

# EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



Instituto Politécnico Nacional  
"La Técnica al Servicio de la Patria"

# Research in Computing Science

**Vol. 153 No. 5**  
**May 2024**

# **Research in Computing Science**

---

## **Series Editorial Board**

### **Editors-in-Chief:**

*Grigori Sidorov, CIC-IPN, Mexico  
Gerhard X. Ritter, University of Florida, USA  
Jean Serra, Ecole des Mines de Paris, France  
Ulises Cortés, UPC, Barcelona, Spain*

*Jesús Angulo, Ecole des Mines de Paris, France  
Jihad El-Sana, Ben-Gurion Univ. of the Negev, Israel  
Alexander Gelbukh, CIC-IPN, Mexico  
Ioannis Kakadiaris, University of Houston, USA  
Petros Maragos, Nat. Tech. Univ. of Athens, Greece  
Julian Padget, University of Bath, UK  
Mateo Valero, UPC, Barcelona, Spain  
Olga Kolesnikova, ESCOM-IPN, Mexico  
Rafael Guzmán, Univ. of Guanajuato, Mexico  
Juan Manuel Torres Moreno, U. of Avignon, France  
Miguel González-Mendoza, ITESM, Mexico*

### **Associate Editors:**

**Editorial Coordination:**  
*Griselda Franco Sánchez*

**Research in Computing Science**, Año 23, Volumen 153, No. 5, mayo de 2024, es una publicación mensual, editada por el Instituto Politécnico Nacional, a través del Centro de Investigación en Computación. Av. Juan de Dios Bátiz S/N, Esq. Av. Miguel Othon de Mendizábal, Col. Nueva Industrial Vallejo, C.P. 07738, Ciudad de México, Tel. 57 29 60 00, ext. 56571. <https://www.rcs.cic.ipn.mx>. Editor responsable: Dr. Grigori Sidorov. Reserva de Derechos al Uso Exclusivo del Título No. 04-2019-082310242100-203. ISSN: en trámite, ambos otorgados por el Instituto Politécnico Nacional de Derecho de Autor. Responsable de la última actualización de este número: el Centro de Investigación en Computación, Dr. Grigori Sidorov, Av. Juan de Dios Bátiz S/N, Esq. Av. Miguel Othon de Mendizábal, Col. Nueva Industrial Vallejo, C.P. 07738. Fecha de última modificación 01 de mayo de 2024.

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 del Instituto Politécnico Nacional.

**Research in Computing Science**, year 23, Volume 153, No. 5, May 2024, is published monthly by the Center for Computing Research of IPN.

The opinions expressed by the authors does not necessarily reflect the editor's posture.

All rights reserved. No part of this publication may be reproduced, stored in a retrieval system, or transmitted, in any form or by any means, electronic, mechanical, photocopying, recording or otherwise, without prior permission of Centre for Computing Research of the IPN.

# **Advances in Computing Science and Applications**

**Ana María Magdalena Saldaña-Pérez  
Yanil Zuleima Contreras Jiménez (eds.)**



**Instituto Politécnico Nacional  
"La Técnica al Servicio de la Patria"**



**Instituto Politécnico Nacional, Centro de Investigación en Computación  
México 2024**

## **ISSN: in process**

---

---

Copyright © Instituto Politécnico Nacional 2024  
Formerly ISSNs: 1870-4069, 1665-9899

Instituto Politécnico Nacional (IPN)  
Centro de Investigación en Computación (CIC)  
Av. Juan de Dios Bátiz s/n esq. M. Othón de Mendizábal  
Unidad Profesional “Adolfo López Mateos”, Zácatenco  
07738, México D.F., México

<http://www.rcc.cic.ipn.mx>  
<http://www.ipn.mx>  
<http://www.cic.ipn.mx>

The editors and the publisher of this journal have made their best effort in preparing this special issue, but make no warranty of any kind, expressed or implied, with regard to the information contained in this volume.

All rights reserved. No part of this publication may be reproduced, stored on a retrieval system or transmitted, in any form or by any means, including electronic, mechanical, photocopying, recording, or otherwise, without prior permission of the Instituto Politécnico Nacional, except for personal or classroom use provided that copies bear the full citation notice provided on the first page of each paper.

Indexed in LATINDEX, DBLP and Periodica

Electronic edition

## Table of Contents

	Page
Modelo de evaluación de la calidad del aire interior empleado el proceso analítico jerárquico .....	5
<i>Miguel Angel Olvera-García, José Juan Carbajal-Hernández, Gabriel de Jesús Rodríguez-Jordán</i>	
CAD Design of a Robotic Thumb of 4 DOF .....	21
<i>Luis Fernando Dzul-Maldonado, Eduardo Morales-Sánchez</i>	
Synthetic EEG Signal Generator of Morphologies Associated with Epileptogenic Events .....	35
<i>José-Emmanuel Vázquez-Galán, Blanca Tovar-Corona, Laura-Ivoone Garay-Jiménez</i>	
Propuesta de sistema computacional para incendios forestales y clasificación de días con riesgo a incendio usando temperatura y humedad en una reserva natural, caso de estudio.....	55
<i>Carlos Sebastián Maya-Rojina, Luis Pastor Sánchez-Fernández, Mario Eduardo Rivero-Ángeles</i>	



## Modelo de evaluación de la calidad del aire interior empleado el proceso analítico jerárquico

Miguel Angel Olvera-García, José Juan Carbajal-Hernández,  
Gabriel de Jesús Rodríguez-Jordán

Instituto Politécnico Nacional,  
Centro de Investigación en Computación,  
México

[ma.olvera58@gmail.com](mailto:ma.olvera58@gmail.com), [jcarbajalh@cic.ipn.mx](mailto:jcarbajalh@cic.ipn.mx),  
[gabrielrodriguezj@hotmail.com](mailto:gabrielrodriguezj@hotmail.com)

**Resumen.** La contaminación del aire interior es un problema común en las grandes ciudades del mundo. Varios gobiernos han emitido normas para evaluar los parámetros del aire interior. En zonas con alta densidad de población, las personas permanecen confinadas en hogares y oficinas por períodos prolongados, respirando el aire interior sin saber cómo está la contaminación del entorno. Este artículo presenta un modelo de evaluación que utiliza el Análisis de Procesos Jerárquicos (AHP) utilizando dos factores de evaluación: uno que evalúa el nivel de toxicidad de los contaminantes del aire interior (TF) y otro que evalúa el confort de la habitación (CF). Finalmente, se calculó la suma de ambos factores para obtener un índice de calidad del aire interior (HIAQI). Los parámetros ambientales utilizados en este índice incluyen partículas finas (PM1), (PM2.5) y (PM10), compuestos orgánicos volátiles totales (TVOC), ozono (O3) y monóxido de carbono (CO) para el factor TF y nitrógeno, dióxido (NO2), dióxido de azufre (SO2), formaldehído (CH2O), dióxido de carbono (CO2), temperatura (TEMP) y humedad relativa (RH) para el factor CF. Según la toxicidad o el nivel de confort, se calculan los pesos individuales de cada contaminante, teniendo una valoración precisa en el cálculo de la calidad del aire interior. Finalmente, el modelo propuesto considera seis etapas de puntuación: excelente, buena, regular, mala, muy mala y peligrosa. Los resultados se compararon contra otros índices de la literatura, mostrando un excelente desempeño del HIAQI en comparación con los índices propuestos en la literatura mundial, proporcionando, mejores evaluaciones cuando se asignaron pesos de jerarquía de acuerdo con la importancia de cada parámetro, dentro de la contaminación del aire interior.

**Palabras clave.** Calidad del aire, interior, sistema de inferencia difusa, proceso analítico jerárquico.

## Indoor Air Quality Assessment Model Using the Hierarchical Analytical Process

**Abstract.** Indoor air pollution is a common problem in large cities around the world. Several governments have issued standards to evaluate indoor air parameters. In areas with high population density, people remain confined to homes and offices for long periods, breathing indoor air without knowing what the pollution in the

environment is like. This article presents an evaluation model that uses Hierarchical Process Analysis (AHP) using two evaluation factors: one that evaluates the level of toxicity of indoor air pollutants (TF) and another that evaluates room comfort (CF). Finally, the sum of both factors was calculated to obtain an indoor air quality index (HIAQI). The environmental parameters used in this index include fine particles (PM1), (PM2.5) and (PM10), total volatile organic compounds (TVOC), ozone (O<sub>3</sub>) and carbon monoxide (CO) for the TF factor and nitrogen dioxide (NO<sub>2</sub>), sulfur dioxide (SO<sub>2</sub>), formaldehyde (CH<sub>2</sub>O), carbon dioxide (CO<sub>2</sub>), temperature (TEMP) and relative humidity (RH) for the CF factor. Depending on the toxicity or comfort level, the individual weights of each pollutant are calculated, having a precise assessment in the calculation of indoor air quality. Finally, the proposed model considers six scoring stages: excellent, good, average, bad, very bad and dangerous. The results were compared against other indices in the literature, showing an excellent performance of the HIAQI in comparison with the indices proposed in the world literature, providing better evaluations when hierarchy weights were assigned according to the importance of each parameter, within the indoor air pollution.

**Keywords:** Air quality, indoor, fuzzy inference system, analytic hierarchy process.

## 1. Introducción

La contaminación del aire interior es un problema de salud para la población de las grandes ciudades del mundo [1]. También, se han observado grandes niveles de contaminantes dentro de las estaciones de metro [2], incluso en las zonas rurales donde se quema madera y otros biocombustibles para cocinar y calentar agua para el aseo personal [3]. La pandemia provocó que millones de personas estuvieran confinadas en sus hogares, respirando el aire interior por períodos prolongados, afectando en algunos casos el rendimiento de las personas debido al síndrome del edificio enfermo [4]. Esta situación hace necesario vigilar la calidad del aire interior ya que, actualmente, esta actividad no está normalizada.

Por otro lado, el seguimiento de la calidad del aire exterior se ha estandarizado en todo el mundo. Sin embargo, muy pocos gobiernos en el mundo han emitido normas para evaluar los parámetros del aire interior. Además, dentro de la literatura mundial se han propuesto diversos modelos de evaluación de la calidad del aire interior [5], [6], [7]. El modelo de Saad se realiza por la normalización de los parámetros y presenta valores altos. El modelo Dionova sólo analiza 8 parámetros, mientras que el modelo propuesto analiza 12 parámetros. Los modelos de Saad y Dionova no consideran el grado de toxicidad de los contaminantes ni dan prioridad a los contaminantes críticos del aire interior.

De la misma manera, Dionova no revisa las PM10 en su análisis, y Saad, en su análisis, no considera las PM2.5. Además, el modelo de Rickenbacker es muy novedoso debido a que incluye contaminantes como PM0.5, PM1 y PM5 que son contaminantes donde aún no existen en el mercado sensores para monitorear estas partículas. Desafortunadamente, no establece los promedios anuales de estas partículas, ni detalla el método para evaluar los 13 contaminantes que enumera. Los límites máximos permisibles de los doce contaminantes evaluados por el Índice Jerárquico de la Calidad del Aire Interior (Hierarchical Indoor Air Quality Index HIAQI) se muestran a continuación en la Tabla 1.

**Tabla 1.** Límites máximos permisibles de contaminantes HIAQI.

Units	PM <sub>1</sub>	PM <sub>2.5</sub>	PM <sub>10</sub>	TVOC	CH <sub>2</sub> O	O <sub>3</sub>	CO	NO <sub>2</sub>	SO <sub>2</sub>	CO <sub>2</sub>	TEM	RH
	$\mu\text{g}/\text{m}^3$					ppm					°C	%
HIAQI	8	15	50	500	50	0.06	9	0.08	0.08	700	20-25	40-70

Por otro lado, algunas agencias especializadas que han emitido regulaciones para regular el aire exterior se han preocupado por emitir algunas regulaciones para el aire interior. Como la Agencia de Protección Ambiental [8], el Departamento de Protección Ambiental de Hong Kong [9] y la Guía de Calidad del Aire Interior de Singapur [10], la Administración Americana de Seguridad y Salud Ocupacional [11], la Conferencia Americana de Higienistas Industriales del Gobierno [12] y el Departamento de Salud y Seguridad Ocupacional de Malasia [13].

### 1.1. Contribución

El modelo propone una mejora a los modelos propuestos por Saad y Dionova y otros de la literatura, utilizando la normalización de parámetros que se complementa con el análisis de procesos jerárquicos.

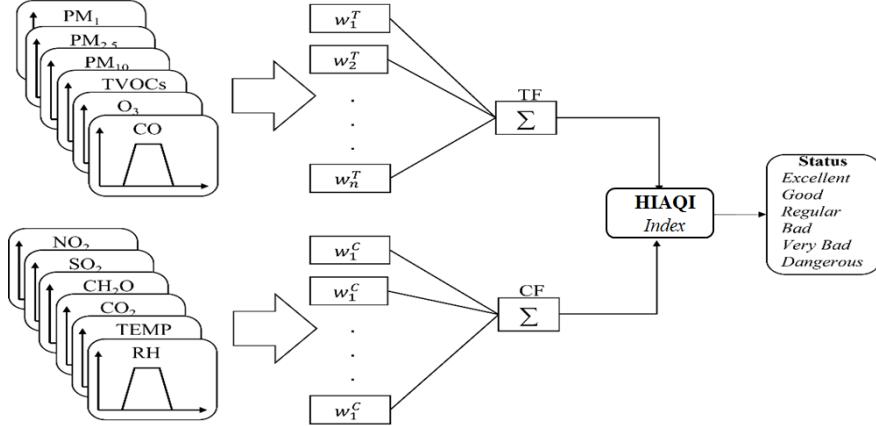
### 1.2. Hipótesis

Mediante un modelo computacional que utilice la normalización de parámetros y el análisis de procesos jerárquicos se puede hacer el monitoreo del aire interior que permita establecer los momentos críticos de contaminación del aire interior, para emitir las alertas que permitan advertir a los usuarios para abrir las ventanas, así como a los sistemas de control automático para activar los ventiladores. El modelo consta del análisis de 12 contaminantes del aire interior agrupados en dos factores. Un factor de toxicidad de los contaminantes y otro factor de confort de la habitación.

