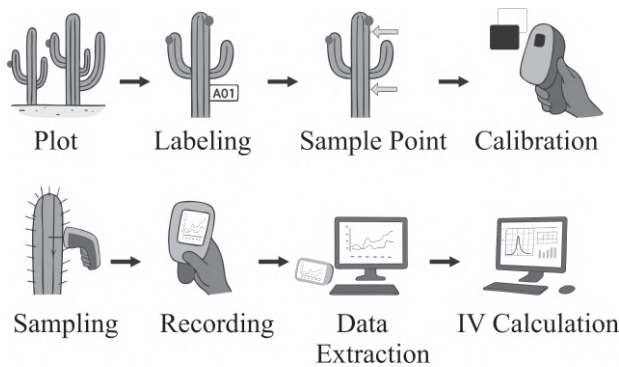


Figure 3: Young *Stenocereus queretaroensis* plant.

Table 1: Some Vegetation Indices within the 400–700 nm range

Index	Equation	Reference
PRI (Photochemical Reflectance Index)	$PRI = \frac{R_{531} - R_{570}}{R_{531} + R_{570}}$	[19]
CARI (Chlorophyll Absorption Ratio Index)	$CARI = (R_{700} - R_{670}) - 0.2 \times (R_{700} - R_{550})$	[20]
MCARI (Modified Chlorophyll Absorption in Reflectance Index)	$MCARI = [(R_{700} - R_{670}) - 0.2 \times (R_{700} - R_{550}) \times (R_{700}/R_{670})]$	[21]
TCARI (Transformed Chlorophyll Absorption Ratio Index)	$TCARI = 3 \times [(R_{700} - R_{670}) - 0.2 \times (R_{700} - R_{550}) \times \frac{R_{700}}{R_{670}}]$	[21]
RARSB (Red-Edge Atmospheric Resistant Index)	$RARSB = \frac{R_{675}}{R_{650} \times R_{700}}$	[22]
RGRI (Red Green Ratio Index)	$RGRI = \frac{R_{550}}{R_{670}}$	[23]
PSRI (Plant Senescence Reflectance Index)	$PSRI = \frac{R_{680} - R_{500}}{R_{750}}$	[24]
ARI (Anthocyanin Reflectance Index)	$ARI = \frac{1}{R_{550}} - \frac{1}{R_{700}}$	[25]
CRI (Carotenoid Reflectance Index)	$CRI_{550} = \frac{1}{R_{510}} - \frac{1}{R_{550}}, \quad CRI_{700} = \frac{1}{R_{510}} - \frac{1}{R_{700}}$	[26]

The experimental design involved in situ acquisition of spectral signatures from 109 plants using a portable YS45 spectrophotometer. The plot was organized into a grid of rows and columns, assigning unique alphanumeric labels to each plant. Fixed reference points were established along each pitayo to ensure consistency in sample collection and measurement repeatability. For each plant, three stem segments (basal, middle, and young) were selected. Figure 4 illustrates the methodology through a schematic diagram. Measurements were conducted between 8:00 and 10:00 a.m., positioning the sensor perpendicular to the surface and calibrating with a white reference before each session.



Figure 4: Methodology for in situ spectral signature acquisition.

The YS45 spectrophotometer employs a 45/0 optical system, D65 light source, 8 mm aperture ($\Phi 8$), dual-matrix CMOS detector, and concave diffraction grating. Spectra were recorded in the 400–700 nm range at 10 nm intervals with repeatability $\Delta E^* \leq 0.05$, and data were exported to MATLAB to generate spectral reflectance curves and organize monthly datasets in text files. The spectral data were acquired using the SQCT software

included with the YS45 and saved as .csv/.txt files for subsequent processing in software such as MATLAB.

IV. Results

Figure 5 shows the set of spectral signatures corresponding to the youngest part of the pitayo plants during January, along with the curve representing the median of all spectral curves for that month.


Figure 5: Spectral signatures of the young part of pitayo plants during January.

The main feature observed in this graph reflects typical vegetation behavior, with a peak around 540–560 nm, corresponding to higher reflectance in the green region, and lower values in the blue and violet regions (400 nm). Additionally, an increase is observed near 700 nm, marking the beginning of the near-infrared (NIR) region, which is associated with plant vigor and water content.

The CARI vegetation index was calculated using the formulas presented in Table 1. Based on reflectance values at the specified wavelengths, vegetation indices were estimated for the months from January to June for the three stem sections of the pitayo. The results for the mature and young sections are presented in Figure 6. The collected spectral signatures also allow straightforward calculation of other vegetation indices such as SR7, GRVI, PRI, ARI, CRI550, and CRI700.




Figure 6: Box plot of CARI vegetation indices for January–June.

The data presented are raw and unfiltered; therefore, some apparent outliers may reflect measurement errors. The median CARI values for most months range around 8–12, suggesting relatively stable central values across months for each plant section, without drastic variation.

Figure 7 shows the average CARI values from January to June. From January to March, CARI values were similar across all three pitayo sections (mature, middle, and young), ranging between 8 and 11 with low variability. In April, the middle section showed a marked increase, reaching around 20 and displaying high dispersion, while the other two sections remained nearly unchanged. In May, values in the middle section returned to normal levels (approx. 12), the young section increased slightly (12–14), and the mature section remained stable. By June, all sections showed similar values (7–9). The variation observed in April coincides with the onset of fruit production in the pitayos, as observed in the field.




Figure 7: Average CARI vegetation index of pitayo plants.

Trends in median CARI values (Figure 8) indicates an increase in the young and middle sections from March to May, followed by a decline in June, while the mature section remained more stable. Since CARI is associated with the spectral signal of foliar pigments (mainly carotenoids

and their relationship with chlorophyll), this pattern may reflect carotenoid accumulation, relative chlorophyll reduction, or a specific phenological event. Correlation with chlorophyll-specific indices and/or chemical measurements is recommended to confirm the underlying cause.




Figure 8: Median CARI values of pitayo plants.

V. Conclusion

This study recorded and analyzed spectral signatures of *Stenocereus queretaroensis* over six months, revealing temporal variation in the CARI vegetation index across different stem sections. Overall, values remained stable between January and March, with minimal variability among the mature, middle, and young sections. However, a notable increase was observed in the middle section in April, accompanied by high data dispersion, coinciding with the onset of the fruiting period. Subsequently, values returned to similar levels in May and June.

These results suggest that variations in the CARI index may be linked to physiological changes associated with fruit development and foliar pigment dynamics. The information provides a useful basis for understanding spectral patterns in pitayo plants and highlights the importance of continued complementary measurements to relate optical indices to biochemical and phenological parameters of the species.

References

- [1] B Xue et al. «PROSPECT-RB: a novel method for simulating the leaf optical properties under rice blast disease». In: *Precision agriculture'25*. Wageningen Academic, 2025, pp. 460–465.
- [2] Stéphane Jacquemoud and Susan L Ustin. «Modeling leaf optical properties». In: *Photobiological Sciences Online* 736 (2008), p. 737.
- [3] Ray D Jackson and Alfredo R Huete. «Interpreting vegetation indices». In: *Preventive veterinary medicine* 11.3-4 (1991), pp. 185–200.

- [4] Eduardo Campos-Rojas et al. «Evaluación de plantas de pitaya (*Stenocereus* spp) de poblaciones naturales de Monte Escobedo, Zacatecas». In: *Revista Chapingo. Serie horticultura* 17.3 (2011), pp. 173–182.
- [5] Brenda Arlette Monroy Orozco. «Diversidad de visitantes florales de *Stenocereus queretaroensis* (FAC Weber) Buxb., bajo un gradiente de manejo agrícola, en el municipio de Techaluta de Montenegro, Jalisco». In: (2025).
- [6] Juana Rodríguez-Morales, Susana Guillén, and Alejandro Casas. «Consecuencias de la domesticación de *Stenocereus stellatus* en el tamaño de las semillas y en la germinación en un gradiente de estrés hídrico». In: *Botanical Sciences* 91.4 (2013), pp. 485–492.
- [7] Jaime Hernández and Daniel Montaner. «Patrones de respuesta espectral». In: *Tecnologías Geoespaciales: Experiencias Aplicadas al Estudio y Gestión del Territorio*. Carlos Mena (Ed.) ISBN (2009), pp. 978–956.
- [8] PS Roy. «Spectral reflectance characteristics of vegetation and their use in estimating productive potential». In: *Proceedings: Plant Sciences* 99 (1989), pp. 59–81.
- [9] James B Campbell and Randolph H Wynne. *Introduction to remote sensing*. Guilford press, 2011.
- [10] Karla Jazmín Meza Tapia. «Caracterización Espectral de Estrés Hídrico en el Cultivo de Pepino Dulce». In: *Revista Geoespacial* 17 (2020), pp. 14–24.
- [11] Chang Liu, Peng-Sen SUN, and Shi-Rong Liu. «A review of plant spectral reflectance response to water physiological changes». In: *Chinese Journal of Plant Ecology* 40.1 (2016), p. 80.
- [12] George Karabourniotis et al. «The optical properties of leaf structural elements and their contribution to photosynthetic performance and photoprotection». In: *Plants* 10.07 (2021), p. 1455.
- [13] Tomás Ignacio Acuña Ruz. «Firmas espectrales de vegetación urbana en Santiago de Chile: caracterización y separabilidad de especies a escala foliar». In: *Repositorio Académico de la Universidad de Chile* (2015).
- [14] Katja Klančnik and Alenka Gaberščik. «Leaf spectral signatures differ in plant species colonizing habitats along a hydrological gradient». In: *Journal of plant Ecology* 9.4 (2016), pp. 442–450.
- [15] Stephane Jacquemoud and Susan L Ustin. «Leaf optical properties: A state of the art». In: *8th International Symposium of Physical Measurements & Signatures in Remote Sensing*. CNES Aussois France. 2001, pp. 223–332.
- [16] Nieves Aparicio et al. «Spectral vegetation indices as nondestructive tools for determining durum wheat yield». In: *Agronomy Journal* 92.1 (2000), pp. 83–91.
- [17] Jinru Xue and Baofeng Su. «Significant remote sensing vegetation indices: A review of developments and applications». In: *Journal of sensors* 2017.1 (2017), p. 1353691.
- [18] Sha Huang et al. «A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing». In: *Journal of forestry research* 32.1 (2021), pp. 1–6.
- [19] JA Gamon, Josep Penuelas, and CB Field. «A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency». In: *Remote Sensing of environment* 41.1 (1992), pp. 35–44.
- [20] Moon S Kim et al. «The use of high spectral resolution bands for estimating absorbed photosynthetically active radiation (A par)». In: *CNES, proceedings of 6th international symposium on physical measurements and signatures in remote sensing*. GSFC-E-DAA-TN72921. 1994.
- [21] Driss Haboudane et al. «Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture». In: *Remote sensing of environment* 90.3 (2004), pp. 337–352.
- [22] Emmett W Chappelle, Moon S Kim, and James E McMurtrey III. «Ratio analysis of reflectance spectra (RARS): an algorithm for the remote estimation of the concentrations of chlorophyll a, chlorophyll b, and carotenoids in soybean leaves». In: *Remote sensing of environment* 39.3 (1992), pp. 239–247.
- [23] Zhengwei Yang, Patrick Willis, and Rick Mueller. «Impact of band-ratio enhanced AWIFS image to crop classification accuracy». In: *Proc. Pecora*. Vol. 17. 1. 2008, pp. 1–11.
- [24] Anatoly A Gitelson, Yoram J Kaufman, and Mark N Merzlyak. «Use of a green channel in remote sensing of global vegetation from EOS-MODIS». In: *Remote sensing of Environment* 58.3 (1996), pp. 289–298.

- [25] Anatoly A Gitelson, Mark N Merzlyak, and Olga B Chivkunova. «Optical properties and nondestructive estimation of anthocyanin content in plant leaves». In: *Photochemistry and photobiology* 74.1 (2001), pp. 38–45.
- [26] Anatoly A Gitelson et al. «Assessing carotenoid content in plant leaves with reflectance spectroscopy». In: *Photochemistry and photobiology* 75.3 (2002), pp. 272–281.
- [27] Feng Gao. «Remote Sensing for Agriculture». In: *Agro-geoinformatics: Theory and Practice*. Springer, 2021, pp. 7–24.
- [28] Marie Weiss, Frédéric Jacob, and Grgory Duveiller. «Remote sensing for agricultural applications: A meta-review». In: *Remote sensing of environment* 236 (2020), p. 111402.