## 2. Métodos y materiales

### 2.1. Modelo de medición de calidad del aire interior

Para asignar un peso prioritario a cada parámetro, primero se deben normalizar las concentraciones de los contaminantes con base en los límites máximos permisibles y la escala de la USEPA que va de [0-500] puntos [14]. Donde 0 es una concentración no tóxica y 1 es cuando la escala es de 500 puntos, suponiendo una calidad del aire interior contaminado. Una vez normalizada la concentración, se asignará un peso de jerarquía para afinar la evaluación. Este proceso se puede observar en la Fig. 1.



**Fig. 1.** Arquitectura del modelo HIAQI utilizando dos modelos TF y CF.

## 2.2. Normalización de parámetros

Para normalizar cada parámetro, se utilizaron las fórmulas de estandarización del factor TF que se muestran en las fórmulas (1) al (6). Esto permitió transformar las concentraciones en un escalar dentro de un rango de 0 a 500 puntos:

$$I[PM_1] = C[PM_1] * \frac{100}{8} \text{ para cualquier concentración,} \quad (1)$$

$$I[PM_{2.5}] = C[PM_{2.5}] * \frac{100}{15} \text{ para cualquier concentración,} \quad (2)$$

$$I[PM_{10}] = C[PM_{10}] * \frac{100}{50} \text{ para cualquier concentración,} \quad (3)$$

$$I[TVOCS] = C[TVOCS] * \frac{100}{500} \text{ para cualquier concentración,} \quad (4)$$

$$I[O_3] = C[O_3] * \frac{100}{0.06} \text{ para cualquier concentración,} \quad (5)$$

$$I[CO] = C[CO] * \frac{100}{9} \text{ para cualquier concentración.} \quad (6)$$

Fórmulas de estandarización de parámetros del factor TF.

También se utilizaron las fórmulas de estandarización del factor CF que se muestran en las fórmulas (7) al (12). Esto permitió transformar las concentraciones en un escalar que va de 0 a 500 puntos. También hay que señalar que en ambos casos las concentraciones son demasiado altas. La estandarización de parámetros permite superar los límites de escala:

$$I[NO_2] = C[NO_2] * \frac{100}{0.08} \text{ para cualquier concentración,} \quad (7)$$

$$I[SO_2] = C[SO_2] * \frac{100}{0.08} \text{ para cualquier concentración,} \quad (8)$$

### *Modelo de evaluación de la calidad del aire interior empleado el proceso analítico jerárquico*

$$I[CH_2O] = C[CH_2O] * \frac{100}{50} \text{ para cualquier concentración,} \quad (9)$$

$$I[CO_2] = C[CO_2] * \frac{100}{700} \text{ para cualquier concentración,} \quad (10)$$

$$I[TEMP] = C[TEMP] * \frac{100}{25} \text{ para cualquier concentración,} \quad (11)$$

$$I[RH] = C[RH] * \frac{100}{40} \text{ para cualquier concentración.} \quad (12)$$

Fórmulas de estandarización de parámetros del factor CF.

Las ecuaciones (13) y (14) según sea el caso y de acuerdo con la Fig. 1 para asignar los pesos de ponderación, donde w es el peso seleccionado del parámetro de cada factor TF o CF. Cuando dos o más salidas tengan el mismo valor de puntuación, se utilizará el peso de mayor prioridad de la siguiente manera:

$$TF = I[PM1] * w_1 + I[PM2.5] * w_2 + I[PM10] * w_3 + I[TVOCs] * w_4 + I[O3] * w_5 + I[CO] * w_6, \quad (13)$$

$$CF = I[NO2] * w_1 + I[SO2] * w_2 + I[CH2O] * w_3 + I[CO2] * w_4 + I[TEMP] * w_5 + I[RH] * w_6. \quad (14)$$

### **2.3. Índice de calidad del aire interior**

Después de normalizar las concentraciones de los doce contaminantes de los factores TF y CF con una escala de 0 a 500 puntos para obtener el índice de calidad del aire con el análisis de procesos jerárquicos (HIAQI). Éste se calculó mediante la suma vectorial de los factores TF y CF, y el resultado es un escalar que varía de 0 a los 500 puntos. Finalmente, una vez obtenidos los escalares de los factores TF y CF, ambos escalares se integran en una única escala de salida de rango de 0 a 500 puntos que describe seis etapas de puntuación como son: *excelente, bueno, regular, malo, muy malo y peligroso*.

Aplicando la jerarquía a los contaminantes más tóxicos y diferenciando la importancia al momento de calcular cada factor. Esta suma garantiza que el puntaje obtenido no sea mayor que la escala final. Ya que las diferentes subescalas proporcionan una interpretación completa del estado de HIAQI, como son: excelente [0 - 50], bueno (51 - 100], regular (101 - 150], malo (151 - 200], muy malo (201 - 300] y peligroso [301 - 500]. La expresión (15) se debe usar para obtener el HIAQI:

$$HIAQI = \frac{\sqrt{TF^2 + CF^2}}{1.4143}. \quad (15)$$

### **2.4. Análisis de procesos jerárquicos (AHP)**

El análisis de procesos jerárquicos (AHP) propuesto por Thomas L. Saaty [14] es un método que permite transformar e interpretar los niveles de una jerarquía de los contaminantes en pesos matemáticos que permitirán ajustar la salida del sistema. Los pesos utilizados en el AHP afectan el resultado de la evaluación según el parámetro más

**Tabla 2.** Interpretación de la escala de importancia según Saaty.

Scale	1	2	3	4	5	6	7	8	9
Importance	Equal	Weak	Moderate	Moderate+	Strong	Strong+	Very Strong	Very Strong+	Extreme
TF	CO	O <sub>3</sub>		TVOCS	PM <sub>10</sub>		PM <sub>2.5</sub>	PM <sub>1</sub>	
CF	RH	TEMP		CO <sub>2</sub>	CH <sub>2</sub> O		SO <sub>2</sub>	NO <sub>2</sub>	

crítico, proporcionando una evaluación más consistente [15]. La Tabla 2 proporciona un orden de prioridad para cada contaminante en una escala de importancia.

Los niveles de importancia se eligieron en función de los requisitos de la calidad del aire interior para la salud humana. Las comparaciones de las relaciones entre los parámetros (PR) del factor TF se pueden describir de la siguiente manera:

- PR1: PM<sub>1</sub> tiene una débil importancia sobre las PM<sub>2.5</sub> porque PM<sub>1</sub> ingresa al torrente sanguíneo y afecta a todo el cuerpo, mientras que PM<sub>2.5</sub> afecta a los pulmones.
- PR2: Las PM<sub>1</sub> tienen una importancia moderada sobre las PM<sub>10</sub> porque las PM<sub>10</sub> afectan sólo a la garganta, la faringe y la laringe.
- PR3: PM<sub>1</sub> es muy importante sobre los TVOC porque los TVOC afectan a los tejidos gramos, principalmente en mujeres embarazadas porque pueden afectar al feto.
- PR4: PM<sub>1</sub> tiene una importancia muy fuerte sobre el O<sub>3</sub> porque los efectos del O<sub>3</sub> afectan a los tejidos vivos y están asociados con algunas enfermedades.
- PR5: Las PM<sub>1</sub> son de extrema importancia sobre el CO porque el CO sólo en altas concentraciones y durante períodos prolongados pueden causar la muerte.

Según el parámetro CF, las relaciones de comparación se pueden describir como:

- PR1: El NO<sub>2</sub> tiene una débil importancia sobre el SO<sub>2</sub> porque el NO<sub>2</sub> corroe los tejidos afecta e irrita las vías respiratorias, y el SO<sub>2</sub> irrita los ojos, la garganta y las vías respiratorias.
- PR2: El NO<sub>2</sub> tiene una importancia moderada sobre el CH<sub>2</sub>O porque el CH<sub>2</sub>O produce irritación en la nariz, garganta y los ojos.
- PR3: El NO<sub>2</sub> es muy importante sobre el CO<sub>2</sub> porque el CO<sub>2</sub> afecta solo a la función respiratoria.
- PR4: El NO<sub>2</sub> tiene una importancia muy fuerte sobre la TEMP porque las altas TEMP afectan la respiración y el ritmo cardíaco.
- PR5: El NO<sub>2</sub> es de extrema importancia sobre la RH porque la RH causa irritación ocular y efectos en las vías respiratorias.

## 2.5. Cálculo de pesos

Para transformar los niveles de jerarquía en pesos según la prioridad de los contaminantes. Es decir, hacer la comparación por pares. Donde los valores de importancia asignados a cada parámetro se utilizaron para desarrollar una matriz definida positiva,

**Tabla 3.** Matriz de comparación de pares del factor TF.

	PM <sub>1</sub>	PM <sub>25</sub>	PM <sub>10</sub>	TVOCS	O <sub>3</sub>	CO
PM <sub>1</sub>	1	9/8	9/7	9/5	9/3	9
PM <sub>25</sub>	8/9	1	8/7	8/5	8/3	8
A <sub>TF</sub> =	PM <sub>10</sub>	7/9	7/8	1	7/5	7/3
	TVOCS	5/9	5/8	5/7	1	5/3
	O <sub>3</sub>	3/9	3/8	3/7	3/5	1
	CO	1/9	1/8	1/7	1/5	1/3

**Tabla 4.** Matriz de comparación de pares del factor CF.

	NO <sub>2</sub>	SO <sub>2</sub>	CH <sub>2</sub> O	CO <sub>2</sub>	TEMP	RH
NO <sub>2</sub>	1	9/8	9/7	9/5	9/3	9
SO <sub>2</sub>	8/9	1	8/7	8/5	8/3	8
A <sub>CF</sub> =	CH <sub>2</sub> O	7/9	7/8	1	7/5	7/3
	CO <sub>2</sub>	5/9	5/8	5/7	1	5/3
	TEMP	3/9	3/8	3/7	3/5	1
	RH	1/9	1/8	1/7	1/5	1/3

consistente y recíproca de  $[n \times n]$  cuyos elementos satisfacen el  $a_{ij} \cdot a_{jk} = a_{ik}$ , para  $i, j$  y  $k = 1, \dots, n$ . Este par también se puede representar de la siguiente manera:

$$A = P_1 \begin{bmatrix} P_1 & P_2 & \cdots & P_n \\ a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ P_n & a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} = \begin{bmatrix} \frac{w_1}{w_1} & \frac{w_1}{w_2} & \cdots & \frac{w_1}{w_n} \\ \frac{w_2}{w_1} & \frac{w_2}{w_2} & \cdots & \frac{w_2}{w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{w_n}{w_1} & \frac{w_n}{w_2} & \cdots & \frac{w_n}{w_n} \end{bmatrix}, \quad (16)$$

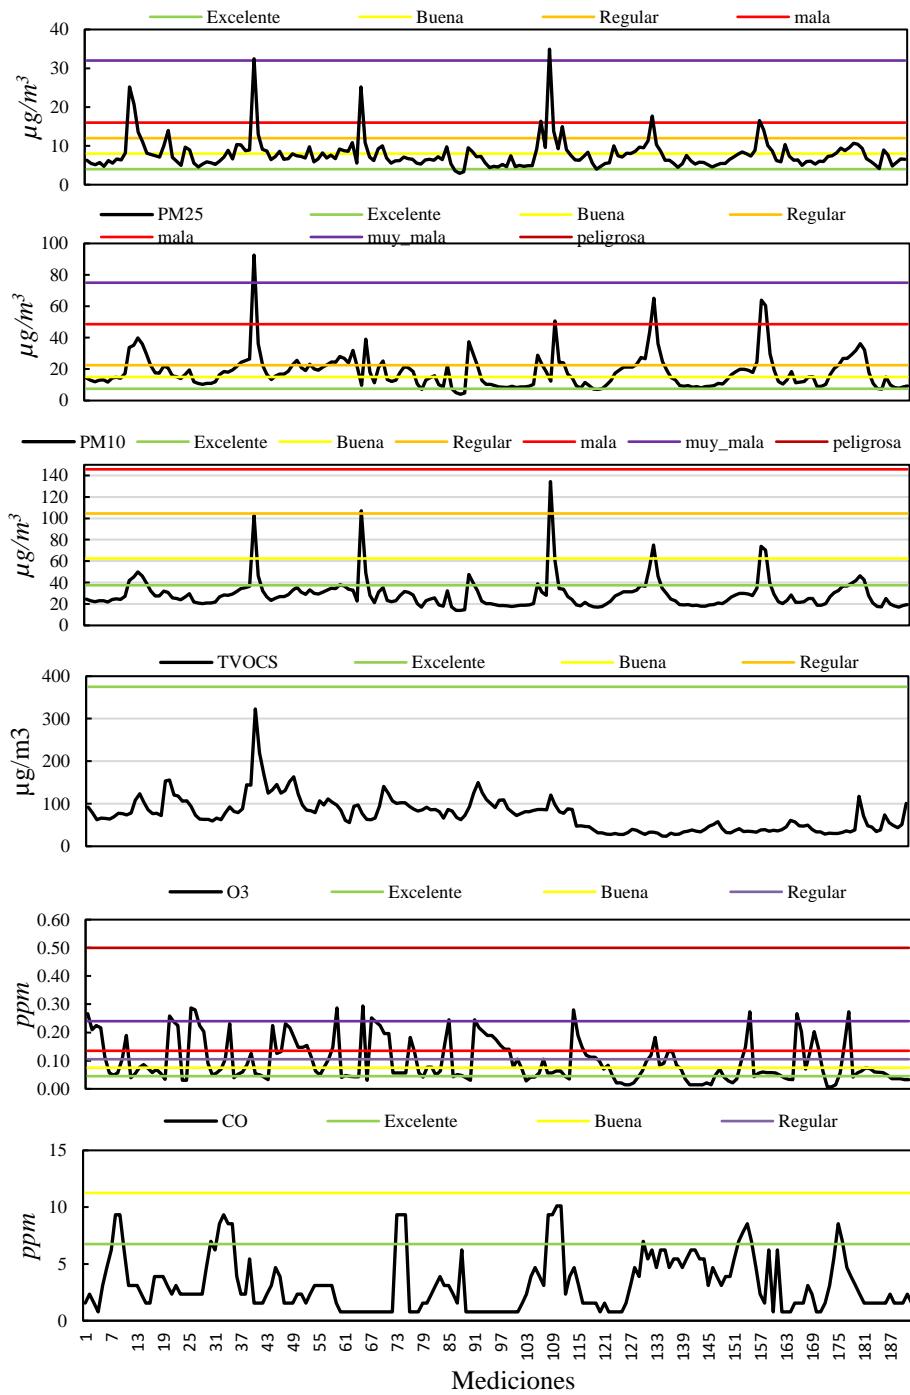
donde  $W_i$  es la escala de importancia del parámetro (P), según los valores de la escala de Saaty y asignados en las relaciones anteriores (PR) y reemplazados en la ecuación 16. Para este caso se construyeron dos matrices correspondientes a los factores TF y CF como se muestra en las tablas (3, 4).

Las matrices cuadradas A y B se calculan mediante la siguiente expresión:

$$B = A \times A = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \times \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix}. \quad (17)$$

La suma de las filas se calcula mediante la siguiente ecuación:

$$C_i = \sum_{j=1}^n B_{ij} \quad \forall i = 1, 2, \dots, n. \quad (18)$$



**Fig. 2.** Variación diaria de los contaminantes del factor TF (1 al 8 de julio de 2022).

**Tabla 5.** Índice de consistencia aleatoria RI.

Matrix Size ( $n$ )	1	2	3	4	5	6	7	8	9	10
RI	0	0	0.52	0.89	1.11	1.25	1.35	1.4	1.45	1.49

Posteriormente, los pesos de prioridad se obtienen normalizando el Vector  $C_i$  de la siguiente manera:

$$w_i = \frac{C_i}{\sum_{j=1}^n C_j} \quad \forall i = 1, 2, \dots, n, \quad (19)$$

donde  $w_i$  es el vector de pesos, el resultado se conoce como el vector propio que fue propuesto por Perron [17]. Este proceso se debe repetir hasta que la solución del vector propio no cambie respecto a la iteración anterior. Los pesos de ponderación determinados de cada contaminante se calculan de la siguiente manera:

$$\mathbf{w}^{TF} = \begin{bmatrix} PM_1 \\ PM_{2.5} \\ PM_{10} \\ TVOC'_S \\ O_3 \\ CO \end{bmatrix} = \begin{bmatrix} 0.27536 \\ 0.24477 \\ 0.20994 \\ 0.14996 \\ 0.08999 \\ 0.02999 \end{bmatrix}, \quad (20)$$

$$\mathbf{w}^{CF} = \begin{bmatrix} NO_2 \\ SO_2 \\ CH2O \\ CO_2 \\ TEMP \\ HR \end{bmatrix} = \begin{bmatrix} 0.27536 \\ 0.24477 \\ 0.20994 \\ 0.14996 \\ 0.08999 \\ 0.02999 \end{bmatrix}, \quad (21)$$

Finalmente, el radio de consistencia (CR) de las matrices  $A_{TF}$  y  $A_{CF}$  deberán calcularse usando la siguiente expresión:

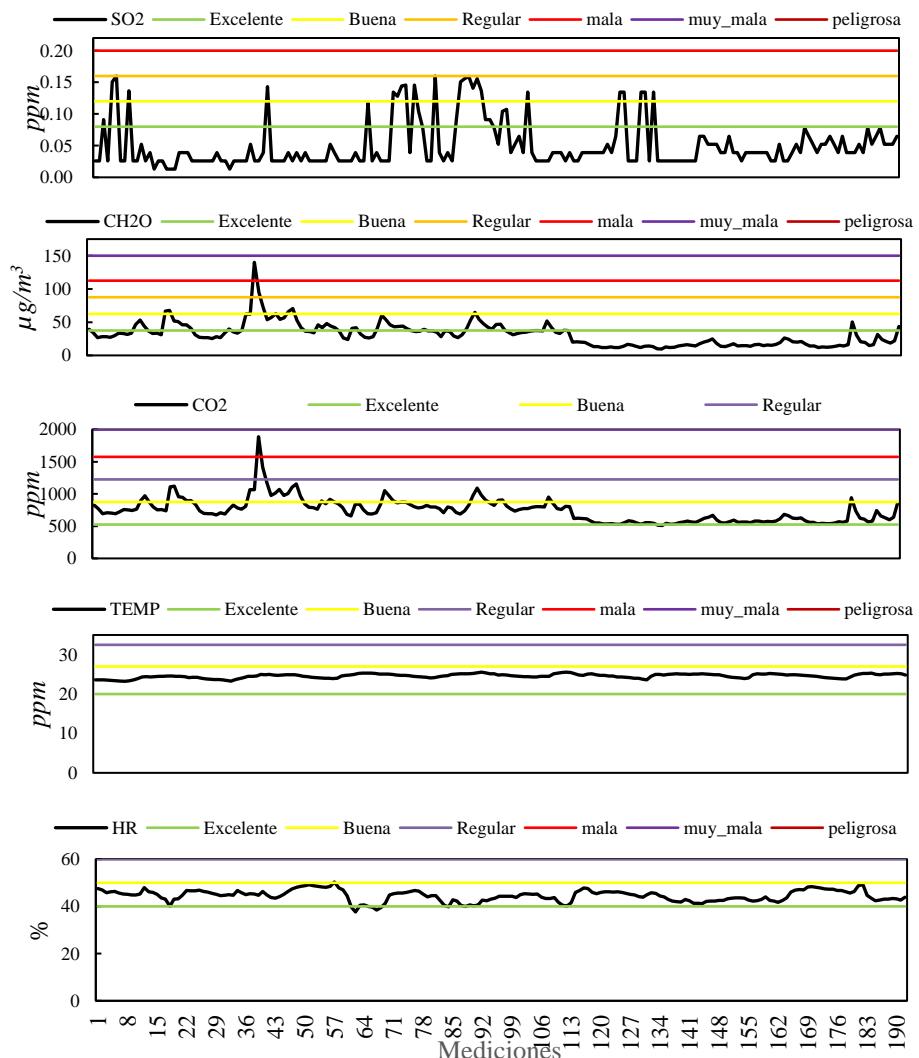
$$CR = \frac{\lambda_{max} - n}{(n-1)RI}, \quad (22)$$

donde  $\lambda_{max}$  son los valores más adecuados de las matrices de comparación de pares,  $n$  es el tamaño de la matriz y RI es el índice de consistencia aleatoria que, según la Tabla 5, es 1,25. En este caso, las matrices de comparación de pares deberán de tener un rango de consistencia (CR) máxima del 10%. Por tanto, el CR obtenido es del 1% (0.01), lo que significa que es aceptable.

### 3. Resultados

#### 3.1. Análisis del factor toxicológico

Para mostrar el comportamiento diario de los parámetros de calidad del aire interior, la Fig. 2 muestra una semana de mediciones (del 1 al 8 de julio de 2022), donde se obtuvieron las evaluaciones a cada hora mediante el promedio móvil de las concentraciones de los parámetros. Se puede ver que diariamente por la tarde, las  $PM_1$ ,  $PM_{2.5}$  y  $O_3$  exceden el nivel muy malo (la línea roja) de los 200 puntos. Sin embargo, durante todo el año, se



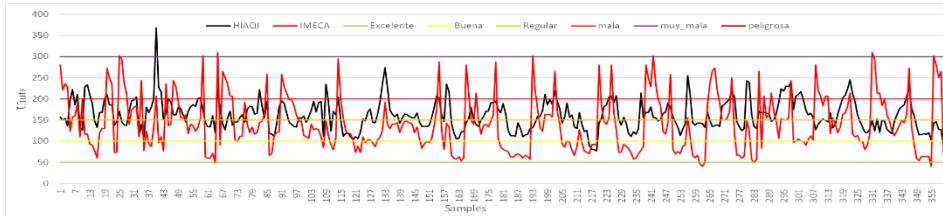
**Fig. 3.** Variación diaria de los contaminantes del factor CF (1 al 8 de julio de 2022).

observó que estos tres contaminantes excedieron considerablemente los 150 puntos ya que, de los 8760 registros de todo el año, 2,845, 5145 y 2441 evaluaciones, respectivamente, rebasan los 150 puntos. Mientras que los TVOC no exceden la línea verde de 50 puntos.

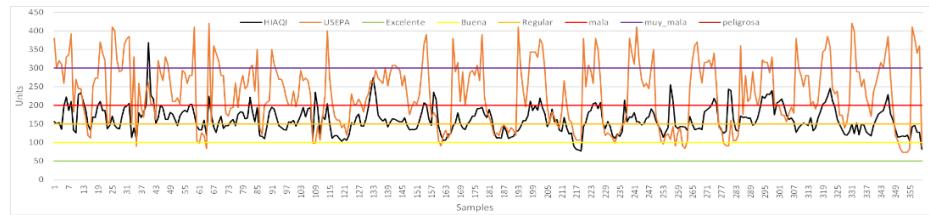
### 3.2. Análisis del factor de confort CF

Similar al análisis del factor TF, los comportamientos de los parámetros de CF observados en la Fig. 3, de una semana de concentraciones (del 1 al 8 de julio de 2022),

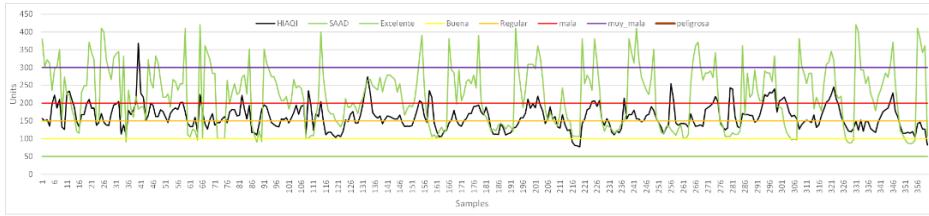
### Modelo de evaluación de la calidad del aire interior empleado el proceso analítico jerárquico



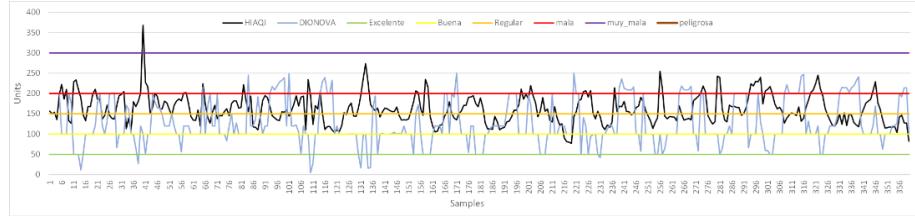
**Fig. 4.** Comparación entre el HIAQI el IMECA.



**Fig. 5.** Comparación entre el HIAQI el USEPA.



**Fig. 6.** Comparación entre el HIAQI y Saad.



**Fig. 7.** Comparación entre el HIAQI y Dionova.

se observó que NO<sub>2</sub>, SO<sub>2</sub>, CH<sub>2</sub>O y CO<sub>2</sub> excedieron la línea naranja del nivel regular de los 150 puntos y esa misma tendencia se mantiene durante todo el año ya que de las 8760 evaluaciones (4,885, 1,136, 3,414 y 4,844 evaluaciones respectivamente). En contraste, TEMP y RH nunca alcanzaron la línea roja del nivel malo de 200 puntos.

### 3.3. Evaluaciones de calidad del aire interior

Para verificar la eficiencia del modelo HIAQI se comparó con otros modelos propuestos y se realizó un análisis exhaustivo del rendimiento de HIAQI. En este sentido, se hizo una comparación utilizando otros índices. Las metodologías para la estandarización de parámetros propuestos por las agencias gubernamentales del aire exterior, como IMECA

**Tabla 6.** Comparación numérica de los diferentes índices de la calidad del aire interior.

No	Date	Pollutants										Indoor Air Quality Indexes						
		PM1	PM25	PM10	TVOCs	O <sub>3</sub>	CO	NO <sub>2</sub>	SO <sub>2</sub>	CH <sub>2</sub> O	CO <sub>2</sub>	TEMP	HR	IMECA	USEPA	HIAQI	SAAD	DIONOVA
1	2022/07/15/T0000	4	7	17	55	0.154	1.56	0.133	0.078	23	652	25.3	44.7	162	220	128	226	219
2	2022/07/15/T0100	3	7	17	45	0.140	1.56	0.133	0.078	19	610	24.9	45.0	147	200	122	207	232
3	2022/07/15/T0200	3	7	17	43	0.119	2.33	0.147	0.052	18	601	24.8	45.0	125	170	118	179	241
4	2022/07/15/T0300	5	9	19	39	0.056	2.33	0.238	0.052	17	583	24.6	45.2	113	238	146	219	122
5	2022/07/15/T0400	6	14	24	41	0.021	2.33	0.259	0.065	17	589	24.7	45.3	123	259	161	237	100
6	2022/07/15/T0500	6	15	25	42	0.007	6.22	0.287	0.078	18	597	24.7	45.2	137	287	176	261	100
7	2022/07/15/T0600	6	15	25	38	0.014	7.78	0.315	0.065	16	576	24.5	45.3	150	315	181	285	100
8	2022/07/15/T0700	7	20	30	54	0.056	8.56	0.301	0.052	23	650	24.4	46.5	143	301	186	273	100
9	2022/07/15/T0800	8	21	31	41	0.140	8.56	0.343	0.052	17	590	24.5	45.4	163	343	206	309	120
10	2022/07/15/T0900	6	19	29	37	0.259	7.78	0.385	0.078	16	575	25.0	44.8	273	385	229	371	169
11	2022/07/15/T1000	8	21	31	42	0.035	3.89	0.28	0.052	18	598	24.8	46.2	133	280	177	255	100
12	2022/07/15/T1100	8	22	32	43	0.049	2.33	0.196	0.078	18	602	25.2	45.3	93	196	161	184	100
13	2022/07/15/T1200	9	23	33	41	0.057	0.78	0.119	0.052	18	594	25.4	43.0	60	119	136	122	62
14	2022/07/15/T1300	7	20	30	42	0.051	0.78	0.105	0.026	18	596	25.6	43.0	54	105	115	112	100
15	2022/07/15/T1400	7	22	32	45	0.048	7.00	0.084	0.026	19	611	25.4	43.2	64	84	115	97	100
16	2022/07/15/T1500	7	23	33	57	0.043	7.00	0.07	0.026	25	665	25.7	46.7	64	74	118	88	100
17	2022/07/15/T1600	7	20	30	79	0.041	7.00	0.056	0.039	34	764	25.6	46.7	64	74	116	85	120
18	2022/07/15/T1700	8	20	30	75	0.039	7.00	0.07	0.039	32	745	25.6	46.0	64	74	120	88	120
19	2022/07/15/T1800	5	13	23	76	0.033	0.78	0.084	0.026	33	753	25.2	46.2	40	84	104	96	126
20	2022/07/15/T1900	7	14	24	69	0.287	0.78	0.105	0.026	30	720	25.1	46.5	302	410	142	410	200
21	2022/07/15/T2000	9	15	25	61	0.266	1.56	0.119	0.026	26	681	25.2	46.0	280	380	146	381	192
22	2022/07/15/T2100	5	10	20	57	0.238	1.56	0.126	0.026	25	665	25.1	45.9	251	340	127	342	214
23	2022/07/15/T2200	6	10	20	57	0.252	1.56	0.119	0.026	24	663	24.8	46.5	265	360	127	361	214
24	2022/07/15/T2300	6	11	21	57	0.063	0.78	0.007	0.039	24	664	25.0	46.5	66	90	82	108	100

**Tabla 7.** Comparación de los límites máximos permisibles de los diferentes índices.

INDICES	PM	PM <sub>2</sub>	PM <sub>1</sub>	TVOC	CH <sub>2</sub>	C	NO	TEM
	1	5	0	S	O	O <sub>3</sub>	O	P
IMECA	45	95			0.11	11	1	0.2
					0.07		3	0.1
USEPA	35.4	154			5	9.4	8	0.0
							0.1	
SAAD		150	841		0.05	8.7	8	100
DIONOV								20-45
A	150		967		0.55	8.5	0.2	40-
							0	100
HIAQI	8	15	50	500	50	0.06	9	0.0
							8	0.0
							700	40-70
							20-25	

y USEPA. También se comparó con los modelos propuestos en la literatura, como Dionova y Saad. Modelos por normalización de parámetros como Saad, y otros desarrollados por un sistema de inferencia difusa (FIS) como Dionova. En la Tabla 6 se muestra un día de evaluaciones y comparaciones numéricas utilizando los siete índices revisados.