Exploring the Optimal Battery Sizing in Grid-Connected PV Systems: A Comparative Study of PSO and GA in Oax, Mx

Exploración del dimensionamiento óptimo de baterías en sistemas FV conectados a la red: un estudio comparativo de PSO y GA en Oax, Mx

Hector Javier Jarquín-Florés ¹, Carlos Lastre-Domínguez ^{*1}, Álvaro César Guevara-Ramírez ¹, Alfredo Cruz-Valdiviezo ¹, Eric Mario Silva-Cruz ¹, and Noé Pérez-Arreortúa ¹

¹ Tecnológico Nacional de México, Instituto Tecnológico de Oaxaca, Departamento de Ingeniería Eléctrica y Electrónica, Avenida Ing. Víctor Bravo Ahuja No. 125, Esquina Calzada Tecnológico, Oaxaca de Juárez, Oaxaca, México, C.P. 68030.
{hector.jarquin, carlos.lastre, alvaro.guevara, alfredo.cruz, eric.cruz, noe.perez}@itoaxaca.edu.mx

Abstract

The optimal sizing of Battery Energy Storage Systems is crucial for maximizing the efficiency and output of grid-connected photovoltaic (PV) systems. This study explores Particle Swarm Optimization (PSO) and Genetic Algorithm (GA), both aimed at minimizing total system costs. The analysis evaluates several performance indicators, including total life cycle cost, optimal battery capacity and power ratings, integrated Levelized Cost of Energy (LCOE), and charge/discharge energy profiles. The results indicate that GA achieves a total cost reduction of approximately 3-4% compared to PSO, alongside a modestly lower integrated LCOE. However, PSO displays enhanced control over discharge depth, yielding a more stable state of charge trajectory.

Keywords— Battery storage, grid-connected PV, PSO

Resumen

La dimensión óptima de los Sistemas de Almacenamiento de Energía en Baterías es fundamental para aprovechar el potencial de las plantas fotovoltaicas (FV) conectadas a la red. Este estudio evalúa la Optimización por Enjambre de Partículas (PSO) y el Algoritmo Genético (AG), con el objetivo de minimizar los costos totales. Los indicadores de rendimiento evaluados incluyen el costo total del ciclo de vida, la capacidad y potencia óptimas de la batería, el Costo Nivelado de Energía integrado (LCOE) y los perfiles de energía de carga/descarga. Los resultados revelan que el AG resulta en un costo total entre un 3% y un 4% menor que el obtenido con PSO, así como un LCOE ligeramente inferior. Sin embargo, PSO muestra un control superior sobre la profundidad de descarga, lo que resulta en una trayectoria de carga más uniforme.

Palabras clave— Almacenamiento de baterías, FV conectada a la red, PSO

I. Introduction

In recent years, the integration of renewable energy sources into electrical grids has gained significant global momentum [1, 2, 3]. This trend primarily arises from increasing energy demand, growing environ-

mental concerns, and the urgent need to address climate change, [4, 5, 6, 7].

Photovoltaic (PV) generation stands out among renewable technologies. It produces minimal greenhouse gas emissions. Its installation costs are declining. PV systems are scalable and suitable for both small rooftop installations and large utility installations [8]. However, solar irradiance is highly variable due to weather changes, sea-

*Corresponding author

sons, and daily cycles. This variability causes operational challenges. These include supply instability, voltage fluctuations, and mismatches between generation and demand [9, 10, 11].

The Battery Energy Storage Systems (BESS) are widely recognized as an effective solution for managing fluctuations in energy production [12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22]. By storing excess PV energy during periods of high sunlight and releasing it during times of low production or peak demand, BESS enhances flexibility, reliability, and overall power quality [23, 24, 25, 26, 27, 28, 29]. However, the high initial cost of batteries makes optimal sizing crucial [30]. Oversizing a BESS can lead to excessive investment and underutilization, while undersizing can result in curtailed PV energy output, reduced reliability, and increased operational costs. Classical optimization techniques often struggle with the non-linear, multi-modal, and constraint-rich nature of PV-BESS sizing [31].

Metaheuristic algorithms particularly Particle Swarm Optimization (PSO) and Genetic Algorithm (GA) have attracted increasing attention in the recent literature, [32, 33, 34, 35, 36]. In [37], a binary PSO is proposed to optimize hybrid energy generating systems (HEGS) in the Galapagos Islands, Ecuador, offering a simple and powerful tool for efficient energy system sizing. In another study, the authors propose the PSO technique to achieve optimal sizing of the hybrid energy storage system (HESS) and an improved low-pass filter for electric vehicle applications, achieving considerable performance [38].

Other work proposes a hybrid technique that combines an extended Kalman filter (EKF), PSO, and long short-term memory (LSTM), achieving an excellent accuracy and robustness, [39]. As to approaches GA, a study's whole objective is to solve a constrained chance model for optimizing the expansion of energy storage (ESSs) and renewable energy integration in an electric grid which considers the initial investment costs for energy storage and renewable energy, as well as conventional generation systems to meet load demand, [40].

In other work, the author applies GA to determine the optimal configuration of subsystems, specifically including the battery capacity, for an autonomous renewable energy multi-source system [41]. In [42], a GA-based method is proposed to determine the optimal energy and power capacities of energy storage systems (ESS) in microgrids.

Other interesting work presents a methodology for the optimal sizing of stand-alone PV/Wind-Generator systems, including the determination of the optimal number and type of batteries, by minimizing the 20-year total system cost. The collective behavior of biological populations, such as bird flocks or fish schools, inspires

PSO. Particles explore the decision space cooperatively by sharing information on promising regions. GA, by contrast, emulates natural selection through crossover and mutation, balancing exploration and exploitation across generations. Both algorithms have shown the ability to deliver near-global optima within reasonable computational timeframes for complex, non-convex problems. However, their performance may vary depending on problem specifics and parameter tuning [43, 44, 45, 46, 47, 48, 49].

This study presents a thorough comparison of PSO and GA for optimizing the sizing of Battery BESS in grid-connected PV systems in Oaxaca, Mexico. The analysis utilizes hourly profiles of irradiance and temperature from the National Solar Radiation Database (NSRDB-NREL) for the period spanning January 1, 2024, to December 31, 2024, based on approximate coordinates of 17.06° N and 96.72° O. The analysis focuses on several key performance indicators, including total system cost, optimal battery capacity and power, LCOE, and charge/discharge energy profiles—all of which play a crucial role in the practical design of PV-BESS systems.

This study makes three significant contributions:

- Development of a unified optimization model integrating PV power estimation, detailed battery dynamics, mismatch penalties, and maintenance costs.
- Implementation of calibrated PSO and GA solvers with identical population sizes and iteration limits, allowing for a fair, side-by-side comparison.
- Execution of a 360-day simulation to evaluate trade-offs between economic performance (total cost, LCOE) and operational behavior (state-of-charge profile, depth of discharge).

The remainder of this paper is organized as follows: Section 2 presents the mathematical formulation, including the objective function and system constraints. Section 3 describes the optimization methodology and parameter settings. Section 4 discusses the results obtained with PSO and GA, including both a representative-day case study and a year-long simulation. Finally, Section 5 presents the conclusions and outlines directions for future work and real-world deployment.

II. Problem formulation

The optimization problem concerns a grid-connected (PV) plant equipped with a BESS. The aim is to choose the 24-hour battery set points that minimize the total daily operating cost while satisfying all physical constraints. The formulation comprises three parts: the PV generation model, the battery state model, and the cost function.

II.1. Photovoltaic power model

PV output depends on solar irradiance and cell temperature. Cell temperature is estimated from ambient temperature by the empirical relation

$$T_{\text{cell}}(t) = T + \frac{GHI(t)}{800} (T_{\text{NOCT}} - 20), \quad (1)$$

where T is ambient temperature ($^{\circ}\text{C}$), GHI is global horizontal irradiance (W m^{-2}), and T_{NOCT} is the nominal operating cell temperature [4]. The impact of temperature on module efficiency is

$$\eta_{\text{loss}}(t) = 1 - \lambda(T_{\text{cell}}(t) - 25), \quad (2)$$

with λ the temperature coefficient and 25°C the standard test condition reference. The DC power produced at hour t is therefore calculated by:

$$P_{PV}(t) = C_{PV} \frac{GHI(t)}{S_{\text{STD}}} \eta_{\text{loss}}(t) \eta_{DC/DC}, \quad (3)$$

where C_{PV} is the nominal PV capacity (kW), $S_{\text{STD}} = 1000 \text{ W m}^{-2}$ is the standard irradiance, and $\eta_{DC/DC}$ is the DC-DC converter efficiency, explicitly set as:

$$\eta_{DC/DC} = 0.95 \quad (4)$$

II.2. Battery energy storage model

Let the state of charge be $C_{\text{BES}}(t)$ (kWh) and the battery power set point be $P_{\text{BES}}(t)$ (kW, positive when charging). At the beginning of the day the SoC is initialized to the mid point between its limits

$$C_{\text{BES}}(0) = \frac{C_{\text{BES}}^{\text{max}} + C_{\text{BES}}^{\text{min}}}{2}. \quad (5)$$

For each subsequent hour, the dynamic model for the state of charge (SoC) is given by:

$$C_{\text{BES}}(t+1) = \min\left[C_{\text{BES}}(t) + P_{\text{BES}}(t) \eta_{\text{charge}}, C_{\text{BES}}^{\text{max}}\right], \quad (6a)$$

$$C_{\text{BES}}(t+1) = \max\left[C_{\text{BES}}(t) + \frac{P_{\text{BES}}(t)}{\eta_{\text{discharge}}}, C_{\text{BES}}^{\text{min}}\right], \quad (6b)$$

where (6a) applies when $P_{\text{BES}}(t) \geq 0$ (charging) and (6b) when $P_{\text{BES}}(t) < 0$ (discharging). To maintain the feasibility of the SOC over the upcoming hour, it is imperative that the set point adheres to the established dynamic constraints.

$$P_{\text{BES}}^{\text{max}}(t) = \min\left[C_{\text{BES}}^{\text{max}} - C_{\text{BES}}(t), \frac{(C_{\text{BES}}(t) - C_{\text{BES}}^{\text{min}}) \eta_{\text{discharge}}}{\Delta t}\right], \quad (7a)$$

$$P_{\text{BES}}^{\text{min}}(t) = \max\left[C_{\text{BES}}^{\text{min}} - C_{\text{BES}}(t), \frac{C_{\text{BES}}(t) - C_{\text{BES}}^{\text{max}}}{\eta_{\text{charge}} \Delta t}\right], \quad (7b)$$

and we enforce

$$P_{\text{BES}}(t) \in [P_{\text{BES}}^{\text{min}}(t), P_{\text{BES}}^{\text{max}}(t)]. \quad (8)$$

II.3. Cost function

With demand $D(t)$, the supply-demand mismatch is

$$\Delta(t) = P_{PV}(t) + P_{\text{BES}}(t) - D(t).$$

The hourly costs $C_{\text{mis}}(t) = c_m |\Delta(t)|$, $C_{\text{mnt}}(t) = c_{\text{mnt}} |P_{\text{BES}}(t)|$, $C_{\text{pen}}(t) = k_p \max\{0, -\Delta(t)\}$ are mismatch, maintenance, and unserved load, respectively and the total daily operating cost to be minimized is

$$\min_{P_{\text{BES}}(t)} \sum_{t=1}^{24} [c_m |\Delta(t)| + c_{\text{mnt}} |P_{\text{BES}}(t)| + k_p \max\{0, -\Delta(t)\}] \quad (9)$$

where the coefficients are determined as follow, $c_m = 0.30 \text{ MXN kWh}^{-1}$ [50], $c_{\text{mnt}} = 0.25 \text{ MXN kWh}^{-1}$ [30], $k_p = 100 \text{ MXN kWh}^{-1}$. The large value $k_p \gg c_m$ reflects the contractual penalty for unserved demand. Equations (2)–(9) define a non convex optimization problem with 24 continuous decision variables $P_{\text{BES}}(1), \dots, P_{\text{BES}}(24)$ limited by the inverter rating

$$P_{\text{BES}}(t) \in [-30, 30] \text{ kW}.$$

The LCOE is explicitly calculated as follows:

$$LCOE = \frac{1}{\sum_{t=1}^T D(t)} \sum_{t=1}^T (c_m |\Delta(t)| + c_{\text{mnt}} |P_{\text{BES}}(t)| + k_p \max\{0, -\Delta(t)\}) \quad (10)$$

where $T = 360$ days. For this extended evaluation, daily profiles of solar irradiance, ambient temperature, and power demand are considered. The cumulative daily operational and energy-related costs provide an annualized LCOE. Since conventional solvers are prone to local optima, we resort to meta-heuristic algorithms, specifically PSO and GA, whose detailed configurations are presented in Section III.

III. Metaheuristic Optimization: PSO and GA

This section describes the configuration and execution of the two metaheuristic solvers (PSO and GA) used to optimize the 24-element battery power vector

$$\mathbf{P}_{\text{BES}} = [P_{\text{BES}}(1), \dots, P_{\text{BES}}(24)]^T.$$

III.1. Search Space and Common Settings

The optimization variables comprise a 24 dimensional real valued vector \mathbf{P}_{BES} , where each component $P_{\text{BES}}(t)$ denotes the battery charge/discharge power (kW) at hour t . Each variable is constrained to

$$P_{\text{BES}}(t) \in [-30, 30] \text{ (kW)},$$

To ensure a fair comparison between the PSO and GA, both solvers will use identical settings. The population size consists of 30 candidate solutions, which refer to particles in PSO and individuals in GA. The iteration limit is set to 100 for both PSO and GA. The convergence criterion states that the process should stop if the relative improvement in the best cost falls below 10^{-5} . For reproducibility, a fixed random seed is used. For constraint handling, after each update, any values of $P_{BES}(t)$ that fall outside the range $[-30, 30]$ will be clipped back into this range before evaluating the cost. In terms of objective evaluation, for each candidate solution, the battery dynamics will be simulated using Equations (5) to (7).

The simulation will accumulate mismatch, maintenance, and penalty costs, ultimately allowing for the computation of the total cost as described in Equation (9). All other parameters (e.g. PV data, load profiles, cost coefficients) are held identical. Both PSO and GA adhere to the same evaluation loop:

1. **Initialization.** Generate population $\{\mathbf{x}_i^0\}$ (and $\{\mathbf{v}_i^0\}$ for PSO).
2. **Evaluation.** For each \mathbf{x}_i^k :
 - Compute PV output $P_{PV}(t)$ via (3).
 - Simulate SoC via (5)–(6b), enforce (7a)–(8).
 - Compute total cost $f(\mathbf{x}_i^k)$ by (9).
3. **Update.**
 - PSO: update $\mathbf{v}_i, \mathbf{x}_i$ by Equations (13) and (14); refresh personal/global bests.
 - GA: produce next generation via selection, crossover, mutation, elitism.
4. **Convergence.** Stop if iteration/gen = 100 or best cost improves by $< 10^{-5}$ over 20 steps.
5. **Logging.** Record best and mean costs for convergence plots.

III.2. Particle Swarm Optimization

We apply PSO to the 24-hour scheduling problem defined by Eqs. (5)–(6b) and objective (9), subject to power limits (7a)–(8). Each particle i holds a 24 vector $\mathbf{x}_i \in [-30, 30]^{24}$. Initialize

$$\mathbf{x}_i^0 \sim \mathcal{U}([-30, 30]^{24}), \quad (11)$$

$$\mathbf{v}_i^0 \sim \mathcal{U}([-v_{\max}, v_{\max}]^{24}), \quad v_{\max} = 15. \quad (12)$$

Set personal best $\mathbf{p}_i^{\text{best}} = \mathbf{x}_i^0$, and global best $\mathbf{g}^{\text{best}} = \arg \min_i f(\mathbf{x}_i^0)$. At iteration $k+1$, update velocities and positions via

$$\mathbf{v}_i^{k+1} = w \mathbf{v}_i^k + c_1 r_1 (\mathbf{p}_i^{\text{best}} - \mathbf{x}_i^k) + c_2 r_2 (\mathbf{g}^{\text{best}} - \mathbf{x}_i^k), \quad (13)$$

$$\mathbf{x}_i^{k+1} = \mathbf{x}_i^k + \mathbf{v}_i^{k+1}, \quad (14)$$

where $r_{1,2} \sim \mathcal{U}(0, 1)$. After each update, clip $|v_{i,t}| \leq v_{\max}$ y $x_{i,t} \in [-30, 30]$ The parameters are determined as follow $w = 0.7$, $c_1 = c_2 = 1.5$, $v_{\max} = 15\text{kW}$, $N = 30$, $K_{\max} = 100$.

III.3. Genetic Algorithm (GA)

GA evolves a population of 30 chromosomes, each encoding $\mathbf{x} \in [-30, 30]^{24}$. Details:

The initialization process starts by selecting 30 individuals randomly within the range of $[-30, 30]^{24}$. We evaluate how well each individual performs using the fitness function $f(\mathbf{x})$ described in Equation (9). For selecting individuals, we use a tournament method with a size of 3. During crossover, we apply single-point crossover. We randomly choose a cut point p from $\{1, \dots, 23\}$ to combine the genes of two parents. In the mutation phase, each gene has a 5% chance of changing. If it does, we add a value from the normal distribution $\mathcal{N}(0, \sigma^2)$ where $\sigma = 3$ kW. We make sure any resulting values stay within the range of $[-30, 30]$. We use an elitism strategy, where we copy the best individual directly into the next generation without changes. The parameters for this process are: population size (Pop) is 30; tournament size is 3; mutation rate is 5%; elitism is 1; the number of genes is 100; crossover size is 1; and σ is 3 kW.

IV. Results

IV.1. convergence analysis for optimization algorithms

First, a *representative day* (24 h) is analyzed in depth to illustrate how each optimizer converges, how the battery is dispatched, and how these decisions translate into cost components. Second, the optimization is repeated for a full 360 day synthetic year to verify that the day scale conclusions remain valid in long term operation. Figure 1 shows how PSO very quickly collapses to its final objective value, with the average (dashed) curve catching up by around iteration 40. Also the algorithms track the best and average objective value versus iteration for PSO and GA, respectively. Both algorithms stabilize well before the 100 iteration limit, but PSO requires fewer evaluations to reach its plateau, reflecting faster exploitation of the search space.

IV.2. A comparative analysis of power.

Figures 2 and 3 superimpose the optimal battery power with PV generation and demand. For PSO, the battery injects fewer large spikes, smoothing the net load curve; GA, while economically attractive, schedules slightly deeper discharge events, visible as larger negative excursions.

Table 1 confirms that GA attains the lowest total cost and integrated LCOE, albeit at the expense of marginally




Figure 1: Best-cost convergence vs. iterations: PSO (solid) and GA (dashed).




Figure 2: Hourly power balance obtained with PSO. Positive values indicate charging or surplus PV, negatives correspond to battery discharge.




Figure 3: Hourly power balance obtained with GA. GA follows similar trends but allows deeper battery discharges during evening peaks.

higher battery cycling (discharge of 150 kWh versus 139 kWh for PSO).

Table 1: Performance metrics for the representative day.

Metric	PSO	GA
Total cost (MXN)	94 039.35	96 696.38
Integrated LCOE (MXN/kWh)	218.19	228.83
Stored energy (kWh)	462.75	446.88
Discharged energy (kWh)	139.36	150.00

IV.3. A year-long analysis of Levelized Cost of Energy (LCOE).

To validate scalability, each optimizer is re run day by day for a 360 day synthetic year. The resulting trajectories highlight systematic differences. Figures 4 and 5 depict the daily integrated LCOE. GA retains an average \$ 4 % advantage, but both methods exhibit comparable variance, indicating stable operation over seasonal irradiance changes.




Figure 4: Daily integrated LCOE over 360 days – PSO.

As you can see in Figure 4, PSO maintains a very consistent LCOE curve with small variance day-to-day.




Figure 5: Daily integrated LCOE over 360 days – GA.

In contrast, Figure 5 shows that GA runs about 3–4 % lower on average but with slightly more scatter.

IV.4. Analysis of costs associated with mismatches, maintenance, penalties, and state of charge




Figure 6: Generated, stored and discharged energy per day – PSO.




Figure 7: Generated, stored and discharged energy per day – GA.

Figures 8 and 9 show logarithmic cost-component stacks. GA reduces mismatch cost thanks to aggressive discharges, whereas PSO pays slightly less penalty by avoiding demand shortfalls.




Figure 8: Daily cost component distribution – PSO (log scale).

Figures 10 show the mean daily SoC envelope. PSO has a narrower SoC band, indicating a lower cycle depth and potentially longer battery life. GA consistently reduces costs by 3–4%, while PSO achieves up to 8% lower average depth of discharge, which can extend cell lifetime. Thus, the choice of optimizer depends on whether stake-




Figure 9: Daily cost component distribution – GA (log scale).

holders prioritize immediate savings (GA) or long-term asset preservation (PSO).




Figure 10: Battery SoC profiles: PSO (solid) and GA (dashed) over 24 h.

V. Conclusions

The GA achieved 3–4% lower operating costs in 85% of the 360-day simulations due to its more aggressive discharge scheduling. Conversely, PSO demonstrated 8% better battery preservation by using reduced Depth of Discharge (DoD) and narrower SoC ranges. Additionally, PSO converged 33% faster, while GA was more adept at escaping local minima. Both methods showed consistent seasonal performance. For projects aimed at minimizing costs, GA is the preferred choice, whereas PSO’s gentler cycling benefits battery longevity.

As future work, it is planned to integrate models and explore optimization methods of metaheuristics to analyze the performance differences between the studied methods, including an evaluation of performance variation under different scenarios of irradiance, load profiles, and battery degradation models to improve robustness and generalizability of the optimal sizing.

References

- [1] REN21. *Renewables Global Status Report*. Report. 2020.
- [2] J. Kaldellis, D. Zafirakis, and E. Kondili. «Optimum sizing of photovoltaic–energy storage systems for autonomous small islands». In: *Int. J. Electr. Power Energy Syst.* 32 (2010), pp. 24–36.
- [3] H. T. Le and T. Q. Nguyen. «Sizing energy storage systems for wind power firming: an analytical approach and a cost–benefit analysis». In: *Proc. IEEE PES Gen. Meet.* IEEE, 2008, pp. 1–8.
- [4] M. Chen. «A review of PV–battery hybrid optimisation». In: *Renew. Sustain. Energy Rev.* 156 (2022).
- [5] M. J. E. Alam, K. M. Muttaqi, and D. Sutanto. «Mitigation of rooftop solar PV impacts and evening peak support by managing available capacity of distributed energy storage systems». In: *IEEE Trans. Power Syst.* (2013). in press. URL: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6515357>.
- [6] F. L. Albuquerque et al. «Photovoltaic solar system connected to the electric power grid operating as active power generator and reactive power compensator». In: *Solar Energy* 84.7 (2010), pp. 1310–1317.
- [7] J. Tant et al. «Multiobjective battery storage to improve PV integration in residential distribution grids». In: *IEEE Trans. Sustain. Energy* 4.1 (2013), pp. 182–191.
- [8] Z. M. Salameh, B. S. Borowy, and A. R. A. Amin. «Photovoltaic module–site matching based on the capacity factors». In: *IEEE Trans. Energy Convers.* 10.2 (1995), pp. 326–332.
- [9] J. Kennedy and R. Eberhart. «Particle swarm optimization». In: *Proc. IEEE ICNN.* IEEE, 1995, pp. 1942–1948.
- [10] E. Lopez et al. «Online reconfiguration considering variability demand: applications to real networks». In: *IEEE Trans. Power Syst.* 19.1 (2004), pp. 549–553.
- [11] S. G. Asper et al. «Bibliography on load models for power flow and dynamic performance simulation». In: *IEEE Trans. Power Syst.* 10.1 (1995), pp. 523–538.
- [12] X. Tan, Q. Li, and H. Wang. «Advances and trends of energy storage technology in microgrid». In: *Int. J. Electr. Power Energy Syst.* 44 (2013), pp. 179–191.
- [13] M. Z. Daud, A. Mohamed, and M. A. Hannan. «An improved control method of battery energy storage system for hourly dispatch of photovoltaic power sources». In: *Energy Convers. Manage.* 73 (2013), pp. 256–270.
- [14] A. Nottrott, J. Kleissl, and B. Washom. «Energy dispatch schedule optimization and cost–benefit analysis for grid–connected photovoltaic–battery storage systems». In: *Renew. Energy* 55 (2013), pp. 230–240.
- [15] S. X. Chen, H. B. Gooi, and M. Q. Wang. «Sizing of energy storage for microgrids». In: *IEEE Trans. Smart Grid* 3.1 (2012), pp. 142–151.
- [16] S. Wei–Fu, H. Shyh–Jier, and E. L.–Chin. «Economic analysis for demand–side hybrid photovoltaic and battery energy storage system». In: *IEEE Trans. Ind. Appl.* 37.1 (2001), pp. 171–177.
- [17] T.–Y. Lee and N. Chen. «Determination of optimal contract capacities and optimal sizes of battery energy storage systems for time–of–use rates industrial customers». In: *IEEE Trans. Energy Convers.* 10.3 (1995), pp. 562–568.
- [18] J. Mitra. «Reliability–based sizing of backup storage». In: *IEEE Trans. Power Syst.* 25.2 (2010), pp. 1198–1199.
- [19] M. M. Rana et al. «A novel peak load shaving algorithm for isolated micro–grid using hybrid PV–BESS system». In: *Energy* (2021), p. 121157.
- [20] D. Dongol et al. «A model predictive control based peak shaving application of battery for a household with photovoltaic system in a rural distribution grid». In: *Sustain. Energy, Grids Netw.* 16 (2018), p. 100430.
- [21] D. Q. Hung, N. Mithulananthan, and R. C. Bansal. «Integration of PV and BES units in commercial distribution systems considering energy loss and voltage stability». In: *Appl. Energy* 113 (2014), pp. 1162–1170.
- [22] R. Yu, J. Kleissl, and S. Martinez. «Storage size determination for grid–connected photovoltaic systems». In: *IEEE Trans. Sustain. Energy* 4.1 (2013), pp. 68–81.
- [23] M. Castillo–Cagigal et al. «A semi–distributed electric demand–side management system with PV generation for self–consumption enhancement». In: *Energy Convers. Manage.* 52.7 (2011), pp. 2659–2666.
- [24] A. Gabash and P. Li. «Active–reactive optimal power flow in distribution networks with embedded generation and battery storage». In: *IEEE Trans. Power Syst.* 27.4 (2012), pp. 2026–2035.