Para comprender mejor las diferencias significativas que hay entre los índices de evaluación, debemos observar que la principal razón de estas diferencias es que los límites máximos permitidos de los contaminantes, el número de contaminantes que cada índice evalúa sin considerar su modelo. Se hicieron comparaciones contra otros índices como el IMECA y USEPA para evaluar la calidad del aire exterior, así como a los seis contaminantes. Al mismo tiempo, los modelos Saad y Dionova evalúan ocho contaminantes.

Finalmente, el HIAQI analiza doce parámetros para realizar su evaluación. La Tabla 7 muestra los límites máximos permitidos de los contaminantes que fueron evaluados por cada uno de los métodos.

La Fig. 4 compara el HIAQI contra el IMECA que realizan las evaluaciones por normalización de los parámetros del 1 al 15 de julio de 2022. En este caso, el IMECA presentó una evaluación más alta que la del HIAQI, ya que el IMECA presentó evaluaciones que están por encima de los 200 puntos, Y en algunos puntos críticos, están por cercanos a los 300 puntos. Mientras que el HIAQI permaneció entre los 200 y los 300 puntos y rara vez excedió la línea morada de los 300 puntos.

La Fig. 5 compara el HIAQI contra el USEPA que realizan las evaluaciones por la normalización de los parámetros del 1 al 15 de julio de 2022. En este caso, el USEPA presentaron evaluaciones más altas que las del HIAQI, ya que mientras las evaluaciones del HIAQI están entre los 200 y los 300 puntos, Y en algunos puntos críticos, supera los 300 puntos. Mientras que el USEPA realizó evaluaciones entre los 300 y 400 puntos, y solo en algunos puntos críticos supera los 400 puntos.

La Fig. 6 compara el HIAQI contra el Saad donde el modelo de Saad realiza sus evaluaciones mediante la normalización de los parámetros. en el periodo del 1 al 15 de julio de 2022. El modelo Saad presentó las evaluaciones más altas que están por encima de los 300 puntos; y en algunos momentos críticos, superaron los 400 puntos. En contraste, HIAQI están entre los 200 y los 300 puntos, Y en algunos puntos críticos, supera los 300 puntos. Debido al sesgo prioritario del AHP que recompensa la evaluación.

La Fig. 7 compara el HIAQI contra el modelo de Dionova que realiza sus evaluaciones a través de un sistema de inferencia difusa en el periodo del 1 al 15 de julio de 2022. El modelo de Dionova tuvo evaluaciones más bajas que las del HIAQI, ya que siempre permaneció por debajo de los 200 puntos y solo en algunos casos excedió la línea roja. En contraste, el HIAQI permaneció entre los 200 y los 300 puntos y rara vez excedió la línea morada de los 300 puntos en algunos casos. Debido al sesgo prioritario del AHP que recompensa la evaluación.

#### **4. Discusión**

Las frecuencias de los siete puntajes de los índices se observaron utilizando un año de datos desde el uno de julio de 2022 hasta los treinta de junio de 2023. En este caso, IMECA, USEPA, Saad, Dionova e HIAQI. Con promedios de 106, 184, 181, 113 y 172 puntos respectivamente.

Los modelos por normalización de parámetros (IMECA, USEPA, y Saad). Los datos tienen una tendencia similar a una distribución normal, pero sus promedios son cercanos a los 200 puntos. Asimismo, el modelo implementado por un sistema de inferencia difusos fue el Dionova. Pero debemos señalar que este modelo no tiene una tendencia similar a una distribución normal porque el modelo Dionova tiene 3023 evaluaciones con un rango de [91-99] puntos.

Mientras tanto, el modelo HIAQI, presentan sus datos con una tendencia similar a una distribución normal, pero su promedio es cercano a los 170 puntos. Por lo tanto, decidir cuál es el mejor modelo de evaluación de calidad del aire interior no es fácil. Sin embargo, el modelo HIAQI es una buena opción para evaluar la calidad del aire interior, ya que,

desde los 156 puntos, puede emitir alertas tempranas necesarias para advertir a los habitantes y recircular el aire interior en momentos críticos.

Además, los modelos que fueron implementados por la normalización de parámetros presentaron promedios más altos que los modelos por inferencia difusa (FIS), como el modelo de Dionova y el HIAQI, tuvieron promedios de 113 y 172 unidades. Pero las principales diferencias entre los modelos debemos mencionar que, aunque en los métodos por normalización de los parámetros (IMECA, USEPA HIAQI y Saad), la distribución de las evaluaciones es muy similar a una distribución normal, con rangos [98-107, 160-174, 161-174, 97-112] puntos, respectivamente.

Sin embargo, las evaluaciones de FIS, como el modelo DIONOVA tiene 3023 evaluaciones con un rango de [91-99] puntos. Esto exhibe una falla aparente del modelo porque solo tiene 16 reglas de inferencia difusa; Cuando se requieren cientos de reglas (incluso miles) para simular la realidad, ya que al aumentar el número de reglas mejora la simulación de la realidad y reduce el número de fallos. Sin embargo, el HIAQI supera por mucho al modelo de Dionova. Contra el resto de los modelos, podemos ver que el promedio de Saad, y USEPA tienen evaluaciones altas, cerca de los 200 puntos, mientras que el HIAQI están cerca de los 170 puntos.

Por tanto, podemos concluir que la evaluación de los modelos mediante la normalización de los parámetros, excepto el IMECA (USEPA, y Saad) presentó altas evaluaciones con puntajes superiores a los 200 puntos (35.9%, y 31.1% de las evaluaciones, respectivamente). Por el contrario, los modelos implementados por FIS como el Dionova solo tuvieron el 18.5% de las evaluaciones con puntajes superiores a los 200 puntos. Mientras que HIAQI tuvo el 32.8% de las evaluaciones con puntajes superiores a los 200 puntos.

En conclusión, debemos comentar que el modelo propuesto HIAQI es una buena opción para evaluar la calidad del aire interior porque va desde los 156 puntos, puede emitir alertas tempranas necesarias para advertir a los habitantes y a los dispositivos de aire acondicionado automático para recircular el aire interior en situaciones críticas.

## 5. Conclusiones

Este trabajo creó un nuevo modelo de evaluación de calidad del aire interior para proteger a la salud humana en las grandes ciudades y áreas urbanas. El modelo se creó de acuerdo con la dinámica y la distribución de los contaminantes del aire interior en un ambiente cerrado. El modelo HIAQI logra el objetivo principal de emitir alertas tempranas, ya que, desde los 156 puntos de la escala, puede advertir a los habitantes, así como a los mecanismos de control de aire acondicionado automático para recircular el aire interior en situaciones críticas.

## Referencias

1. Kabele, K., Veverková, Z., Urban, M.: Methodology for assessing the indoor environmental quality in low energy buildings in the Czechia. In: IOP Conference Series: Materials Science and Engineering, vol. 609, no. 4, p. 042103 (2019) doi: 10.1088/1757-899X/609/4/042103
2. Xu, B., Hao, J.: Air quality inside subway metro indoor environment worldwide: A review. Environment International, vol. 107, pp. 33–46 (2017) doi: 10.1016/j.envint.2017.06.016
3. Weaver, A. M., Gurley, E. S., Crabtree-Ide, C., Salje, H., Yoo, E. H., Mu, L., Akter, N., Ram,

*Modelo de evaluación de la calidad del aire interior empleado el proceso analítico jerárquico*

- P. K.: Air pollution dispersion from biomass stoves to neighboring homes in Mirpur, Dhaka, Bangladesh. BMC Public Health, vol. 19, no. 425, pp 1–12 (2019) doi: 10.1186/s12889-019-6751-z
- 4. Sarkhosh, M., Najafpoor, A. A., Alidadi, H., Shamsara, J., Amiri, H., Andrea, T., Kariminejad, F.: Indoor air quality associations with sick building syndrome: An application of decision tree technology. Building and Environment, vol. 188, pp. 107446 (2021) doi: 10.1016/j.buildenv.2020.107446
  - 5. Rickenbacker, H. J., Collinge, W. O., Hasik, V., Bilec, M. M.: Indoor air quality assessments of diverse buildings in an energy conservation district from a life cycle assessment lens: Short paper. In: Proceedings of the 3rd ACM International Conference on Systems for Energy-Efficient Built Environments, pp. 207–210 (2016) doi: 10.1145/2993422.2993424
  - 6. Saad, S. M., Shakaff, A. Y. M., Saad, A. R. M., Yusof, A. M., Andrew, A. M., Zakaria, A., Adom, A. H.: Development of indoor environmental index: Air quality index and thermal comfort index. In: AIP Conference Proceedings, vol. 1808, no. 1 (2017) doi: 10.1063/1.4975276
  - 7. Dionova, B. W., Mohammed, M. N., Al-Zubaidi, S., Yusuf, E.: Environment indoor air quality assessment using fuzzy inference system. ICT Express, vol. 6, no. 3, pp. 185–194 (2020) doi: 10.1016/j.ictex.2020.05.007
  - 8. New Jersey Department of Environmental Protection: 2018 air quality index (2018) USEPA.aqi-technical-assistance-document-sept2018 <https://www.airnow.gov/publications/air-quality-index/technical-assistance-document-for-reporting-the-daily-aqi/>
  - 9. HKEPD: A guide on indoor air quality certification scheme for offices and public places indoor air quality management group. (2003). <https://www.iaq.gov.hk/wp-content/uploads/2021/04/certguide-eng.pdf>
  - 10. SIAQG: Guidelines for good indoor air quality in office premises (1996) <https://www.nlb.gov.sg/biblio/203971917>
  - 11. OSHA: Indoor air quality in commercial and institutional buildings (2011) <https://www.osha.gov/sites/default/files/publications/3430indoor-air-quality-sm.pdf>
  - 12. ACGIH: TLVs® and BEIs® based on the documentation of the® defining the science of occupational and environmental health® threshold limit values for chemical substances and physical agents biological exposure indices (2019) <https://www.acgih.org/science/tlv-bei-guidelines/>
  - 13. DOSH: Industry code of practice on chemicals classification and hazard communication (2014) <https://www.dosh.gov.my/index.php/legislation/codes-of-practice/chemical-management/3460-industry-code-of-practice-on-chemicals-classification-and-hazard-communication-amendment-2019-part-1/file>
  - 14. Zadeh, L. A.: Fuzzy sets as a basis for a theory of possibility. Fuzzy Sets and Systems, vol. 1, no. 1, pp. 3–28 (1978) 10.1016/0165-0114(78)90029-5
  - 15. Saaty, T. L.: Decision making the analytic hierarchy and network processes (AHP/ANP). Journal of Systems Science and Systems Engineering, vol. 13, pp. 1–35 (2004) doi: 10.1007/s11518-006-0151-5
  - 16. Olvera-García, M. A., Carbajal-Hernández, J. J., Sánchez-Fernández, L. P., Hernández-Bautista, I.: Air quality assessment using a weighted fuzzy inference system. Ecological Informatics, vol. 33, pp. 57–74 (2016) doi: <https://doi.org/10.1016/j.ecoinf.2016.04.005>
  - 17. Perron, O.: Zur theorie der matrizes. Mathematische Annalen, vol. 64, no. 2, pp. 248–263 (1907) doi: 10.1007/BF01449896



## CAD Design of a Robotic Thumb of 4 DOF

Luis Fernando Dzul-Maldonado, Eduardo Morales-Sánchez

Instituto Politécnico Nacional,  
Centro de Investigación en Ciencia Aplicada y Tecnología Avanzada,  
Querétaro,  
Mexico

ldzulm2200@alumno.ipn.mx, emoraless@ipn.mx

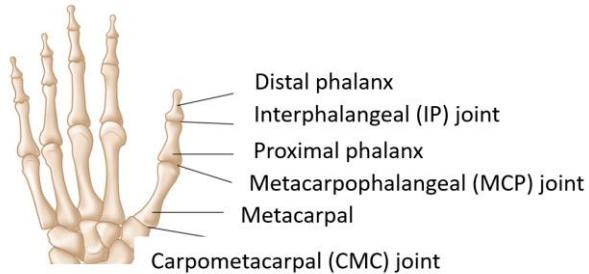
**Abstract.** This paper presents a comprehensive study on the design and development of a robotic thumb that closely emulates the natural range of motion and functionality of the human thumb. Careful consideration is given to the thumb's anatomy, including the bones (metacarpal, proximal phalanx, and distal phalanx) and joints (carpometacarpal, metacarpophalangeal, and interphalangeal). Anthropometric proportions and biomechanical principles are incorporated to ensure accuracy and realism including them in a Kinematic Model. CAD software is utilized for modeling and simulation, incorporating four degrees of freedom (DOF) for two movements of flexion extension, the abduction adduction, and the opposition of the thumb. The modeling is divided in the design of the phalanges and the metacarpal section. Comparative analysis against established benchmarks and reported ranges of motion validates the design with the help of a simulation program through the Kinematic Model, demonstrating that the robotic thumb matches or exceeds natural ranges of movement. These findings highlight the potential of the robotic thumb for real-world applications. In conclusion, this paper presents a successful design and development of an anthropomorphic robotic thumb that replicates the range of motion and characteristics of the human thumb.