- [25] M. Mohammadi, S. H. Hosseinian, and G. B. Gharehpetian. «GA-based optimal sizing of microgrid and DG units under pool and hybrid electricity markets». In: *Int. J. Electr. Power Energy Syst.* 35 (2012), pp. 83–92.
- [26] B. Bahmani-Firouzi and R. Azizipanah-Abarghooee. «Optimal sizing of battery energy storage for micro-grid operation management using a new improved bat algorithm». In: *Int. J. Electr. Power Energy Syst.* 56 (2014), pp. 42–54.
- [27] M. R. Aghamohammadi and H. Abdolahinia. «A new approach for optimal sizing of battery energy storage system for primary frequency control of islanded microgrid». In: *Int. J. Electr. Power Energy Syst.* 54 (2014), pp. 325–333.
- [28] H. Jia, Y. Mu, and Y. Qi. «A statistical model to determine the capacity of battery-supercapacitor hybrid energy storage system in an autonomous microgrid». In: *Int. J. Electr. Power Energy Syst.* 54 (2014), pp. 516–524.
- [29] O. Ekren and B. Y. Ekren. «Size optimization of a PV/wind hybrid energy conversion system with battery storage using simulated annealing». In: *Appl. Energy* 87 (2010), pp. 592–598.
- [30] IRENA. *Electricity Storage and Batteries Technology Brief*. Report. 2022.
- [31] G.-C. Liao. «Solve environmental economic dispatch of smart micro-grid containing distributed generation system using chaotic quantum genetic algorithm». In: *Int. J. Electr. Power Energy Syst.* 43 (2012), pp. 779–787.
- [32] D. E. Goldberg. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley, 1989.
- [33] X. S. Yang. «A new metaheuristic bat-inspired algorithm». In: *Nature-Inspired Cooperative Strategies for Optimization (NICSO)*. Ed. by J. R. González et al. Vol. 284. Studies in Comput. Intell. Springer, 2010, pp. 65–74.
- [34] W. Al-Saedi et al. «Power-flow control in grid-connected microgrid operation using Particle Swarm Optimization under variable load conditions». In: *Int. J. Electr. Power Energy Syst.* 49 (2013), pp. 76–85.
- [35] R. Azizipanah-Abarghooee. «A new hybrid bacterial foraging and simplified swarm optimization algorithm for practical optimal dynamic load dispatch». In: *Int. J. Electr. Power Energy Syst.* 49 (2013), pp. 414–429.
- [36] M. Basu. «Hybridization of bee colony optimization and sequential quadratic programming for dynamic economic dispatch». In: *Int. J. Electr. Power Energy Syst.* 44 (2013), pp. 591–596.
- [37] Omar Llerena-Pizarro et al. «A PSO-BPSO Technique for Hybrid Power Generation System Sizing». In: *IEEE Latin America Transactions* 18.08 (2020), pp. 1362–1370. DOI: 10.1109/TLA.2020.9111671.
- [38] Hari Maghfiroh, Oyas Wahyunggoro, and Adha Imam Cahyadi. «Optimal Sizing and Improved Low-Pass Filter Energy Management for Hybrid Energy Storage Electric Vehicles». In: *IEEE Access* 12 (2024), pp. 180926–180938. DOI: 10.1109/ACCESS.2024.3509481.
- [39] Hequan Xu et al. «State-of-Charge Estimation of Lithium-Ion Batteries Based on EKF Integrated With PSO-LSTM for Electric Vehicles». In: *IEEE Transactions on Transportation Electrification* 11.1 (2025), pp. 2311–2321. DOI: 10.1109/TTE.2024.3421260.
- [40] Farukh Abbas et al. «Optimizing generation capacities incorporating renewable energy with storage systems using genetic algorithms». In: *Electronics* 7.7 (2018), p. 100.
- [41] Chaima Ghanjati and Slim Tnani. «Optimal sizing and energy management of a stand-alone photovoltaic/pumped storage hydropower/battery hybrid system using Genetic Algorithm for reducing cost and increasing reliability». In: *Energy & Environment* 34.6 (2023), pp. 2186–2203.
- [42] Ahmet Aktas et al. «Genetic algorithm-based optimal sizing of hybrid battery/ultracapacitor energy storage system for wave energy harvesting applications». In: *IEEE Access* 12 (2024), pp. 125572–125584.
- [43] M. A. Elseify, S. Kamel, and L. Nasrat. «An improved moth flame optimization for optimal DG and battery energy storage allocation in distribution systems». In: *Cluster Computing* 27 (2024), pp. 14767–14810.
- [44] M. A. Elseify et al. «A novel approach based on honey badger algorithm for optimal allocation of multiple DG and capacitor in radial distribution networks considering power loss sensitivity». In: *Mathematics* 10 (2022), p. 2081.
- [45] T. Yuvaraj, K. R. Devabalaji, and S. B. Thanikanti. «Simultaneous allocation of DG and DSTATCOM using whale optimization algorithm». In: *Iran. J. Sci. Technol. Trans. Electr. Eng.* 44 (2020), pp. 879–896.

- [46] Y. G. Werkie and H. A. Kefale. «Optimal allocation of multiple distributed generation units in power distribution networks for voltage profile improvement and power losses minimization». In: *Cogent Eng.* 9 (2022), p. 2091668.
- [47] A. Shaik, P. L. Mareddy, and N. Visali. «Enhancement of voltage profile in the distribution system by reconfiguring with DG placement using equilibrium optimizer». In: *Alexandria Eng. J.* 61.5 (2022), pp. 4081–4093.
- [48] M. A. Shaik, P. L. Mareddy, and N. Visali. «Enhancement of voltage profile in the distribution system by reconfiguring with DG placement using equilibrium optimizer». In: *Alexandria Eng. J.* 61.5 (2022), pp. 4081–4093.
- [49] W. Haider et al. «Voltage profile enhancement and loss minimization using optimal placement and sizing of distributed generation in reconfigured network». In: *Machines* 9 (2021), p. 20.
- [50] CENACE. *Mercado Eléctrico Mayorista: Tarifas y costos de desbalance*. Online. [Consultado: Fecha de consulta]. 2024. URL: <https://www.cenace.gob.mx/mercado/tarifas>.

LP0965 log-periodic antenna performance analysis for radar applications

Análisis de la antena log-periódica LP0965 para aplicaciones de radar

Alejandra Isabel Medina-Díaz¹, Víktor Iván Rodríguez-Abdalá¹, José Ricardo Gómez-Rodríguez¹, Salvador Ibarra-Delgado¹, Remberto Sandoval-Aréchiga¹, and Efrén González-Ramírez¹

¹Universidad Autónoma de Zacatecas, Unidad Académica de Ingeniería Eléctrica,
Posgrado en Ingeniería para la Innovación Tecnológica,
Carretera Zacatecas - Guadalajara, Kilómetro 6, Ejido la Escondida, Zacatecas, México, CP 98160.
{a.medina,abdala,gonzalezefren,jrgrodri, rsandoval,sibarra}@uaz.edu.mx

Abstract

The lack of adequate technical documentation on the LP0965 antenna characteristics provides an opportunity for a specific application analysis. In this article, we analyze this antenna in order to estimate its efficiency in terms of bandwidth, gain and directivity for radar applications. This is known for its high bandwidth, which makes it suitable for applications in a wide frequency range. The analysis includes simulations and experimental measurements.

Keywords— Radar Antenna, bandwidth, log-periodic

Resumen

La falta de documentación técnica adecuada sobre las características de la antena LP0965, ofrece una oportunidad de análisis para una aplicación específica. El presente artículo analiza dicha antena con la finalidad de determinar su idoneidad en términos de ancho de banda, ganancia y directividad en aplicaciones de radar. Esta es conocida por su gran ancho de banda, lo que la hace adecuada para aplicaciones en un amplio rango de frecuencias. El análisis incluye simulaciones y mediciones experimentales de la antena.

Palabras clave— Antena de radar, ancho de banda, log-periódica

I. Introducción

Como en cualquier sistema de comunicación, las antenas juegan un papel muy importante, ya que dependiendo de la aplicación es el tipo de antena a usar [1]. Los parámetros a considerar en el diseño de una antena son: patrón de radiación, potencia radiada, directividad, ganancia, eficiencia, ancho de banda, ancho de haz, la forma de la antena, entre otros. En aplicaciones de radar, las antenas deben cumplir con determinadas características para su correcto funcionamiento, entre ellos una alta ganancia y un ancho de haz estrecho, ya que estos son fundamentales para determinar la ubicación de los blancos que se detectan [2].

Según [3], el ancho de haz permite determinar la resolución de la antena para distinguir entre dos fuentes radiantes o blancos de radar adyacentes. El criterio de resolución más común establece que la capacidad de una antena para distinguir entre dos fuentes es igual a la mitad del primer ancho de haz nulo (First Null Beam Width, FNBW/2, por sus siglas en inglés), que generalmente se utiliza para aproximar el ancho de haz a la mitad de la potencia (Half Power Beam Width, HPBW, por sus siglas en inglés) como se observa en la Fig. 1.

De acuerdo con [4], el diseño de una antena de radar necesita balancear entre un ancho de banda amplio, necesario para adaptarse a cambios rápidos en la trayectoria del objetivo, y uno estrecho, requerido para mejorar la sensibilidad.




Figura 1: Patrón de radiación de una antena direccional.

En distancias largas, donde los movimientos angulares del objetivo son menores y la señal es más débil, es preferible un ancho de haz estrecho para mantener una alta sensibilidad y minimizar el retraso en el seguimiento. Por otro lado, a distancias cortas, donde los movimientos angulares son más pronunciados, se necesita un ancho de haz más amplio para seguir eficazmente al blanco.

Además, otros parámetros como: polarización, ganancia de directividad, ganancia de potencia, apertura efectiva, radiación de lóbulos laterales y la eficiencia de apertura son aspectos a cuidar según [4].

Bajo estas condiciones, una antena logarítmica periódica cumple con ciertas características para antenas de radar como una banda amplia de frecuencias y alta directividad. De acuerdo con [5], el uso de discontinuidades apropiadamente localizadas en la estructura de la antena es lo que hace posible que tenga una banda amplia de frecuencias, es decir, un arreglo de dipolos. En el mercado existen varios tipos de antenas con diferentes características, sin embargo, a menudo la documentación técnica de estas antenas es insuficiente o incluso inexistente, lo que impide realizar cálculos precisos para aplicaciones específicas debido a la falta de dicha información.

Esta carencia hace necesario recurrir a modelos teóricos de diseño de antenas para estimar los parámetros faltantes. Una vez completados estos cálculos, es posible llevar a cabo experimentos para evaluar el desempeño de la antena en aplicaciones particulares y explorar su rendimiento.

En el caso de la antena LP0965, la falta de documentación técnica relacionada a su patrón de radiación y




Figura 2: Antena LP.

otras características ofrece una oportunidad para un análisis detallado para aplicaciones de radar. Esta falta de documentación puede deberse a que se trata de una antena de banda amplia y se espera un comportamiento estable dentro de su rango de frecuencia. Por ello, a partir de la medición de las dimensiones de la antena, se llevó a cabo la simulación, modelado y análisis con el objetivo de obtener una caracterización.

En este contexto, el presente artículo se centró en el análisis y la comparación entre los resultados de simulación de diseño contra las mediciones en una cámara anecoica de la antena log-periódica LP0965 a una frecuencia de 3.15 GHz, adquirida de Ettus Research, que opera en un rango de frecuencia de 850 MHz a 6.5 GHz, de acuerdo a las especificaciones del fabricante.

El artículo se organiza de la siguiente manera: en la Sección II se muestra el marco teórico para el diseño de una antena LP (Logarítmica Periódica); en la Sección III se realiza la parametrización y modelado de la antena; y finalmente en las secciones IV y V se muestran los resultados y conclusiones.

I.1. Antecedentes

La antena LP0965 ha sido utilizada en el desarrollo de radares de corto alcance, [6] realizó un radar para ver a través de muros usando Wi-Fi, de forma similar en [7], se obtuvieron imágenes con radar de penetración basado en SDR; por otro lado, [8] realizó un sistema de radar armónico el cual fue capaz de detectar con fiabilidad algunos dispositivos a una distancia de aproximadamente dos metros, en [9] identificaron dispositivos electrónicos sin red, apagados o que intentaron evadir la detección, mientras que en [10] se demostró que este tipo de radar también puede detectar la presencia de baterías con una alta precisión en la mayoría de los casos. Finalmente, en [11], el sistema de radar pulsado tuvo una resolución de

distancia mayor de 150 m, sin embargo, con 6.7% de error.

Diversas aplicaciones con la antena han logrado detectar correctamente la presencia de objetos entre el 90% y 100%. Por ejemplo, en [12], un sistema de reconocimiento de objetos basado en microondas utilizando USRP con una señal pulsada de tan solo 10 ms fue capaz de diferenciar varios objetos.

1.2. Antenas Log-Periódica

Existen diferentes antenas LP planas: circular, cuadrada, cónica y piramidal. Como se observa en la Fig. 2, la geometría LP se utiliza para diseñar una antena configurando primero un conductor eléctrico dentro de cualquiera de las celdas. Esta configuración, debidamente escalada, se reproduce en las demás celdas y se repite infinitas veces para las celdas más pequeñas, ya que la estructura resultante convergerá en un punto. La repetición infinita de las celdas más grandes hace que el tamaño de la estructura aumente sin límite.

El principio de operación de este tipo de antena se basa en que cada dipolo actúa como un elemento resonante para una frecuencia en particular, y sus resonancias se escalonan de modo que se solapan entre sí. De esta manera, de acuerdo con [13], a medida que varía la frecuencia, la radiación efectiva se transfiere de un dipolo al siguiente, generando un comportamiento casi independiente de la frecuencia.

De acuerdo a [14], una geometría LP se define como una estructura cuyas propiedades eléctricas varían periódicamente con el logaritmo de la frecuencia. Esta consiste en una tira de metal cuyos bordes están definidos por la mitad del ángulo del vértice ($\alpha/2$), como se muestra en Fig. 2.

Asimismo, según [5] y [13], la geometría de la antena log-periódica se define principalmente por el factor de escala o relación geométrica δ y por el ángulo de vértice α , estableciendo así el escalamiento de las celdas. El factor de escala δ determina este escalamiento y establece la relación entre las dimensiones de los elementos sucesivos, como se expresa en las ecuaciones (1) y (2).

$$\delta = \frac{R_{n+1}}{R_n}, \tag{1}$$

$$\delta = \frac{L_{n+1}}{L_n}, L_n > L_{n+1}, \tag{2}$$

donde R_n es la distancia del vértice virtual a cualquiera de los dipolos y L_n la longitud del dipolo.

Además, como se observa en la Fig. 1, el patrón de radiación de la antena está relacionado con su diseño, ya que, debido a su estructura de dipolos dispuestos de manera logarítmica, donde el dipolo más largo actúa como reflector y los dipolos sucesivos como directores,

genera un patrón de radiación que concentra la energía en una dirección.

Con esto, el dipolo más largo L_1 se asocia con la frecuencia mínima de operación, mientras que el más corto L_{18} corresponde a la frecuencia máxima. En una antena LP, las longitudes no corresponden a media longitud de onda, por lo que en este diseño se emplea una relación aproximada dada por la Ec. (3)

$$L = \frac{\lambda}{5} = \frac{c}{5f}. \tag{3}$$

donde c es la velocidad de la luz ($3 \times 10^8 m/s$), f es la frecuencia de operación y λ es la longitud de onda. Por lo tanto, para determinar L_1 se utiliza la Ec. (4) y para L_{18} la Ec. (5).

$$L_1 = \frac{c}{5f_{min}}, \tag{4}$$

$$L_{18} = \frac{c}{5f_{max}}. \tag{5}$$

El dipolo más largo resuena a la frecuencia más baja, mientras que el más corto resuena a la frecuencia más alta [15]. Su ancho de banda amplio se logra mediante la variación de la longitud de los dipolos y la función logarítmica de la distancia entre ellos (denominada factor de espaciado), lo que permite que la antena cubra frecuencias desde 850 MHz hasta 6.5 GHz para el caso de la antena LP0965.

Según [16], para cada frecuencia de operación, los dipolos que más contribuyen a la radiación son aquellos cuyo tamaño es aproximadamente la mitad de la longitud de onda correspondiente. Estos dipolos activos se desplazan desde los más largos hacia los más cortos (cerca del alimentador), y debido a la configuración de la línea de alimentación, las corrientes fluyen en fase a lo largo de la estructura. Por eso, la antena emite su energía principalmente hacia adelante (hacia el alimentador), lo que se llama patrón axial (end-fire, en inglés) como se muestra en la Fig. 3.




Figura 3: Patrón axial.

En [17] se describe la función de transferencia de una LPDA (acrónimo en inglés de log-periodic dipole antenna), de la cual se deduce que el patrón de radiación se

obtiene sumando el campo electromagnético emitido por cada dipolo resonante, teniendo en cuenta tres factores: su patrón individual de radiación, la amplitud de la corriente inducida y fase asociada, causada por su posición y la forma en que se alimenta la antena.

I.3. Sistemas de radar

En términos generales, los sistemas de radar son muy similares a los sistemas de comunicación. El diagrama de bloques simplificado de un radar consiste en un generador de señales, transmisor, duplexor, antena, procesador de señales y procesador de datos [18].

El generador de señales produce una señal lineal que es modulada a una señal pasabanda de alta frecuencia, la cual es transmitida por la antena directiva del radar hacia el espacio. El objetivo refleja la señal incidente y parte de ella regresa al radar.

El procesador de señales recibe la señal para estimar la ubicación del objetivo y el procesador de datos, mediante algoritmos, determina las características como: tamaño, dirección y velocidad del objetivo.

I.3.1. Formas de onda en radares

El principio básico de operación de un radar consiste en emitir ondas electromagnéticas en forma de pulsos o de onda continua, que al encontrarse con objetos se reflejan hacia la antena del radar. El retardo y los cambios en la señal reflejada permiten determinar la distancia y la velocidad de los blancos [1].

Las formas de onda utilizadas en los radares de pulso son: de duración finita, periódico y tren de pulsos de duración finita. En los radares de onda continua son: sin modular y moduladas, en las cuales está la onda senoidal, diente de sierra, triangular y cuadrada [19].

También en los radares de Modulación de Frecuencia Lineal (Linear Frequency Modulation, LFM, por sus siglas en inglés) se usan las formas de onda de: diente de sierra, triangular y segmentada.

Los radares de Onda Continua Modulada en Frecuencia (Frequency Modulated Continuous Wave, FMCW, por sus siglas en inglés) son modulados por una señal periódica como en los radares LFM.

II. Modelado de la antena

Se realizó la medición de las dimensiones de la antena LP095 que se muestra en la Fig. 4, tales como: ancho, largo y altura de los brazos, separación entre los brazos, ancho y largo de la placa de circuito impreso (Printed Circuit Board, PCB, por sus siglas en inglés) para su parametrización obteniendo la Tabla 1.



Figura 4: Antena LP0965.

Tabla 1: Mediciones de la antena LP0965

Dimensión	Metros
Largo del PCB	0.1422
Ancho del PCB	0.0143 0.0133
Altura del PCB	0.0013
Ancho de línea	0.00133
Longitud de alimentación	0.0023
Largo de brazos	[0.007 0.0068 0.0086 0.0092 0.0114 0.0128 0.015 0.0168 0.0192 0.0237 0.0267 0.0308 0.033 0.0376 0.0415 0.0480 0.0556 0.064]
Ancho de brazos	[0.0002 0.0002 0.0002 0.0002 0.0004 0.0004 0.0004 0.0005 0.0006 0.0006 0.0006 0.0006 0.0007 0.0007 0.0004 0.001 0.0026 0.0034]
Espacio entre brazos	[0.0017 0.0019 0.0023 0.0027 0.003 0.0035 0.0041 0.0045 0.0047 0.0063 0.008 0.008 0.0088 0.0115 0.012 0.0127 0.013]

Usando las ecuaciones (1) y (2), la relación geométrica de la antena se muestra en las ecuaciones (6) y (7).

$$\delta = \frac{R_2}{R_1} = \frac{0.1209}{0.1422} = 0.86, \tag{6}$$

$$\delta = \frac{L_2}{L_1} = \frac{0.0556}{0.064} = 0.86. \tag{7}$$

Y de acuerdo a las ecuaciones (3)-(5), la relación de la longitud de onda y la longitud de los dipolos se muestra en las ecuaciones (8)-(11).

$$\lambda_{max} = \frac{c}{f_{min}} = \frac{3 \times 10^8}{850 \times 10^6} = 0.3529 \text{ m}, \tag{8}$$

$$\lambda_{min} = \frac{c}{f_{max}} = \frac{3 \times 10^8}{6.5 \times 10^9} = 0.0462 \text{ m.} \quad (9)$$

Dipolo más largo

$$L_1 = \frac{\lambda_{max}}{5} = 0.07058 \text{ m,} \quad (10)$$

Dipolo más corto

$$L_{18} = \frac{\lambda_{min}}{5} = 0.0924 \text{ m.} \quad (11)$$

En la Tabla 2, se muestra el error entre el largo (L_n) del brazo medido y el estimado (W_n).

Tabla 2: Mediciones vs calculado

Dipolo	Calculado (m)	Medido (W_b) (m)	$L_n - W_b$ (m)	% error
L_1	0.07058	0.06400	0.00658	9.45
L_2	0.06524	0.05560	0.00964	14.73
L_3	0.06067	0.04800	0.01267	20.96
L_4	0.05637	0.04150	0.01487	27.40
L_5	0.05232	0.03760	0.01472	28.06
L_6	0.04850	0.03300	0.01550	30.00
L_7	0.04491	0.03080	0.01411	31.45
L_8	0.04142	0.02670	0.01472	35.43
L_9	0.03804	0.02370	0.01434	38.01
L_{10}	0.03475	0.01920	0.01555	44.77
L_{11}	0.03156	0.01680	0.01476	46.88
L_{12}	0.02848	0.01500	0.01348	47.37
L_{13}	0.02551	0.01280	0.01271	49.12
L_{14}	0.02264	0.01140	0.01124	50.52
L_{15}	0.01988	0.00920	0.01068	53.66
L_{16}	0.01721	0.00860	0.00861	55.11
L_{17}	0.01463	0.00680	0.00783	57.87
L_{18}	0.00924	0.00700	0.00514	68.94

III. Resultados




Figura 5: Hoja de especificaciones 1.

La hoja de especificaciones del fabricante presenta un rango de frecuencias de operación de 850 MHz a 6.5 GHz, como se muestra en la Fig. 5. El gráfico de la Fig. 6 muestra la variación del parámetro s_{11} de la antenna en función de la frecuencia. Comparado con la Fig. 7, se observa la frecuencia en la que se obtiene mejor adaptación de impedancia (mínimo) es a partir de 2.4 GHz aproximadamente. En la Fig. 8 se observa una ganancia constante a partir de 2.4 GHz aproximadamente como lo indica la Fig. 7 y se observa la máxima ganancia en 6.09 GHz con 5.8 dB.




Figura 6: Hoja de especificaciones 2.

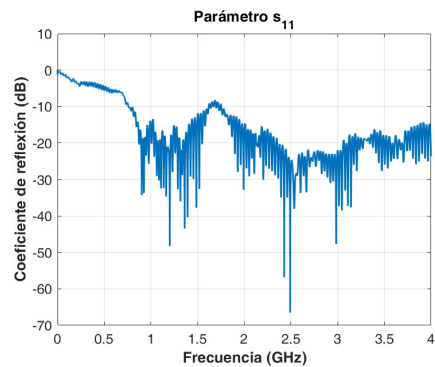


Figura 7: Coeficiente de reflexión.




Figura 8: Ganancia calculada.

De acuerdo a la Tabla 1, se simuló el patrón de radiación en la frecuencia de operación de 3.15 GHz como se observa en las figuras 9 y 10.




Figura 9: Plano en 3-D simulado.




Figura 10: Plano azimuth simulado.

Por lo que en términos de ganancia, la antena es adecuada para aplicaciones de radar de corto alcance, ya que típicamente se utilizan antenas de 5 a 10 dB [20], considerando que la ganancia no es el único criterio, sino que debe evaluarse junto con otras características como el patrón de radiación.

En las figuras 11 y 12 se muestra el patrón de radiación en la frecuencia de 6.09 GHz donde se tiene la máxima ganancia de la antena.

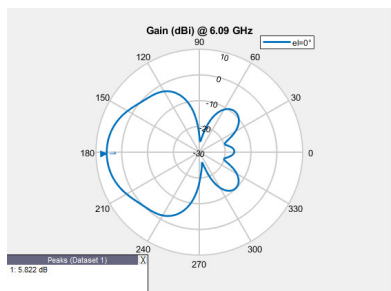


Figura 11: Plano azimuth simulado.