**Keyword:** Robotic hand, thumb, degrees of freedom.

### 1 Introduction

Human hands are extremely complex due to their ability to perform a wide variety of tasks, from handling delicate objects to performing complex and precise movements. Researchers have tried to model those functional features for robotic multififingered grippers since the mid-eighties (Nanayakkara et al., 2017) and the anthropomorphic robotic dexterous hand has become one of the most important researching fields on humanoid robots (Wang et al., 2012), and a crucial element of the robotic hand design is the thumb.

Robotic thumbs play a crucial role in the development of robotic hands as they mimic the dexterity and functionality of the human thumb. By incorporating a robotic thumb with multiple degrees of freedom (DOF) into a robotic hand, engineers and researchers can enhance the hand's overall functionality, adaptability, and versatility. Examples of robotic thumbs include the Gifu Hand III (Tetsuya et al., 2002) which



**Fig. 1.** Bones and joints of the human thumb [1].

possesses a 4 DOF thumb, the multiarticulated hand (Ramos, 2021), with a thumb of 3 DOF, the EthoHand (Konnaris, 2016) with a ball articulation actuated with tendons, or the thumb developed by Prudencio et al. (2014) with 3 DOF.

There is also use of soft robotics like the BCL-13 (Zhou et. al., 2018) and the RBO Hand 2 (Deimel and Brock, 2016). There also are underactuated designs like the thumbs of the SCCA Hand (Wiste, Tuomas et. al, 2017) and the Adam's hand (Zappatore Giovanni et. al, 2017) that keep rigid mechanisms and others that use tendons like the Highly Biomimetic Anthropomorphic Robotic Hand (Xu, Zhe and Todorov, Emanuel, 2016).

The design and development of robotic thumbs involve careful consideration of anthropometry, biomechanics, and kinematics to achieve optimal performance. By emulating the structure and movements of the human thumb, robotic thumbs can provide increased dexterity and enable the hand to perform a wide range of tasks in various environments.

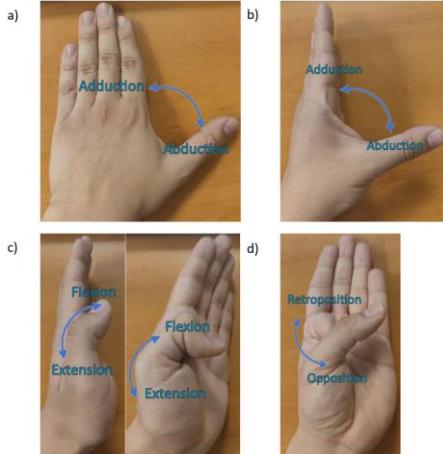
The objective of this paper is to design, analyze, and evaluate a robotic thumb with anthropometric proportions and 4 DOF using the Fusion 360 CAD program, with a focus on generating opposition and adduction movements. The paper aims to provide a comprehensive understanding of the design process, functionality, and potential applications of the robotic thumb in the development of robotic hands.

## 2 Thumbs Anatomy

The human thumb is a vital component of hand functionality, characterized by its unique structure and mobility. Understanding the anatomy of the human thumb's bones and joints is crucial to generate a design which imitates its anthropomorphy and anthropometry. There are 3 bones inside the thumb (see Fig. 1): the metacarpal bone, where the thumb originates and connects the thumb to the wrist. It is short and robust, allowing for stability and strength during grasping motions.

The proximal phalanx, the first phalanx of the thumb, located closest to the metacarpal bone. It is responsible for the thumb's pivotal movement and flexion. And the distal phalanx which forms the tip of the thumb. It provides support and precision for grasping objects.

As for the joints there are also 3 in the thumb (see Fig. 1) those being: the carpometacarpal joint (CMC), located at the base of the thumb, where the metacarpal



**Fig. 2.** Movements of the thumb. a) The radial abduction/adduction of the thumb. b) The palmar abduction/adduction of the thumb. c) The flexion/extension of the IP and MCP thumb joints. d) The opposition/retroposition of the thumb.

bone connects to the carpal bones of the wrist. The metacarpophalangeal joint (MCP) that connects the metacarpal bone to the proximal phalanx. It permits flexion, extension, and abduction-adduction movements of the thumb. And the interphalangeal joint (IP), present between the proximal and distal phalanges. It allows for flexion and extension movements, contributing to the thumb's grasping capabilities (see Fig. 2).

The carpometacarpal (CMC) joint primarily facilitates abduction and adduction of the thumb. Abduction refers to the motion of the thumb away from the second metacarpal bone, while adduction signifies the opposite movement. These motions occur in two planes: palmar and dorsal. Radial abduction-adduction involves the thumb moving parallel to both the radius and the palm of the hand, with a relatively smaller range of motion. In contrast, palmar abduction-adduction occurs in a plane perpendicular to the palm of the hand.

These bones and joints collectively provide the thumb with its remarkable dexterity and versatility, allowing for a wide range of movements and precision in object manipulation. Understanding the anatomical structure of the human thumb serves as a valuable reference point for designing and developing robotic thumbs with comparable functionalities.

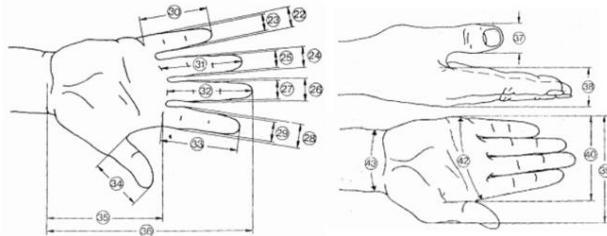
### 3 Design Methodology

In the realm of robotic hand design, their elements can be categorized into two groups based on their actuators: tendon-driven and rigid mechanics-driven. Tendon-driven systems utilize cables to generate movements, while rigid mechanics-driven systems employ gears.

The robotic thumb discussed in this paper falls into the latter category and is equipped with four actuated degrees of freedom (DOF). This requires careful

**Table 1.** Anthropometric measurements of the thumb according to the norm DIN 33402 (DIN, 2020).

Dimensions (cm)	Percentile					
	Men			Women		
	5%	50%	95%	5%	50%	95%
(34) Thumb Length	6.0	6.7	7.6	5.2	6.0	6.9
(37) Thumb Width	2.0	2.3	2.5	1.6	1.9	2.1
(39) Hand Length with Thumb	9.8	10.7	11.6	8.2	9.2	10.1
(40) Hand Length without Thumb	7.8	8.5	9.3	7.2	8.0	8.5



**Fig 3.** Anthropometric measurements of the hand according to norm DIN 33402 (DIN, 2020).

consideration of selecting compact motors that can fit within the thumb's confines and dividing the design into separate parts for independent movement and assembly.

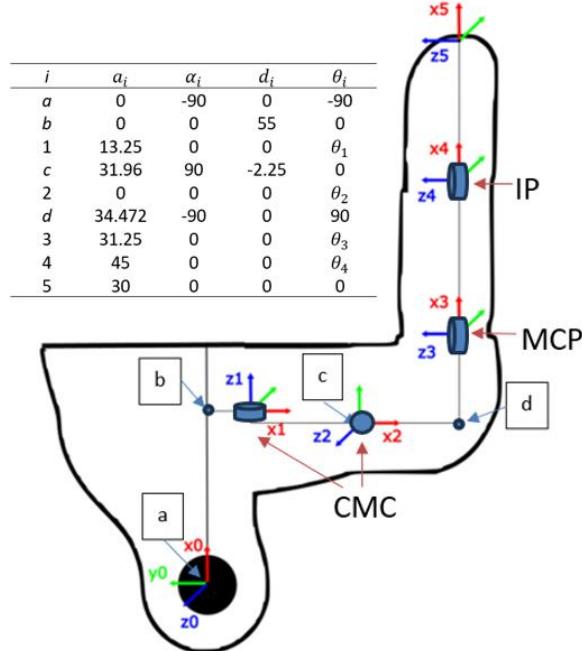
The method used to design the robotic thumb can be divided in three sections, the design requirements, the development of the phalanges, and the design of the metacarpal bone, both of those must keep the anthropometry of the thumb, following the DIN 33402 norm (DIN, 2020) (see Table 1 and Fig. 3).

### 3.1 Design Requirements

To demonstrate the anthropomorphic qualities of the robotic finger, three key factors are essential: joint structure, dexterity, and appearance. The joint structure entails utilizing phalanges and joints that closely resemble those found in a human finger. Dexterity encompasses the finger's ability to mimic natural human movements, aligning with the initial design concept. Additionally, the appearance of the robotic finger must closely resemble that of a human thumb.

To achieve the desired range of motion, the robotic finger is designed with four actuated degrees of freedom (DOF). These include opposition, abduction-adduction in both palmar and radial planes, and flexion-extension of the metacarpophalangeal (MCP) and interphalangeal (IP) joints.

The joint structure incorporates a division of the metacarpal bone to facilitate opposition and abduction-adduction movements while maintaining the human thumb's appearance. The distance between the divisions is set to the minimum allowed by the actuators to ensure a natural appearance.



**Fig 4.** Denavit Hartenberg (DH) Kinematic Model. The DH parameters are shown in the table above. There are 4 joints ( $i = 1,2,3,4$ )  $i = 1$  and 2 correspond to the CMC joint,  $i = 3$  to the MCP joint and  $i = 4$  to the IP joint,  $i = 0$  is the location of the wrist and there are also auxiliary parameters used for transformations between joints ( $i = a,b,c,d$ ).

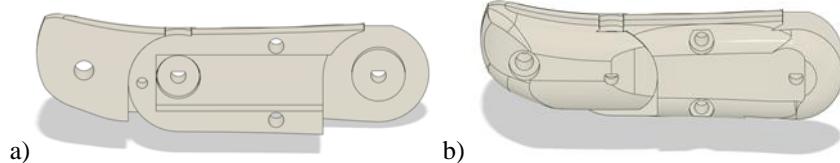
In terms of the mechanical design, the robotic finger incorporates a transmission system utilizing rigid links. The chosen actuators for this design are the n20 micromotors, which are equipped with gearboxes. These micromotors, with dimensions of 33.5 x 12.1 x 10 mm, are strategically positioned within the proximal phalanx and the two parts of the metacarpal bone, leaving one to be coupled to a robotic hand.

By addressing these factors, the robotic finger achieves a remarkable level of anthropomorphism, closely resembling the joint structure, dexterity, and appearance of a human thumb. The design's integration of the transmission system using n20 micromotors ensures the finger's effective actuation and movement capabilities.

### 3.2 Kinematic Model of the Robotic Thumb

To mathematically represent the movements and positions of the robotic thumb, a kinematic model was developed. The kinematic model outlines the relationships between joint angles and the resulting position and orientation of the thumb. It is crucial for understanding and predicting the thumb's behavior during various motions.

The Denavit-Hartenberg (DH) parameters, shown in Fig. 4, were employed to describe the transformations between adjacent links of the robotic thumb. These



**Fig. 5.** CAD design of the thumb phalanges with lateral view of a) the inside of the thumb, where a compartment for the actuator can be seen, and b) the assembled phalanges of the thumb.

parameters include link lengths, joint angles, and other geometric information that define the kinematic properties of the thumb.

The kinematic model serves as a tool for validating the design of the robotic thumb. By simulating movements using the model, we could ensure that the designed structure facilitates the intended range of motion and functionality, this also permitted us to optimize the design parameters to achieve optimal performance in simulation. This involved adjusting metacarpal lengths, while refining the overall structure to enhance the thumb's dexterity.

The Forward Kinematics were calculated by the multiplication of the transformation matrices (equation 1). These equations enable us to determine the end-effector pose of the thumb:

$$T_5 = T_a \times T_b \times T_{01} \times T_c \times T_{12} \times T_d \times T_{23} \times T_{34} \times T_{45}, \quad (1)$$

where:

$T_{01}, T_{12}, T_{23}, T_{34}$  are transformation matrices for respective joints.

And

$T_a, T_b, T_c, T_d$  are auxiliary parameters used for transformations between joints.

### 3.3 Phalanges CAD Design

The human thumb has two phalanges: the proximal and the distal. To ensure accurate design of the robotic thumb, it is essential to establish precise measurements for the joint distances. In this case, the distance between the joints is set at 45 mm, while the length of the distal phalanx measures 30 mm, the diameter of both of a maximum of 25 mm to be in the range of the DIN 33402 norm, also specified in the Kinematic Model.

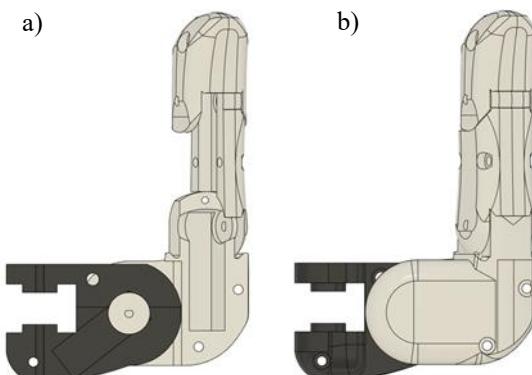
By knowing the joint positions, it becomes possible to create the silhouette of the human finger, divided into the two phalanges. These silhouettes are then extruded, and further details are added using a fillet tool.

For the proximal phalanx, which possesses two joints, a compartment is designed to house the micro motor n20. The motor axis is positioned at the center of the interphalangeal joint, enabling the flexion and extension movements of the distal phalanx. The design of the distal phalanx is such that it can be assembled to the proximal phalanx while accommodating the motor within.

Considering the design is intended for additive manufacturing, each phalanx needs to be divided into two parts to allow for assembly and integration of the motor, it is also needed to design the unions where the phalanges will be assembled (see Fig. 5a).

**Table 2.** Measurements of the robotic thumb by their links, including the maximum dimensions of the links between each joint and the range of movements angle of each joint.