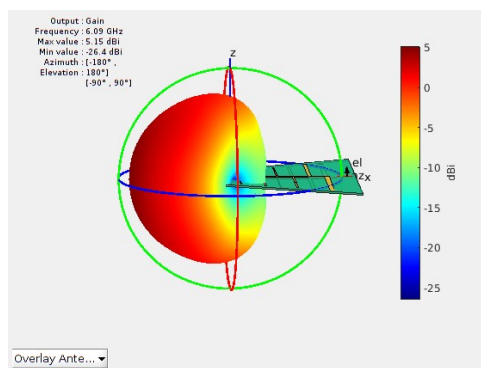


Figura 12: Plano 3-D simulado.

Las figuras 13 y 14 muestra el patrón de radiación de la antena a una frecuencia de 3.15 GHz medido en una cámara anecoica a cinco alturas diferentes representadas por un color diferente: 1 m, 1.25 m, 1.5 m, 1.75 m y 2 m. Comparando los resultados de simulación de las figuras 9 y 10, son similares, mostrando un comportamiento directivo, aunque con un ancho de haz amplio.




Figura 13: Patrón de radiación a diferentes alturas.




Figura 14: Patrón de radiación a diferentes alturas.

IV. Conclusiones

La antena mostró un comportamiento directivo bajo ya que presenta un ancho de haz amplio. Estos factores afectan la precisión con la que un radar puede determinar la dirección hacia un objetivo, ya que la capacidad

de distinguirlo depende del ancho del haz y los lóbulos secundarios de la antena.

Además, la antena tiene una ganancia de aproximadamente 5 dB lo que limita el alcance de la señal transmitida. Por estas razones la antena log-periódica LP0965 es especialmente adecuada para aplicaciones de radar de corto alcance, por lo que se sugiere para onda continua en vez de pulsos.

Referencias

- [1] Bassem R Mahafza. *Radar systems analysis and design using MATLAB*. Chapman y Hall/CRC, 2005.
- [2] David Hysell. *Antennas and radar for environmental scientists and engineers*. Cambridge University Press, 2018.
- [3] Constantine A Balanis. *Antenna theory: analysis and design 3rd ed*. John Wiley & sons, 2016.
- [4] Merrill Ivan Skolnik et al. *Introduction to radar systems*. Vol. 3. McGraw-hill New York, 1980.
- [5] Eduardo Rojas Falla, Carlos Sánchez Retis, Nestor Gómez Valencia et al. «Teoría de modelos y diseño de una antena Log-Periódica». En: *Corporación Universitaria Autónoma de Occidente* (1976).
- [6] Isaac Cushman et al. «Experimental Approach for Seeing Through Walls Using Wi-Fi Enabled Software Defined Radio Technology». En: *Digital Communications and Networks 2* (sep. de 2016). DOI: 10.1016/j.dcan.2016.09.001.
- [7] Rehan Hafiz y Mahboob Ur Rahman. «A Deep Approach for Reliable Subsurface Imaging in Software-Defined Ground Penetrating Radar». En: *Second Workshop on Machine Learning and the Physical Sciences (NeurIPS 2019), Vancouver, Canada* (2019).
- [8] Beatrice Perez et al. «Evaluating the practical range of harmonic radar to detect smart electronics». En: (oct. de 2023), págs. 528-535. DOI: 10.1109/MILCOM58377.2023.10356371.
- [9] Beatrice Perez et al. «Identification and classification of electronic devices using harmonic radar». En: *2023 19th International Conference on Distributed Computing in Smart Systems and the Internet of Things (DCOSS-IoT)*. IEEE. 2023, págs. 248-255.
- [10] Cesar Arguello et al. «Detecting Battery Cells with Harmonic Radar». En: *Proceedings of the 17th ACM Conference on Security and Privacy in Wireless and Mobile Networks*. 2024, págs. 231-236.
- [11] Alifia Utami, Iswandi Iswandi e I Mustika. «Random Time Delay Mitigation in Pulse Radar Systems Implementation using Universal Software Radio Peripheral (USRP) and GNU Radio Companion (GRC)». En: *IJITEE (International Journal of Information Technology and Electrical Engineering) 2* (feb. de 2019), pág. 85. DOI: 10.22146/ijitee.42873.
- [12] Viktor Erdélyi et al. «Learn to see: A microwave-based object recognition system using learning techniques». En: *Adjunct Proceedings of the 2021 International Conference on Distributed Computing and Networking*. 2021, págs. 145-150.
- [13] D Isbell. «Log periodic dipole arrays». En: *IRE transactions on antennas and propagation 8.3* (2003), págs. 260-267.
- [14] John Leonidas Volakis. *Antenna engineering handbook*. Vol. 1755. McGraw-Hill New York, 2007.
- [15] Paul E Mayes. «Frequency-independent antennas». En: *Antenna Handbook: Theory, Applications, and Design*. Springer, 1988, págs. 517-637.
- [16] RE Tapia-Rodríguez et al. «Design of Log-Periodic Dipole Array Antenna with Implemented Extra Dipole». En: *2018 15th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE)*. IEEE. 2018, págs. 1-5.
- [17] Francesco Merli et al. «Analysis, design and realization of a novel directive ultrawideband antenna». En: *IEEE Transactions on Antennas and Propagation 57.11* (2009), págs. 3458-3466.
- [18] William L Melvin y James A Scheer. *Principles of Modern Radar: Vol. 3: Radar Applications*. SciTech Publishing Incorporated, 2013.
- [19] Mohinder Jankiraman. *FMCW radar design*. Artech House, 2018.
- [20] David K. Barton y Ernest S. Levine. *Radar System Analysis and Modeling*. Artech House, 1991.

AT Command-Based Library Development for Microchip RN2903 LoRa Module

Desarrollo de una biblioteca basada en comandos AT para el módulo LoRa RN2903 de Microchip

Pedro Manuel Montoya Lara^{*1}, Oscar Osvaldo Ordaz García¹, José Ricardo Gómez Rodríguez¹, Víktor Iván Rodríguez Abdalá¹, Salvador Ibarra Delgado¹, Ángel García Durán¹, Remberto Sandoval Aréchiga¹, and Roberto Solís Robles¹

¹Universidad Autónoma de Zacatecas (UAZ), Unidad Académica de Ingeniería Eléctrica,

Posgrado en Ingeniería para la Innovación Tecnológica,

Campus Siglo XXI Carretera Zacatecas - Guadalajara Kilómetro 6, Ejido la Escondida, Zacatecas, Zac., México, 98160.

{pedromontoyalara,oscarordazg,jrgrodri,abdala,sibarra,angel.garcia.duran,rsandoval,rsolis}@uaz.edu.mx

Abstract

This article presents the development of a C library designed to simplify interaction with the Microchip RN2903 LoRa module for Internet of Things (IoT) applications. The work addresses the complexity of directly managing AT commands, which can hinder developers with limited experience in communication systems. The proposed library provides a structured UART-based interface for configuring parameters and managing data transmission and reception. It also integrates feedback and fault-tolerance mechanisms to ensure reliable operation. Experimental validation was carried out through point-to-point LoRa communication in an urban environment, achieving distances of up to 1.1 km with stable performance.

Keywords— IoT, LoRa, C Library

Resumen

Este artículo presenta el desarrollo de una biblioteca en C para simplificar la interacción con el módulo LoRa RN2903 de Microchip en aplicaciones de Internet de las Cosas (IoT). El trabajo surge ante la complejidad de gestionar directamente los comandos AT, lo que dificulta su uso para desarrolladores con experiencia limitada. La biblioteca propuesta proporciona una interfaz estructurada basada en comunicación UART para configurar parámetros y gestionar la transmisión y recepción de datos. Además, incorpora mecanismos de retroalimentación y tolerancia a fallas para asegurar la operación confiable. La validación experimental se realizó mediante comunicación LoRa punto a punto en un entorno urbano, alcanzando hasta 1.1 km con funcionamiento estable.

Palabras clave— IoT, LoRa, Biblioteca en C

I. Introducción

El Internet de las Cosas (IoT, siglas en inglés de Internet of Things) ha mostrado un crecimiento acelerado en los últimos años, las proyecciones indican que esta tendencia se mantendrá en el futuro cercano. El IoT es una red de dispositivos inteligentes

que integran sensores, nodos de comunicación, software embebido y otras tecnologías, los cuales son diseñados para la recolección, procesamiento y transmisión de datos hacia la nube. Estos nodos, que pueden contener varios sensores, pueden estar ubicados en áreas remotas, por lo que el envío de información hacia la nube es un reto, para ello, se recomienda el uso de LPWAN (siglas en inglés de Low Power Wide Area Network), la cual es una tecnología diseñada para nodos que deben enviar

*Corresponding author

pequeñas cantidades de datos a largas distancias con un consumo de energía bajo [1, 2].

Entre las LPWAN, LoRaWAN (siglas en inglés de Long Range Wide Area Network) se ha destacado como una tecnología entre aplicaciones de corto alcance que usan Wi-Fi y Bluetooth y de alto consumo energético como las redes celulares, ofreciendo una solución de largo alcance, eficiencia energética y de bajo costo para IoT [3, 4].

LoRa (siglas en inglés de Long Range) es la técnica de modulación de espectro expandido que permite transmitir datos a largas distancias con bajo consumo de energía. Sobre esta capa física se construye LoRaWAN, que define el protocolo de red y la arquitectura necesaria para gestionar la comunicación entre dispositivos finales, puertas de enlace (gateways en inglés) y servidores de aplicación, permitiendo la integración masiva de dispositivos IoT en entornos urbanos, rurales e industriales [3, 4].

El apoyo de fabricantes como Microchip, han permitido que LoRaWAN sea popular entre desarrolladores con pocos conocimientos de radiofrecuencia, ya que el uso de módulos de solo conectar y usar (plug and play en inglés) propicia un rápido desarrollo de aplicaciones IoT. El RN2903 es un módulo transceptor LoRa que opera en la banda de 915 MHz, su arquitectura integra una pila LoRaWAN completo, lo que permite a los desarrolladores comunicarse con el módulo mediante comandos ASCII (siglas en inglés de American Standard Code for Information Interchange), también conocidos como comandos AT (siglas en inglés de Attention Commands), a través de UART (siglas en inglés de Universal Asynchronous Receiver/Transmitter), sin necesidad de implementar directamente el protocolo LoRaWAN en el microcontrolador [5, 6].

A pesar de la disponibilidad de módulos LoRa como el RN2903, su uso requiere la gestión directa de comandos AT, lo que implica un conocimiento detallado del funcionamiento interno del dispositivo y puede resultar complejo para desarrolladores con experiencia limitada en sistemas de comunicación. Esta situación genera la necesidad de contar con herramientas que abstraigan dicha complejidad. En este contexto, el presente trabajo propone el desarrollo de una biblioteca en lenguaje C que encapsula los comandos AT del módulo RN2903, proporcionando una interfaz estructurada, simple y reutilizable para facilitar su implementación en aplicaciones IoT.

II. Biblioteca RN2903

En el contexto del uso de módulos LoRa como el RN2903, la interacción con el dispositivo se realiza mediante comandos AT, lo que implica el manejo manual de cadenas de caracteres a través de la interfaz UART. Aunque este enfoque ofrece flexibilidad, también introduce complejidad en el desarrollo, especialmente en la gestión

de secuencias de configuración, validación de respuestas y manejo de errores. Ante esta situación, resulta necesario contar con una capa de abstracción que simplifique dichas tareas.

La biblioteca desarrollada para el módulo RN2903 de Microchip fue escrita en lenguaje C dentro del entorno de desarrollo MPLAB X. Su propósito es ofrecer un conjunto de funciones que facilitan la configuración y el control del radio, integrando de manera estructurada los comandos necesarios para inicializar, ajustar parámetros y gestionar la comunicación LoRa. Con este enfoque, se busca simplificar el trabajo del desarrollador y garantizar una implementación eficiente y flexible en aplicaciones de IoT [7, 8, 9, 10].

Actualmente existen diferentes bibliotecas para radios LoRa, por ejemplo, Semtech ofrece la biblioteca LoRaMAC-Node, escrita en C y orientada a microcontroladores ARM [7]; la biblioteca Arduino LoRa, desarrollada por Sandeep Mistry, permite un manejo básico de módulos basados en el chip SX127x; RadioLib amplía la compatibilidad hacia múltiples dispositivos LoRa, como la serie RFM9X (95, 96, 97, 98), mediante una arquitectura en C++; estas alternativas requieren de la pila de LoRaWAN en el microcontrolador, ya que los radios son configurados a través de los registros de memoria vía SPI [11].

Dado que el RN2903 de Microchip incorpora de manera nativa la pila LoRaWAN en su firmware, no resulta necesario desarrollar una biblioteca adicional que implemente dicho protocolo. Sin embargo, para facilitar el uso del radio y simplificar la interacción con el módulo, sí es conveniente contar con una biblioteca de comandos AT, la cual permite gestionar de forma estructurada las funciones de configuración, control y transmisión, ofreciendo al desarrollador una interfaz más accesible y eficiente. El desarrollo esta biblioteca se basó en la guía de usuario, donde se describen los comandos de la pila LoRaWAN [12].

Los comandos AT son un conjunto de instrucciones basadas en texto que permiten controlar dispositivos electrónicos, como módems o radios, a través de UART. Su funcionamiento se basa en el envío de cadenas de caracteres ASCII desde un microcontrolador o computadora hacia el dispositivo, el cual interpreta dichas órdenes y responde con mensajes de confirmación o los datos solicitados [13, 14].

Es importante destacar que la biblioteca desarrollada opera en modo LoRa punto a punto, utilizando comandos AT del módulo RN2903 en su modalidad “radio”, sin emplear la pila LoRaWAN integrada. Esta decisión permite un mayor control sobre la transmisión y recepción de datos, así como una implementación más simple para aplicaciones específicas que no requieren infraestructura de red LoRaWAN.

III. Descripción de hardware del nodo

La Figura 1 presenta el diagrama esquemático del nodo IoT desarrollado, el cual está compuesto por una tarjeta PIC-IoT WG de Microchip y el módulo transceptor LoRa RN2903. A diferencia de una arquitectura a nivel de bloques, este diagrama muestra la interconexión eléctrica entre los componentes, destacando principalmente la comunicación mediante la interfaz UART [15, 12, 6].

El microcontrolador PIC24FJ128GA705 actúa como la unidad de procesamiento principal, encargado de ejecutar la biblioteca desarrollada y gestionar la lógica de comunicación. A través de la interfaz UART, el microcontrolador envía comandos AT al módulo RN2903 y recibe las respuestas correspondientes, permitiendo la configuración y operación del enlace LoRa.

El módulo RN2903 integra en su firmware la pila del protocolo LoRaWAN, aunque en este trabajo se emplea únicamente su modo de operación LoRa punto a punto mediante comandos de tipo “radio”. Esta característica permite simplificar la implementación, delegando las funciones de modulación y transmisión al propio módulo. Este opera en la banda de 915 MHz, correspondiente a la región ISM (Industrial, Scientific and Medical en inglés), la cual es de uso libre en países como Estados Unidos y México, sujeta a regulaciones específicas de potencia y uso del espectro.

Adicionalmente, la tarjeta PIC-IoT WG incorpora un módulo de seguridad ATECC608A y conectividad Wi-Fi mediante el dispositivo ATWINC1510; sin embargo, estos elementos no son utilizados en las pruebas experimentales, ya que el enfoque del presente trabajo se centra exclusivamente en la comunicación LoRa.

Entre las características principales del PIC-IoT WG, se tiene:

- MCU PIC24FJ128GA705: arquitectura de 16 bits, bajo consumo, con integración analógica avanzada.
- ATECC608A CryptoAuthentication: elemento seguro para almacenamiento de claves y autenticación basada en hardware.
- ATWINC1510 Wi-Fi: controlador optimizado para aplicaciones alimentadas por batería, con certificación completa.
- Conectividad en la nube: originalmente orientada a Google Cloud IoT Core (ya discontinuado), pero puede integrarse con Amazon AWS mediante herramientas de provisión de Microchip.
- Diseño compacto y listo para usar: pensado para acelerar prototipos IoT con seguridad y conectividad integradas.

Las características del módulo RN2903, como su bajo consumo energético, la integración de la pila de comunicación y su interfaz UART basada en comandos AT, lo

convierten en una solución adecuada para aplicaciones IoT de bajo consumo y largo alcance. Estas propiedades permiten reducir la complejidad en el microcontrolador, ya que las funciones de radiofrecuencia son gestionadas internamente por el módulo. A continuación se listan sus características principales.

- Capa de red integrada: incluye el protocolo LoRaWAN en el firmware.
- Interfaz sencilla: comunicación mediante UART con comandos ASCII.
- Dimensiones compactas: $17.8 \times 26.7 \times 3.34$ mm, con contactos para montaje en PCB.
- Certificaciones: homologado para EE. UU. (FCC, siglas en inglés de Federal Communications Commission), Canadá (IC, siglas en inglés de Industry Canada) y otros países.
- Consumo energético bajo: ideal para dispositivos IoT alimentados por batería.
- Voltaje de operación: 2.1 V a 3.6 V (típico 3.3 V).
- Rango de temperatura: -40°C a $+85^{\circ}\text{C}$.
- Modulación: soporta LoRa y FSK.
- Actualización de firmware (DFU siglas en inglés de Device Firmware Upgrade): posible vía UART.
- Identidad única: incluye EEPROM (siglas en inglés de Electrically Erasable Programmable Read-Only Memory) con dirección EUI-64 (siglas en inglés de Extended Unique Identifier) preprogramada.

IV. Flujo de transmisión y recepción

El funcionamiento de la biblioteca desarrollada se basa en la interacción mediante comandos AT del tipo *radio* entre el microcontrolador PIC24FJ128GA705 y el módulo LoRa RN2903 a través de la interfaz UART. Es importante destacar que el sistema opera en modo LoRa punto a punto, sin emplear la pila LoRaWAN integrada en el módulo, lo que permite un control directo sobre los parámetros de comunicación y simplifica la implementación.

El proceso general de operación se divide en dos modos: transmisión y recepción, ambos estructurados mediante secuencias de configuración, verificación y ejecución. Además, se incorpora un mecanismo de detección de errores que garantiza la robustez de la comunicación, tal como se puede observar en la Figura 2.

IV.1. Transmisión

El proceso de transmisión inicia con la configuración del módulo RN2903 mediante una serie de comandos AT que permiten establecer los parámetros de comunicación, tal como se observa en la Figura 2a. Entre los principales comandos utilizados se encuentran:

- `radio set freq 915000000` (configuración de la frecuencia de operación)

La transmisión queda resumida en los siguientes pasos:

1. Comandos enviados por el microcontrolador al RN2903 para configurarlo en modo LoRa (transmisión).
2. Respuestas de aceptación del RN2903 tras recibir cada comando.
3. Comandos de verificación enviados por el microcontrolador.
4. Respuestas del RN2903 confirmando la correcta configuración.
5. Envío del comando de transmisión en formato hexadecimal.
6. Respuesta del RN2903 indicando si la transmisión fue exitosa.
7. Comando para establecer el modo de sueño por un determinado tiempo en milisegundos.
8. El microcontrolador entra en modo de sueño o realiza otras tareas mientras espera completar la transmisión.

IV.2. Recepción

El proceso de recepción se inicia de manera similar (véase Figura 2b), mediante la configuración del módulo en modo de recepción utilizando los mismos parámetros de comunicación definidos en el transmisor. Una vez verificada la correcta configuración, se activa la recepción mediante el comando:

- `radio rx 0`

Este comando habilita el modo de escucha continua del módulo RN2903. En caso de que los datos sean recibidos correctamente, el módulo responde con:

- `radio_rx <datos>`

donde `<datos>` corresponde a la información recibida en formato hexadecimal. Si no se recibe información o ocurre una falla, se devuelve la respuesta `radio_err`.

Al igual que en el proceso de transmisión, se emplea el comando `sys sleep` para reducir el consumo energético durante periodos de inactividad.

Estos pasos se resumen a continuación:

1. Comandos enviados por el microcontrolador para configurar el RN2903 en modo LoRa (recepción).
2. Respuestas del RN2903 tras recibir cada comando.
3. Comandos de verificación enviados por el microcontrolador.
4. Respuestas del RN2903 confirmando la correcta configuración.
5. Envío del comando de recepción junto con la cantidad de símbolos.
6. Respuesta del RN2903 confirmando si los datos fueron recibidos exitosamente.

7. Comando para establecer el modo de sueño por un determinado tiempo en milisegundos.

IV.3. Manejo de errores

La biblioteca implementa un mecanismo de tolerancia a fallas que permite detectar problemas en la comunicación UART entre el microcontrolador y el módulo RN2903. Este mecanismo se basa en la verificación de la recepción de una línea completa de datos mediante una bandera de control.

En caso de no recibir respuesta del módulo, se considera que ha ocurrido una falla de comunicación. Ante esta situación, el sistema ejecuta una rutina de recuperación que:

1. Finaliza correctamente la cadena almacenada en el buffer.
2. Genera un mensaje de error para notificar al usuario.
3. Reinicia las variables de control del sistema.
4. Permite reintentar el proceso de comunicación.

Este enfoque garantiza una operación robusta del sistema, permitiendo la detección oportuna de errores y la recuperación automática sin necesidad de reiniciar el microcontrolador.

V. Funcionamiento de la biblioteca RN2903

El funcionamiento de la biblioteca se organiza como un flujo estructurado en tres etapas principales: envío de comandos, recepción de respuestas y validación, lo que garantiza una comunicación confiable con el módulo RN2903. La Figura 11 describe de manera detallada el funcionamiento de cada una de ellas.

V.1. Etapa 1: Envío de comandos

En esta etapa, el microcontrolador construye una cadena de caracteres que representa el comando AT a ejecutar. Esta cadena es almacenada en un buffer de transmisión y enviada secuencialmente carácter por carácter a través de la interfaz UART. La Figura 4 muestra el diagrama de flujo de esta etapa.

Este proceso asegura que el módulo RN2903 reciba correctamente la instrucción completa, constituyendo el primer paso en la configuración y control del dispositivo LoRa.

V.2. Etapa 2: Recepción y procesamiento de respuestas

Una vez transmitido el comando, el sistema espera la respuesta del módulo RN2903. La información recibida es almacenada en un buffer de entrada mediante la interfaz UART.

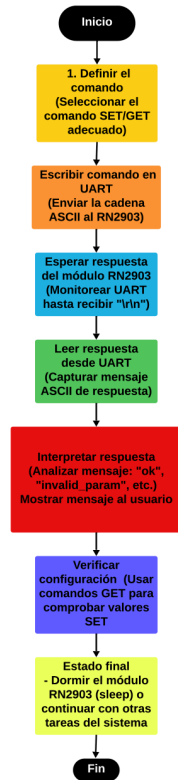


Figura 3: Diagrama de flujo del procesamiento de comandos en la biblioteca RN2903

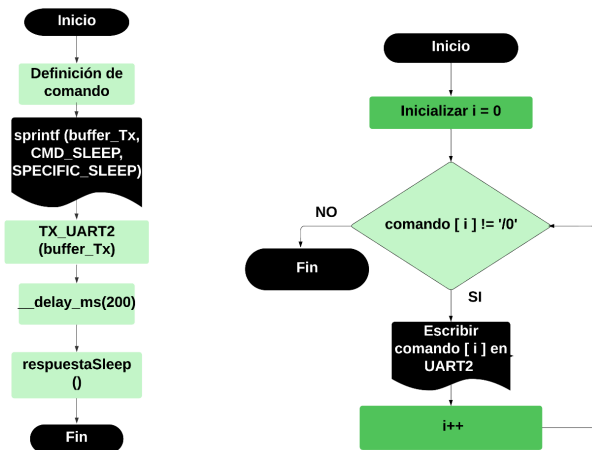


Figura 4: Diagrama de flujo de la etapa de envío de comandos de la biblioteca RN2903

El procesamiento de la respuesta se activa cuando se detecta la recepción completa de una línea de datos. Posteriormente, la cadena recibida es analizada para identificar el estado de la operación solicitada.

Después de procesar la respuesta, las variables de control del buffer son reiniciadas para preparar el sistema para futuras comunicaciones, asegurando la continuidad

del flujo de operación, como se ilustra en la Figura 5.

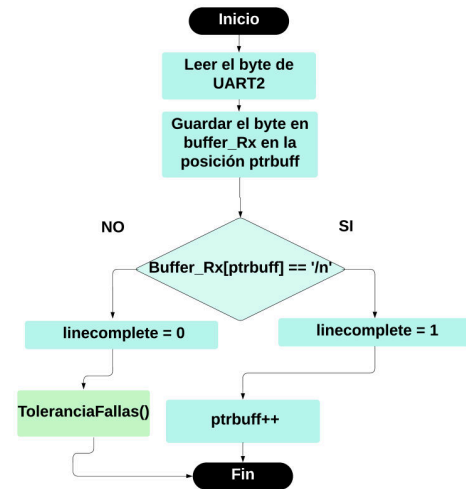


Figura 5: Diagrama de flujo de la etapa de recepción y procesamiento de respuestas de la biblioteca RN2903

V.3. Etapa 3: Validación del comando

En esta etapa, la biblioteca evalúa la respuesta proporcionada por el módulo RN2903 para determinar si el comando fue ejecutado correctamente. Esta validación se basa en la identificación de patrones dentro de la cadena recibida, como los indicadores ok (comando aceptado) o invalid_param (parámetro inválido).

La Figura 6 muestra el diagrama de flujo correspondiente a la etapa de validación de comandos, donde se analiza la respuesta del módulo RN2903 para determinar si la operación fue ejecutada correctamente.