Link	Measurements			
	Dimensions (mm)		Range of Movement	
	Max Length	Max Width	Joint	Angle
Distal Phalanx	30	25	IP	-15° - 90°
Proximal Phalanx	45	25	M CP	-15° - 78°
Metacarpal bone (abduction)	50	45	C MC	0° - 69°
Metacarpal bone (opposition)	45	45	C MC	-18° - 80°



**Fig. 6.** CAD design of the thumb phalanges with top view of a) the inside of the thumb, where the actuators compartments can be seen, and b) the assembled thumb.

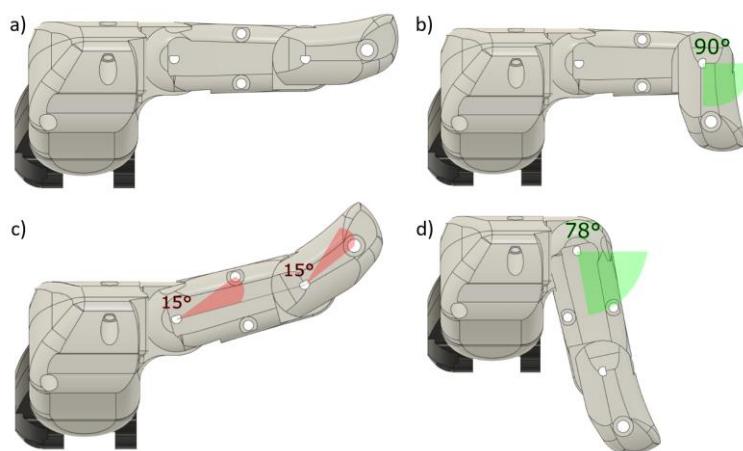
### 3.4 Metacarpal Bone CAD Design

To design the metacarpal bone section there needs to be a division of the shape of the thumb to generate both the opposition and the adduction-abduction movement, the last needed to be able to be generated in both the radial and palmar plane of the hand, leaving the opposition movement first in the base of the thumb followed by the adduction-abduction. The design needs to consider the hand to include a motor inside it for the opposition, while the next link of the thumb to generate the adduction-abduction, and the next link to do the flexion-extension of the MCP joint.

To achieve this, the design required an approximation of the shape of the hand as a reference. Using the DIN 33402 norm, the length of the hand was acquired and half of it was used for the length of the thumb inside the hand, followed by separating that half from the rest of the hand. By closely referring to the shape of an actual human thumb, the design could be created.

**Table 3.** Table of comparison of the design of the robotic thumb proposed and the benchmark ranges of movement (ROM) based on the average values reported by Barakat et al. (2013). The proposed robotic thumb design demonstrates ROM that closely align with or exceed these benchmarks. \*In the mechanical design of the robotic thumb the abduction works in both palmar and radial planes. \*\*The Expected Kapandji grade of 10 refers to the thumb ROM when added to a complete robotic hand.

Joint	Average Range of Movement (Barakat et al., 2013)	Proposed Design	Robotic Thumb
IP Joint	Flexion: 88° Extension: 12°	Flexion: 90° Extension: 15°	
MCP Joint	Flexion: 60° Extension: 8.1°	Flexion: 78° Extension: 15°	
CMC Joint	Palmar Abduction: 61.2° Radial Abduction: 62.9° Kapandji grade: 9	*Abduction: 69° **Expected Kapandji grade: 10	

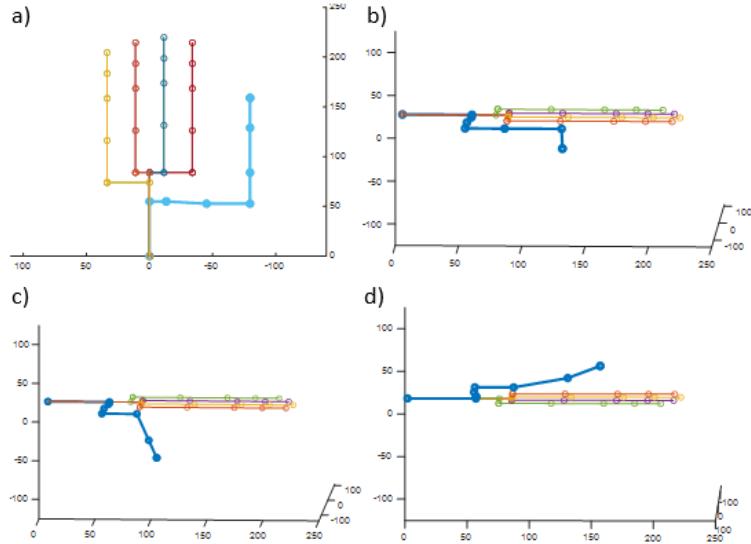


**Fig. 7.** CAD range of movement of the thumb a) resting position; b) flexion of the IP joint with a maximum range of 90°; c) extension of the IP and MCP joints with a maximum range of 15° each; and d) flexion of the MCP joint with a maximum range of 78°.

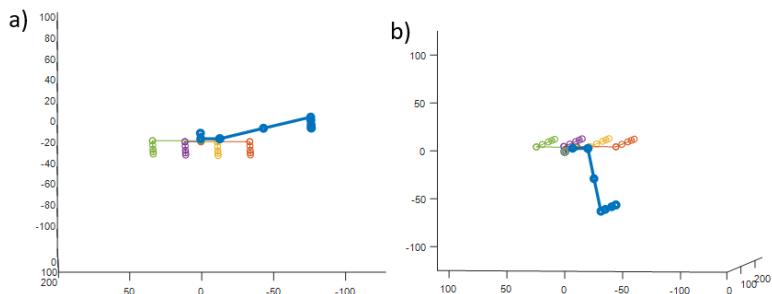
The design process for the metacarpal bone section, began by rotating the previously designed phalanges along their axis to simulate the natural resting position of the thumb, achieving a 30° angle. Subsequently, a top view design was created referring to the kinematic model, to replicate the thumb's shape in the horizontal plane of the hand, giving dimensions of 50 mm parallel to the axis of the phalanges and 90 mm perpendicular to it.

This was followed by generating the side and back views of the thumb in perpendicular planes with a depth of 45 mm. By combining these views, an approximate shape of the thumb was formed, capturing its essential characteristics. To add finer details, a fillet tool was employed, enhancing the realism and accuracy of the design.

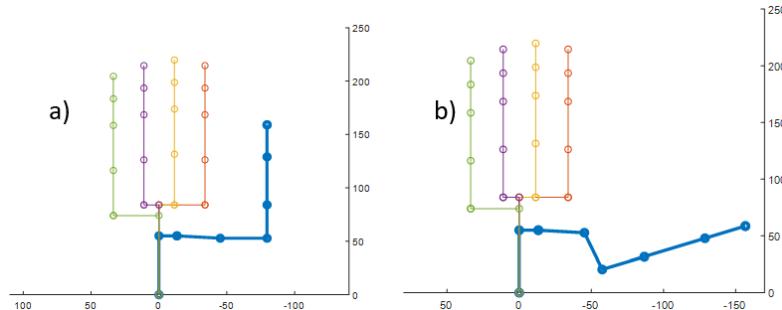
*CAD Design of a Robotic Thumb of 4 DOF*



**Fig. 10.** MATLAB range of movement of the thumb a) resting position; b) flexion of the IP joint with a maximum range of  $90^\circ$ ; c) flexion of the MCP joint with a maximum range of  $78^\circ$ ; and d) extension of the IP and MCP joints with a maximum range of  $15^\circ$  each.



**Fig. 11.** MATLAB range of movement of the CMC joint a) retroposition with a maximum of  $18^\circ$ ; b) resting position; and c) opposition with a maximum of  $80^\circ$ .



**Fig. 12.** MATLAB range of movement of the thumb phalanges a) rest position; and b) abduction of the CMC joint with a maximum range of  $69^\circ$ .

After generating an approximate shape, the measurements of the motors n20, were considered to create the divisions of the links of the thumb, so compartments were created starting from the motor used for the MCP flexion-extension and ending by the opposition motor. These compartments were made considering the limited space of the thumb. Finally, the shape was divided in two links of 45 mm each perpendicular to the phalanges axis (see Table 2), by using the motors axis in reference and considering the assembly of the parts to generate the movement (see Fig. 6).

## 4 Range of Motion

The average ranges of movement reported by Barakat et al. (2013) served as a benchmark for comparison. According to their findings, the average ranges of movement for the IP joint were 88° of flexion and 12° of extension, while the MCP joint exhibited 60° of flexion and 8.1° of extension. The CMC joint demonstrated a palmar abduction of 61.2°, retroposition of 31°, and radial abduction of 62.9°.

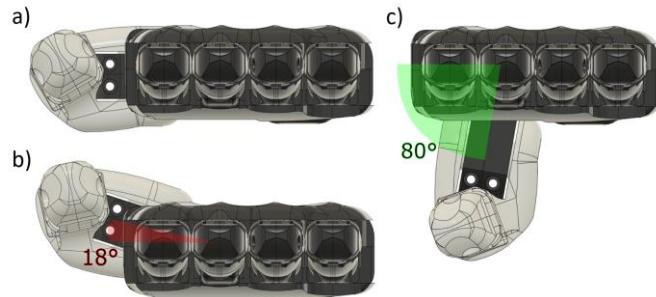
In our simulated CAD assembly, we carefully assessed the range of movement for each joint. The results revealed promising outcomes, with the designed thumb showcasing ranges of movement that closely aligned with the average values reported in the literature. Specifically, the IP joint demonstrated a flexion range of 90° and an extension range of 15°. The MCP joint exhibited a flexion range of 78° and an extension range of 15° (see Fig. 7). The CMC joint displayed an opposition range of 80°, retroposition range of 18° (see Fig. 8), and abduction (both radial and palmar) range of 69° (see Fig. 9).

The similarities between our simulated ranges and the reported average ranges of movement indicate that our design effectively emulates the natural movement capabilities of the human thumb. However, it is important to note that these results are based on a simulated CAD assembly, and further validation is required through physical prototyping and experimentation involving human participants. Such validation studies would provide more accurate insights into the actual performance and usability of the designed thumb (see Table 3).

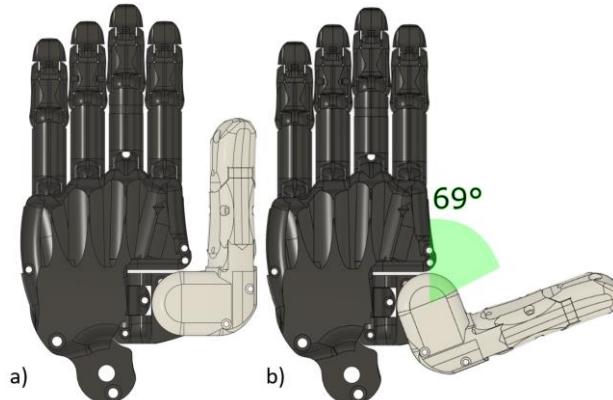
### 4.1 Range of Motion Validation through Kinematic Simulation in MATLAB

To validate the accuracy of the ROM, a simulation was conducted using the forward kinematics equations with the Kinematic Model. The simulated range of motion was compared with the actual range obtained from the CAD design, ensuring the consistency and reliability with the kinematic model.

The kinematic model aids in predicting the workspace of the robotic thumb, indicating the range of positions and orientations it can achieve. This information is crucial for future applications in control, it also allows us to assess the feasibility of the design before advancing to the physical prototyping stage. It also helped verify no potential issues such as joint limitations, collisions, or singularities (see Fig. 10-12).



**Fig. 8.** CAD range of movement of the CMC joint a) retroposition with a maximum of 18°; b) resting position; and c) opposition with a maximum of 80°.



**Fig. 9.** CAD range of movement of the thumb phalanges a) rest position; and b) abduction of the CMC joint with a maximum range of 69°.

## 5 Conclusion

A successful design was presented for a robotic thumb capable of achieving a wide range of movements, closely resembling the anthropomorphic features of a human thumb. The design encompassed all essential ranges of motion, including flexion, extension, abduction, adduction, and opposition, using 4 DOF, while maintaining accurate anthropometry.

The designed robotic thumb stands as a significant contribution, being among the few designs to successfully integrate four degrees of freedom (DOF) into a thumb while adhering to anthropometric measurements. This achievement is made possible through a meticulously crafted design based on gear-driven mechanics, enabling the thumb to replicate intricate human-like movements including opposition, flexion, extension, as well as palmar and radial abduction-adduction.

The design process involved meticulous considerations, such as dividing the thumb's shape to accommodate opposition and adduction-abduction movements, as well as selecting appropriate motors and creating compartments within the thumb for their

integration. The resulting design demonstrates the potential for constructing the thumb through 3D printing and subsequent assembly.

The simulated ranges of movement for each joint were evaluated and compared to the designed ranges, confirming the effectiveness of the kinematic model in accurately representing the thumb's motion capabilities.

By achieving a thumb design with human-like functionality and appearance, this work sets the stage for future advancements in robotic hand development. The designed thumb can be seamlessly integrated into a robotic hand system, enhancing its dexterity and grasp capabilities.

Overall, this research showcases a promising step towards the realization of highly functional and lifelike robotic hands, opening doors for numerous applications in fields such as prosthetics, human-robot interaction, and industrial automation. Future work can focus on the manufacturing and assembly of the designed thumb, as well as exploring its integration into a complete robotic hand system for comprehensive functionality and performance evaluation.