El resultado del análisis permite generar un mensaje de retroalimentación para el usuario, indicando el estado de la operación y facilitando la detección de posibles errores de configuración.

V.4. Mecanismo de tolerancia a fallas

Con el objetivo de garantizar la robustez del sistema, se implementa un mecanismo de tolerancia a fallas que permite detectar errores en la comunicación UART entre el microcontrolador y el módulo RN2903.

Cuando no se recibe una respuesta completa dentro del tiempo esperado, el sistema asume la existencia de un fallo de comunicación y ejecuta una rutina de recuperación que incluye:

1. Finalización segura de la cadena en el buffer.
2. Generación de un mensaje de error para el usuario.
3. Reinicio de las variables de control.
4. Preparación para un nuevo intento de comunicación.

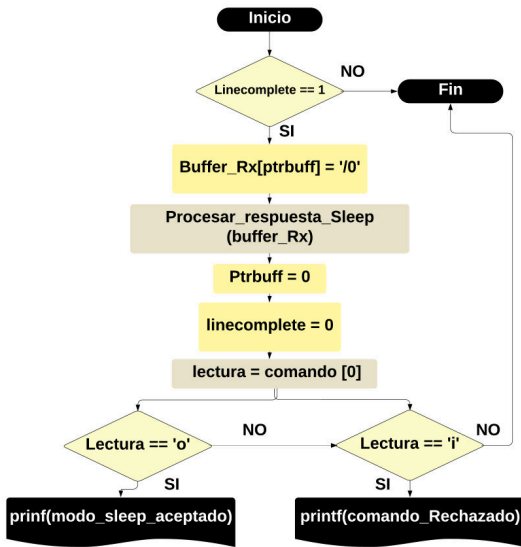


Figura 6: Diagrama de flujo de la etapa de validación de comandos de la biblioteca RN2903

Este mecanismo permite detectar fallos de manera oportuna y recuperar la comunicación sin necesidad de reiniciar el sistema, garantizando una operación continua y confiable.

La Figura 7 muestra el diagrama de flujo del mecanismo de tolerancia a fallas, el cual permite detectar la ausencia de respuesta del módulo RN2903 y ejecutar una rutina de recuperación para mantener la continuidad de la comunicación.

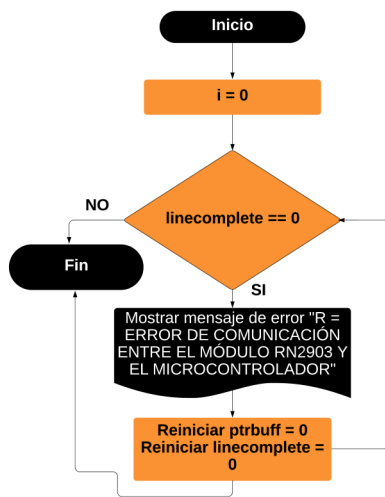


Figura 7: Diagrama de flujo del mecanismo de tolerancia a fallas en la biblioteca RN2903

VI. Resultados experimentales

Con el objetivo de validar el funcionamiento de la biblioteca desarrollada, se realizaron diversas pruebas experimentales que evalúan la configuración del módulo RN2903, la detección de fallas en la comunicación UART y el desempeño del enlace LoRa en escenarios reales.

La Tabla 1 muestra los principales parámetros utilizados durante las pruebas experimentales.

Tabla 1: Parámetros de configuración del dispositivo LoRa

Parámetro	Valor	Descripción
SPECIFIC_MOD	lora	Modo de modulación utilizado.
SPECIFIC_FREQ	915000000	Frecuencia de operación en Hz.
SPECIFIC_PWR	14	Potencia de transmisión en dBm.
SPECIFIC_SF	7	Factor de esparcimiento
SPECIFIC_CRC	on	Activación de la cabecera CRC.
SPECIFIC_IQI	off	Configuración de Invert IQ.
SPECIFIC_CR	4/7	Tasa de codificación.
SPECIFIC_WDT	2000	Tiempo del watchdog (miliseg).
SPECIFIC_SYNC	12	Valor de sincronización.
SPECIFIC_BW	125	Ancho de banda en kHz.

Los parámetros fueron seleccionados con el objetivo de balancear alcance, consumo energético y robustez del enlace LoRa en un entorno urbano.

VI.1. Pruebas de configuración del módulo RN2903

En primer lugar, se verificó la correcta configuración del módulo LoRa RN2903 mediante el envío de comandos AT desde el microcontrolador. Durante este proceso, se observó que el módulo responde adecuadamente a los comandos de configuración, retornando mensajes de aceptación (ok) cuando los parámetros son válidos.

Asimismo, se emplearon comandos de verificación (radio get) para comprobar que los valores configurados coincidieran con los parámetros establecidos, garantizando la correcta operación del sistema.

La Figura 8 muestra un ejemplo de la verificación realizada en la terminal, donde se observan los comandos enviados y las respuestas del módulo RN2903.

```

CONFIGURANDO EL MÓDULO LORA TX
CMD: sys get ver
R = COMANDO_VERSION_GET_SISTEMA_ACEPTADO:
CMD: mac pause
R = COMANDOS_MAC_PAUSE: 4294967245
CMD: radio set mod lora
R = COMANDO_SET_LORA_ACEPTADO
CMD: radio get mod
R = MODO_LORA
    
```

Figura 8: Verificación de configuración del módulo RN2903 mediante comandos AT

VI.2. Pruebas de detección de fallas en la comunicación UART

Se evaluó el mecanismo de tolerancia a fallas implementado en la biblioteca mediante la simulación de errores en la comunicación UART. Para ello, el módulo RN2903 fue desconectado intencionalmente del sistema.

Como resultado, se detectó la ausencia de respuesta del módulo en un tiempo menor a un segundo, generando un mensaje de error en la terminal del usuario y activando una señal visual mediante un LED en la placa de desarrollo. Además, el sistema logró recuperarse automáticamente una vez restablecida la conexión, sin necesidad de reiniciar el microcontrolador.

La Figura 9 muestra el mensaje de error generado durante la prueba, confirmando la detección de la falla en la comunicación entre el microcontrolador y el módulo RN2903.

```

radio rx 977
R = ERROR DE COMUNICACIÓN ENTRE EL MÓDULO RN2903 Y EL MICROCONTROLADOR
Esperando mensaje...
radio rx 977
R = ERROR DE COMUNICACIÓN ENTRE EL MÓDULO RN2903 Y EL MICROCONTROLADOR
Esperando mensaje...
radio rx 977
R = ERROR DE COMUNICACIÓN ENTRE EL MÓDULO RN2903 Y EL MICROCONTROLADOR
Esperando mensaje...
radio rx 977
R = ERROR DE COMUNICACIÓN ENTRE EL MÓDULO RN2903 Y EL MICROCONTROLADOR
Esperando mensaje...
    
```

Figura 9: Mensaje de error de comunicación entre el microcontrolador y el módulo RN2903

Además, el sistema logró recuperarse automáticamente una vez restablecida la conexión, sin necesidad de reiniciar el microcontrolador, validando la robustez del mecanismo implementado.

VI.3. Pruebas de transmisión y recepción LoRa

Para evaluar el desempeño del enlace LoRa, se configuraron dos nodos basados en la tarjeta PIC-IoT WG, uno como transmisor y otro como receptor, ambos equipados con el módulo RN2903.

Las pruebas se realizaron en un entorno urbano, transmitiendo datos de temperatura obtenidos del sensor MCP9808 integrado en la placa. Se evaluó el sistema

durante periodos prolongados de operación continua, obteniendo los resultados que se muestran en la Tabla 2.

Tabla 2: Resultados de las pruebas de transmisión y recepción LoRa

Parámetro	Enlace A	Enlace B
Distancia	560 m	1.1 km
Duración	8 h	12 h
Paquetes enviados	480	720
Paquetes recibidos	472	705
Tasa de pérdida	1.6 %	2.0 %
Intervalo de envío	60 s	60 s

La Figura 10 muestra la primera prueba de transmisión, donde se alcanzó una distancia aproximada de 560 metros con comunicación estable durante 8 horas de operación continua.




Figura 10: Prueba de enlace LoRa A a una distancia de 560 m

Posteriormente, se realizó una segunda prueba en condiciones similares, incrementando la distancia entre los nodos. En esta prueba, se alcanzó una distancia aproximada de 1.1 km, manteniendo comunicación estable durante 12 horas de operación continua.

La Figura 11 muestra la prueba de enlace LoRa B, donde se valida el correcto funcionamiento del sistema a mayor distancia.




Figura 11: Prueba experimental de enlace LoRa B (1.1 km) en entorno urbano

Los resultados obtenidos demuestran que la biblioteca

permite establecer comunicación LoRa confiable en condiciones reales, alcanzando distancias superiores a 1 km con operación estable durante largos periodos.

Cabe destacar que el alcance obtenido es menor al máximo teórico reportado por el fabricante; sin embargo, las pruebas se realizaron en un entorno urbano caracterizado por la presencia de edificaciones y condiciones topográficas que introducen atenuación en la señal. Bajo estas condiciones, el desempeño observado es consistente y valida la funcionalidad del sistema.

VII. Conclusiones

En este trabajo se desarrolló una biblioteca en lenguaje C para la gestión del módulo LoRa RN2903 mediante el microcontrolador PIC24FJ128GA705, con el objetivo de simplificar la configuración y operación del dispositivo en aplicaciones de Internet de las Cosas.

La biblioteca propuesta permite abstraer la complejidad asociada al uso de comandos AT, proporcionando funciones estructuradas para la configuración de parámetros de comunicación, así como para la transmisión y recepción de datos. Además, incorpora mecanismos de retroalimentación y detección de errores que mejoran la robustez del sistema.

Los resultados experimentales demostraron el correcto funcionamiento de la biblioteca en escenarios reales, alcanzando distancias de hasta 1.1 km con comunicación estable durante periodos prolongados. Asimismo, se validó la efectividad del mecanismo de tolerancia a fallas, logrando detectar errores de comunicación en tiempos menores a un segundo y recuperarse automáticamente sin reiniciar el sistema.

En conjunto, la biblioteca desarrollada representa una solución eficiente y accesible para la implementación de sistemas IoT basados en LoRa, facilitando su adopción por desarrolladores con conocimientos intermedios en sistemas embebidos.

Como trabajo futuro, se plantea la incorporación de técnicas de optimización energética, la inclusión de métricas adicionales de calidad de enlace y la extensión de la biblioteca para su uso en otras plataformas de microcontroladores.

Referencias

- [1] Mario Cruz Vega et al. *Las tecnologías IOT dentro de la industria conectada: Internet of things*. EOI Escuela de Organización Industrial, 2015.
- [2] Joan Miquel Solé. «Improving the usability of a LoRa Mesh Library». B.S. thesis. Universitat Politècnica de Catalunya, 2022.

- [3] Aloÿs Augustin et al. «A study of LoRa: Long range & low power networks for the internet of things». En: *Sensors* 16.9 (2016), pág. 1466.
- [4] ML Liya y D Arjun. «A survey of LPWAN technology in agricultural field». En: *2020 Fourth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*. IEEE. 2020, págs. 313-317.
- [5] Anne H Ngu et al. «IoT middleware: A survey on issues and enabling technologies». En: *IEEE Internet of Things Journal* 4.1 (2016), págs. 1-20.
- [6] Microchip RN2903. *Tomado en línea*: <http://ww1.microchip.com/downloads/en/DeviceDoc/50002390E.pdf>. 2024.
- [7] Luis Felipe Patiño Lopez y et al. «Diseño e implementación de un sistema embebido basado en IoT para la gestión del transporte público». 2019.
- [8] Matheus Ferreira Bernardo de Souza. «Biblioteca de rede baseada em LoRa: Uma solução independente da plataforma». 2023.
- [9] Rajkumar Buyya y Amir Vahid Dastjerdi. *Internet of Things: Principles and paradigms*. Elsevier, 2016.
- [10] Alexandru Lavric y Valentin Popa. «Internet of things and LoRa™ low-power wide-area networks: a survey». En: *2017 International Symposium on Signals, Circuits and Systems (ISSCS)*. IEEE. 2017, págs. 1-5.
- [11] Joan Miquel Solé et al. «Implementation of a LoRa mesh library». En: *IEEE access* 10 (2022), págs. 113-171.
- [12] Documentación-Microchip. *Tomado en la web*: <https://www.microchip.com/en-us/development-tool/ac164164>. 2024.
- [13] Microchip Technology Inc. *MPLAB® Code Configurator User's Guide*. Último acceso: 28 de agosto de 2024. 2024. URL: <https://www.microchip.com/mplab/mplab-code-configurator>.
- [14] Carlos A Henao y Edison Duque. «Programando microcontroladores PIC en lenguaje C». En: *Scientia et Technica* 3.43 (2009).
- [15] Guía del usuario PIC-IoT WG. *PIC-IoT WG Hardware User Guide*. 2020.