## References

1. American Academic of Orthopedic Surgeon.: Thumb Fractures <https://orthoinfo.aaos.org/en/diseases--conditions/thumb-fractures/>
2. Barakat, M. J., Field, J., Taylor, J.: The range of movement of the thumb. Sage Journal, vol. 8, no. 2, pp. 179–182 (2013) doi: 10.1007/s11552-013-9492-y
3. Cabibihan, J. J., Alkhatib, F., Mudassir, M., Al-Kwifi, O. S., Diab, K., Mahdi, E.: Suitability of the openly accessible 3D printed prosthetic hands for war-wounded children. Frontiers in Robotics and AI, vol. 7 (2021) doi: 10.3389/frobt.2020.594196
4. Cotugno, G., Althoefer, K., Nanayakkara, T.: The role of the thumb: Study of finger motion in grasping and reachability space in human and robotic hands. IEEE Transactions on Systems, Man, and Cybernetics: Systems, vol. 47, no. 7, pp. 1061–1070 (2016) doi: 10.1109/TSMC.2016.2531679
5. Drake, R. L., Vogl, A. W., Mitchell, A. W.: Gray anatomía para estudiantes. 3a. ed., Barcelona: Elsevier (2015)
6. El-Sawah, A., Georganas, N. D., Petriu, E. M.: Finger inverse kinematics using error model analysis for gesture enabled navigation in virtual environments. In: 2006 IEEE International Workshop on Haptic Audio Visual Environments and their Applications, HAVE'06, pp. 34–39 (2006) doi: 10.1109/HAVE.2006.283786
7. Prudencio, A., Morales, E., García, M. A., Lozano, A.: Anthropometric and anthropomorphic features applied to a mechanical finger. In: Intelligent Robotics and Applications: 7th International Conference, ICIRA'14, Springer International Publishing, vol. 8917, pp. 254–265 (2014) doi: 10.1007/978-3-319-13966-1\_26
8. Ramos, M.: Diseño y construcción de una mano robótica humanoide multiarticulada. Trabajo de tesis, Centro de Investigación en Ciencia Aplicada y Tecnología Avanzada-IPN, Unidad Querétaro (2021)
9. Reyes, A., Morales, E.: Generación del agarre de precisión mediante dedos robóticos multiarticulados con características antropométricas y antropomórficas basado en mecanismos planares de 4 barras. Pistas Educativas, no. 130, Tecnológico Nacional de México en Celaya (2018)
10. Mouri, T., Kawasaki, H., Yoshikawa, K., Takai, J., Ito, S.: Anthropomorphic robot hand: gifu hand III. Semantic Scholar, pp. 1288–1293 (2002)

11. Wang, H., Fan, S., Liu, H.: An anthropomorphic design guideline for the thumb of the dexterous hand. In: IEEE International Conference on Mechatronics and Automation, pp. 777–782 (2012)
12. Zhou, J., Yi, J., Chen, X., Liu, Z., Wang, Z.: BCL-13: A 13-DOF soft robotic hand for dexterous grasping and in-hand manipulation. *IEEE Robotics and Automation Letters*, vol. 3, no. 4, pp. 3379–3386 (2018) doi: 10.1109/LRA.2018.2851360
13. Konnaris, C., Gavriel, C., Thomik, A. A., Faisal, A. A.: Ethohand: A dexterous robotic hand with ball-joint thumb enables complex in-hand object manipulation. In: 2016 6th IEEE international conference on biomedical robotics and biomechatronics (BioRob), pp. 1154–1159 (2016) doi: 10.1109/BIOROB.2016.7523787
14. Deimel, R., Brock, O.: A novel type of compliant and underactuated robotic hand for dexterous grasping. *International Journal of Robotics Research*, vol. 35, no. 1-3, pp. 161–185 (2016) doi:10.1109/IJRR.2016.2592961
15. Deutsche Institut für Normung: DIN 33402-2:2020. DIN. ICS: 13.180 (2020)
16. Xu, Z., Todorov, E.: Design of a highly biomimetic anthropomorphic robotic hand towards artificial limb regeneration. In: 2016 IEEE International Conference on Robotics and Automation (ICRA), pp. 3485–3492 (2016) doi: 10.1109/ICRA.2016.7487528
17. Zappatore, G. A., Reina, G., Messina, A.: Adam's Hand: An underactuated robotic end-effector. In: *Advances in Italian Mechanism Science: Proceedings of the First International Conference of IFToMM*, Springer International Publishing, pp. 239–246 (2017) doi: 10.1007/978-3-319-48375-7\_26
18. Wiste, T., Goldfarb, M.: Design of a simplified compliant anthropomorphic robot hand. In: 2017 IEEE International Conference on Robotics and Automation, pp. 3433–38 (2017) doi: 10.1109/ICRA.2017.7989391



# Synthetic EEG Signal Generator of Morphologies Associated with Epileptogenic Events

José-Emmanuel Vázquez-Galán, Blanca Tovar-Corona,  
Laura-Ivoone Garay-Jiménez

Instituto Politécnico Nacional,  
UPIITA,  
Mexico

jvazquezg1603@alumno.ipn.mx, bltovar@ipn.mx, lgaray@ipn.mx

**Abstract.** In recent decades, Electroencephalography (EEG) has undergone extensive analysis and study, seeking to improve the brain signals knowledge. Given the importance of having EEG data available in contexts where it is unfeasible to obtain them, this work presents a methodology for the synthetic generation of these signals. Techniques and algorithms are described to simulate EEG frequency bands, incorporate noise, and emulate specific EEG phenomena. Using Python libraries, key functions for simulating EEG signals with different characteristics and morphologies are detailed. A Python-based tool, implemented through Dash, allows controlled generation of these signals with export options in various formats. Evaluation using EEGLAB ensures the accuracy and consistency of the generated signals, underlining the relevance of external validation. This initiative has potential in the research, diagnosis, and analysis of neurological diseases such as epilepsy, by offering a realistic synthetic approach to EEG signals.

**Keywords:** EEG signals, sharp wave, slow wave, sharp-slow wave, rhythm bands, noise types.

## 1 Introduction

The Electroencephalogram (EEG) has been utilized over decades to probe into brain activity. When employed as a cerebral mapping tool, it can furnish spatiotemporal insights regarding brain function or dysfunction [1]. Its utility in combined research approaches, particularly with techniques like EEG-fMRI, is often undervalued, pushing EEG to ancillary roles, despite its potential for a comprehensive spatial analysis [1].

A seminal contribution of the EEG has been towards diagnosing and treating afflictions such as epilepsy. The EEG has facilitated the pinpointing of aberrant rhythms or transient wave patterns in cerebral regions, although certain constraints related to volume conduction and the inter-electrode distances persist [2]. Such localizations are paramount when ascertaining, for instance, the precise site of an epileptic lesion in the brain, thereby aiding in informed treatment decisions.

Advancements in digitization have augmented the interpretative capabilities of these signals, paving the way for intricate analyses that aim to discern intracranial sources and their interconnections [2]. Nonetheless, it warrants mentioning that electrode dimensions denote the integration of signals spanning 30–500 million neurons.

Furthermore, scalp connectivity might introduce distortions to the resultant estimates [3]. These perturbations often obfuscate the understanding of inherent cerebral interactions, necessitating sophisticated methods to decipher the underlying neural dynamics [4].

Intriguingly, the morphological diversity in EEG readings, even adhering meticulous measurement paradigms, correlates with factors like age and the specific cerebral activity being observed. Hence, it is predominantly perceived as a stochastic signal. Notwithstanding, within minimal variability bounds, recurring patterns become discernible, predominantly in pathological states. It is observed that the EEG embodies significant inter-individual and intra-individual variances over time [5].

While these morphological diversities are consequential, their primary significance lies in their representational capacity of concurrent cerebral events, rather than being focal points of intrigue per se. In the epoch of machine learning, such data heterogeneity became pivotal for algorithm training and validation processes [5]. Concurrently, an extensive EEG dataset repository becomes indispensable to ascertain the robustness of data processing [5].

Positioned against this backdrop, the current endeavor embarks on crafting an application tailored for the synthetic generation of EEG signals, encapsulating clinically discernible morphologies. Such a tool becomes indispensable in enriching and diversifying the EEG signal repository available for scientific inquiries and educational purposes.

This article is organized to first contextualize the significance of EEG in clinical diagnosis (Section 2) and then to detail the nature of EEG waves and their simulation (Section 3). The methodology of synthesizing EEG signals, including noise integration and the emulation of distinctive EEG phenomena, is presented in Section 4. Section 5 evaluates the tool's efficacy using EEGLAB, while Section 6 concludes with the study's key findings and future research directions.

## **2 Importance and Contextualization of EEG Signals in the Diagnosis of Neurological Disease**

Electroencephalogram (EEG) signals serve a paramount role in deciphering and diagnosing an array of diseases associated with the central nervous system (CNS). This diagnostic modality draws its essence from correlating specific EEG patterns with CNS functionalities, anomalies, and pathologies. Within the clinical settings, harnessing EEG signals fortifies the empirical skill in diagnosing cerebral afflictions, including convulsive and metabolic disorders.

Such signals, emanating from extracellular potentials termed as field potentials, are the outcomes of both neuronal and glial activities. The CNS architecture comprises nerve cells or neurons, instrumental in electrical signal transmission, and glial cells. While glial cells don't initiate action potentials akin to neurons, their association with ionic flows allows them to influence extracellular potentials.

Field potentials, stratified by their type and frequency, demand a thorough comprehension of their origin—be it due to neuronal or focal activity—for an apt clinical and diagnostic elucidation [2].

Central to this discussion is the acknowledgment of the quintessential waves within EEG readings. Segregated based on frequency, amplitude, and morphology, these waves encompass diverse patterns: spike waves, sharp waves, spikeslow wave complexes, and sharp wave-slow wave constructs [6]. These characteristic waves play a pivotal role in determining if an EEG trace leans towards being normal or denotes pathology. Specifically, the presence or absence of distinct waves or complexes can hint at disparate cerebral anomalies [6].

A pressing challenge in EEG analyses remains the manual deciphering of signals. Undertaking this intricate endeavor mandates a profound understanding of typical EEG activities, contingent on the patient's age and clinical statuses. A meticulous identification of artifacts, technical anomalies, and borderline patterns is imperative. This discernment, demanding both time and specialized expertise, underlines the rigorous efforts EEG specialists investing reviewing and juxtaposing EEG traces, aiming for unerring diagnoses or to negate specific medical hypotheses [6].

## **2.1 Background**

Within the biomedical domain, a large number of tools and simulators have been conceived for biosignal generation and simulation. When focusing on EEG signals, these generative platforms have been crafted with distinct objectives and diverse methodologies. What follows is a comparative scrutiny of these instruments, emphasizing their attributes and limitations, subsequently delineating the unique proposition our endeavor offers in this realm.

Table 1 illustrates the cardinal features of akin projects, offering insights that could potentially refine our current endeavor and/or corroborate the accurate generation of signals. Contrary to the previously discussed tools, this project focuses on the synthetic generation of EEG signals with notable morphologies. The use of Python as the main programming language to harness of the large number of available libraries, thereby creating an intuitive tool.

This tool grants users the flexibility to dictate morphological patterns, their frequency, and spatial positioning. Developed using the Dash framework in Python, the interface is not only user-friendly but also encompasses several unique benefits, such as exporting data in diverse formats and affording a high degree of flexibility in parameter configuration. Fig. 1 presents some of the outputs from the projects outlined in Table 1.

This initiative's uniqueness becomes more pronounced when juxtaposed other available solutions against. For instance, the Simulated EEG data generator from the University of Oxford [7] and the ECG Simulator from Data Science Automation [8], while invaluable, don't provide the same comprehensive set of features, especially concerning generating specific morphologies.

**Table 1.** Related works.

Name	Description	Characteristics	Institute	Type	Quote
Simulated EEG data generator	Generates EEG data based on two Event-Related Potentials (ERP) theories: classical and phase reset.	EEG; Simulated EEG data generation; Classical and phase reset ERP theories; Matlab; Language: English.	University of Oxford	Open source CC BY-SA 4.0 license	[7]
ECG Simulator	NI-DAQmx HW compatible to generate pre-recorded or template-based ECG signals.	ECG; ECG signal generation; Platforms: Windows 10, 8.1, 7; Language: English;	Data Science Automation (DSA)	Commercial (Price not specified)	[8]
Synthetic ECG Signals model	Proposes a math model to generate an artificial synthetic ECG signal based on real.	ECG Signals Generation of synthetic ECG signals Trigonometric functions and Gaussian monopulse.	University of Calabria, Italy	Academic research (Article)	[9]
Simulating brain signals	Synthetic EEG data using neuralbased generative models to enhance SSVEP classification.	EEG signals; Synthetic EEG signals for SSVEP classification; Neural-based generative models like GAN and VAE.	University Durham, UK.	Academic research (Article)	[10]
Generation of Synthetic Biosignals through Timevarying Fourier Series	Suggests a database encompassing synthetic biomedical signals based on real signal planes. Characterized by time-frequency features, intended to mimic authentic behavior.	Focus on cardiographic impedance signals; Uses Fourier series for modeling and synthetic signal generation.	Quantum Medical SL Department	Research document	[11]
EEGLAB	Offers an opensource, interactive environment for EEG data processing within MATLAB.	EEG (partial support for MEG and other); Signal analysis, visualization, preprocessing, source modeling, and statistical. Plugins and add-ons.	University of California San Diego.	Open source	[12]
MNE	Tool tailored for analyzing and visualizing Magnetoencephalography (MEG) and EEG data.	MEG and EEG; Signal analysis, preprocessing, visualization, source reconstruction, and statistics; Includes t/f analysis, ICA, CSP, dSPM, and others.	Collaborative; No central institution	Open source	[13]

Concurrently, platforms like EEGLAB [12] and MNE [13] augment and enrich our work. EEGLAB serves as a signal processing tool, facilitating the import and analysis of the generated signals, thus verifying their integrity. MNE, on the other hand, refines the data formatting and processing, making the generated images resonate more with real EEG data. This is achieved by incorporating MNE-style visuals and leveraging Plotly graphics in Dash to capture user-specific sections.

It's also worth noting that, diverging from certain research propositions rooted in mathematical modeling, this project could be used in generative models powered by neural networks [10]. Our methodology emphasizes the temporal integration of elements categorized in specific frequency bands that synergize to establish distinguishable patterns. This tactic is reminiscent of strategies employed in ECG [9] and the creation of synthetic biosignals [11], grounding them in authentic signal paradigms.

### **3 EEG Signals and Primary Characteristics**

EEG captures brain dynamics through electrodes placed on the scalp. Conventionally, these electrodes are organized according to the 10–20 system or its extension, the 10–10 system, as described by Oostenveld and Praamstra [14]. In specific circumstances, electrodes can be positioned on the cerebral cortex, termed ECoG, or intracranially implanted. This approach yields less filtered, localized, and higher quality data.

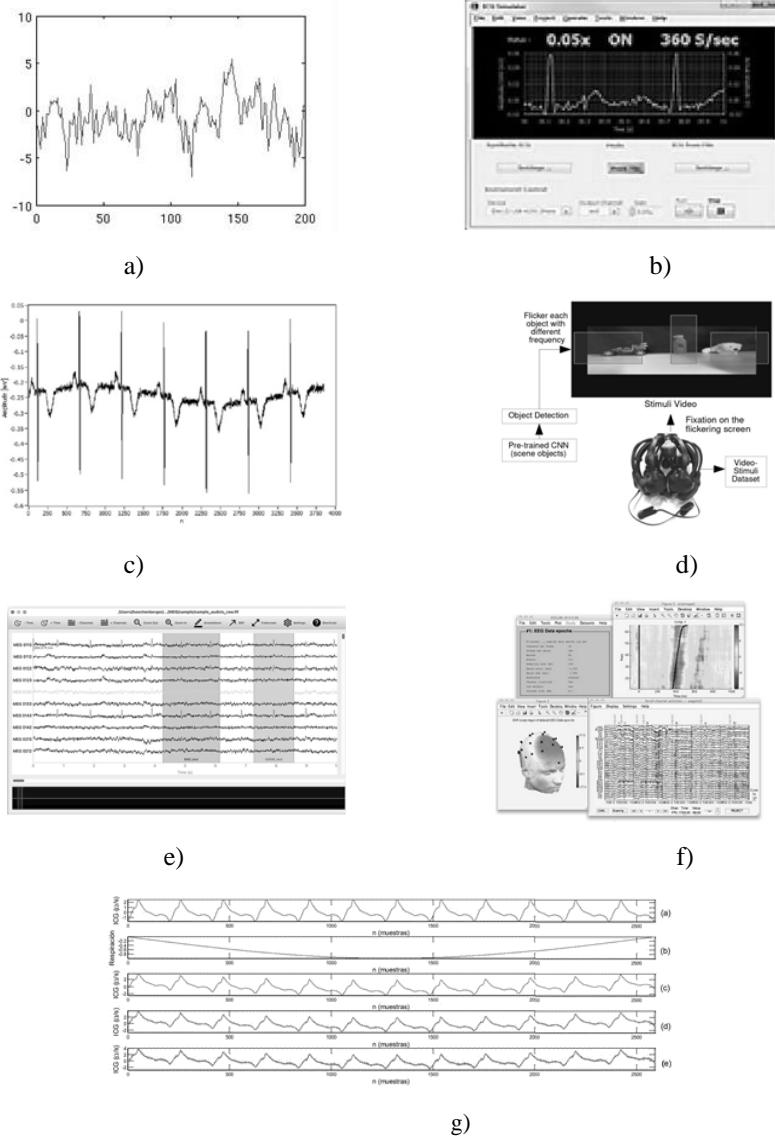
Nonetheless, being invasive entails greater associated risks. Both scalp EEG and intracranial signals are assessed for discernible patterns like epileptic spikes and ongoing background activity [15].

#### **3.1 Waves**

In EEG recordings, the potential difference between two electrodes is termed a wave. These shifts in cerebral electrical activity are identified as patterns [6]. Proper EEG interpretation necessitates distinguishing between normal and abnormal characteristics [16].

##### **Sharp Wave, Spike, Spike-Slow Wave, and Sharp Wave-Slow Wave Complexes:**

- Commonly referred to as spikes, these are transient waves distinguishable from background activity, lasting between 20 ms to just under 70 ms [2]. Characterized by their high amplitude and sharp morphology, these spikes might represent an event of overly synchronous neuronal discharge [2].
- Sharp waves, on the other hand, are also transient with a duration ranging from more than 70 ms to less than 200 ms, distinguished from background activity by their sharp peak at conventional paper speeds [8]. For its part, the Slow Wave-Point pattern, comprising a combination of sharp wave followed by a slow wave in the EEG, is commonly observed in typical absences or petit mal, but can also manifest in other clinical and epileptological conditions. Sharp waves represent a brief, synchronous



**Fig. 1.** a) Simulated EEG data generator [7]. b) ECG [8]. c) Model for generating simple synthetic ECG signals [9]. d) Simulating brain signals: creating synthetic EEG data via neural-based generative models for improved SSVEP classification [10]. e) MNE [11]. f) EEGLAB [12]. g) Generation of synthetic biosignals using time varying fourier series [10].

neuronal discharge, whereas slow waves may reflect the propagation of electrical activity through larger cortical circuits [9].

- Conversely, sharp waves are also transient, spanning over 70 ms but less than 200 ms. They stand out from the background activity due to their sharp

peak [17]. The Spike-Slow Wave pattern, a sequence of a sharp wave followed by a slow one in the EEG, is often seen in typical absence seizures but can also be evident in other clinical and epileptologic situations. Sharp waves indicate a synchronous, brief neuronal discharge, whereas slow waves might suggest the spread of electrical activity through expansive cortical circuits [2].

- As per Niedermeyer and da Silva, slow waves are low-frequency, low-amplitude electrical discharges in the EEG, enduring typically between 200 and 500 milliseconds [2]. Although they might occasionally overlap with sharp waves, they're chiefly defined as waves persisting over 200 ms [16]. Morphologically, slow waves exhibit a variable amplitude and a gentler waveform when contrasted with sharp waves. Notably, slow waves can correspond with the synchronized activity of neuron groups, reflecting slow depolarization processes and cortical spread. Such waves are observed in diverse clinical and epileptologic states, including deep sleep and specific seizure disorders [2].

Fig. 2, showcases generalized interictal epileptiform discharges in EEG signals, underscoring the previously discussed features. The depicted complexes have a pronounced amplitude, roughly 200 uV, with the alpha rhythm and background retaining a standard amplitude. Yet, due to the vertical scaling chosen for optimal visualization of epileptiform discharges, the latter might seem of diminished amplitude. The signals originate from an EEG recording of a 16-year-old with a history of absence seizures, even though he presently exhibits no epileptic episodes. Technical specifications of the recording are (LFF 1 Hz, HFF 70 Hz) [17].

**Transient Events and Wave Complexes:** A complex is typified as “a series of two or more waves with a characteristic or consistently repeated shape, distinct from the background activity” [17].

Complexes can manifest as diphasic, triphasic, or polyphasic waves. Typically, the term denotes a wave with at least three distinctive waveform components. These complexes are identifiable by specific features in a singular EEG channel, less defined than patterns which are determined by additional factors like positioning and dispersion.

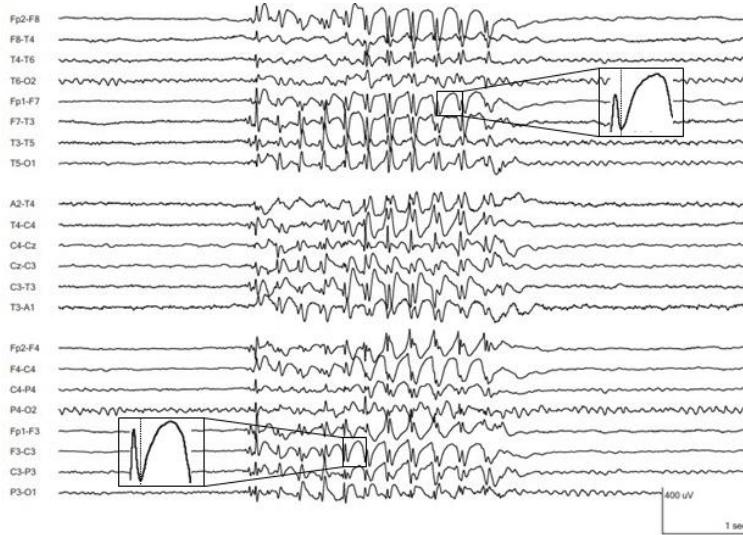
A transient event is demarcated as “an individual wave or complex, distinguishable from background activity” [17], marked by its pronounced disruption of the background activity and its duration.

### 3.2 EEG Frequency Characteristics

Clinical neurophysiology categorizes the EEG's background activity into various rhythmic bands, from the Delta rhythm (0-4 Hz) extending to exceptionally high EEG frequency components, seldom considered in regular clinical assessments [16].

#### 3.2.1 Rhythmic Bands

- **Delta Band (d):** Ranging from 0.1 to 4 Hz with amplitudes exceeding 50uV, this band typifies children younger than three months and Phase III of physiological sleep. It predominantly features regular, sinusoidal, or sawtooth-like waveforms.



**Fig. 2.** Generalized interictal epileptiform discharges. Polyspikes precede the initial spike and the ensuing slow wave complex, with subsequent complexes also showcasing initiating polyspikes in individual channels. Edited from [17].

- **Theta Band (theta):** Frequencies between 4 and 7 Hz, this band manifests with amplitudes surpassing 40µV and is predominantly fronto-central. Its waves can display various morphologies and are typically low amplitude.
- **Alpha Band (a):** Located within 8 and 12 Hz, its amplitude is approximately 15µV, dominantly in the occipital region. A distinguishing feature is its cessation during eyelid opening and intense concentration.
- **Beta Band (B):** Characterized by regular waveforms lasting around 50 ms with a sinusoidal shape. As a faster variant of the Alpha rhythm, these waves usually have low amplitudes between 5-10 µV, though they can rise to 15-25 µV. Primarily found in the frontal and central regions, their frequencies are typically between 18-25 Hz, but always above 13 Hz.
- **Gamma Band (Y):** This represents the higher EEG frequencies, predominantly between 30-70 Hz.

### 3.2.2 The 1/f Statistical Behavior of EEG in the Noise Context and Its Types

Through its 1/f statistical behavior, EEG has elucidated how cellular discharge microscopic rules and synaptic activity result in a complex system spread across various temporal scales. The inverse correlation between oscillation classes and the extent of neuronal engagement offers valuable insights into the brain's large-scale, long-term operations.

A Fourier analysis, yielding a power spectrum across frequencies, presents a straight line on a log-log chart where the density logarithm is plotted against the EEG frequency logarithm, suggesting scale-free systems. This relationship is articulated as  $A \approx 1/fa$ , where  $A$  symbolizes the amplitude (square root of power) and  $a$  is an exponent. This

infers that the EEG mirrors the brain's internal noise, generated by both its active and passive components.

However, the 'one over  $f$ ' power spectrum noise, or 'pink noise', is peculiar. It is essential to recognize that the mean frequencies of adjacent oscillatory groups are not integers relative to each other, making synchronization challenging and resulting in metastable or transient dynamics.

The log-log linear relationship gets disrupted below 2 Hz, possibly attributed in part to the high-pass filtering of the amplifiers utilized. Yet, extensive scalp recordings affirm a power-scaling behavior across all tested frequencies, lengthening the  $1/f$  line's temporal scale past a minute. The EEG introduces three primary noise types:

- **Pink Noise:** Its power spectrum adheres to a  $1/f$  relation, positioned between white and brown noise concerning predictability.
- **White Noise:** Exhibits no correlation between frequency bands, maintaining consistent power density across a limited frequency range. Its spectrum is flat, represented mathematically as  $1/f_0$ .
- **Brown Noise (Brownian Noise):** Pertaining to Brownian motion, this noise's power density diminishes with frequency ( $1/f^2$ ) quicker than pink noise. It's randomized over extended intervals but displays strong correlations over shorter spans.

The cerebral cortex, owing to its intricate architecture, emanates the most intricate noise recognized in physics. A pivotal query is the brain's rationale behind generating such intricate noise.

Several theories postulate that the brain oscillators aren't autonomous. Identical neurons and neuronal clusters orchestrate all rhythms. Oscillators at the cerebral level aren't merely swayed by noise; they might be spawning self-regulated collective patterns that sequentially influence the behavior of their constituent neurons [18].

## 4 Methodology

Over recent decades, the domain of Electroencephalography (EEG) has been intensely scrutinized, advancing the comprehension and characterization of cerebral signals. This progress has instigated the formulation of assorted tools and methodologies for the simulation and scrutiny of EEG data, particularly salient in scenarios where acquiring authentic signals is challenging or restricted.

Electroencephalographic (EEG) waves, stemming from cerebral electrical activity, are represented as voltage discrepancies between two electrodes. These transient patterns, termed waves, offer invaluable insights into cerebral dynamics. While the developed code in this project relies on established neurophysiological and mathematical principles, it is imperative to emphasize the balance between precision and realism in simulations. Inherent in any simulation is the abstraction from reality, which may not fully encapsulate the intricacies found in genuine EEG recordings.

---

**Algorithm 1.** EEG Signal Generation with Frequency Bands and Noise Integration.

---

Input: None  
Output: eeg\_signal (synthesized EEG signal)

1: Enumerate EEG frequency bands.  
These bands denote specific EEG frequency delineations.

1.1: delta\_band  $\leftarrow [0, 4]$   
Establish frequency range corresponding to deep sleep.

1.2: theta\_band  $\leftarrow [4, 8]$   
Identify frequency range associated with relaxation and meditative states.

1.3: alpha\_band  $\leftarrow [8, 12]$   
Denote frequency range typically correlated with relaxation and absence of visual stimuli.

1.4: beta\_band  $\leftarrow [12, 30]$   
Demarcate frequency range linked to active cognition and focus.

1.5: gamma\_band  $\leftarrow [30, 70]$   
Pinpoint frequency range affiliated with perceptual processes and cognizance.

2: Establish signal parameters.  
These parameters ascertain signal duration, sampling rate, and temporal vector.

2.1: duration  $\leftarrow 10$  sec  
2.2: sampling\_freq  $\leftarrow 500$  Hz  
2.3: num\_samples  $\leftarrow \text{duration} \times \text{sampling\_freq}$   
2.4: time  $\leftarrow$  array spanning from 0 to duration, incremented by 1/ sampling\_freq

3: Initialize eeg\_signal with zero-valued array.  
This array serves as the foundational canvas for impending band and noise superpositions.

4: generate\_band(freq\_range, amplitude, duration, sampling\_freq) function :  
Constructs a sinusoidal waveform with frequency and phase values chosen from a given range.

4.1: frequency  $\leftarrow$  random selection within freq\_range  
4.2: phase  $\leftarrow$  random selection between 0 and  $2\pi$   
4.3: Return amplitude  $\times \sin(2\pi \times \text{frequency} \times \text{time} + \text{phase})$

5: Incorporate variegated amplitudes from delta\_band into eeg\_signal  
This procedure amalgamates multiple sinusoidal signals onto the foundational signal.

6: Construct and standardize pink\_noise  
Pink\_noise is noise characterized by a power spectrum that diminishes with frequency.

6.1: pink\_noise  $\leftarrow$  accumulation of random Gaussian-distributed values.  
6.2: eeg\_signal  $\leftarrow$  eeg\_signal + pink\_noise

7: Produce and regulate white\_noise.  
White\_noise manifests uniform intensity across disparate frequencies.

7.1: white\_noise  $\leftarrow$  random Gaussian-distributed values.  
7.2: eeg\_signal  $\leftarrow$  eeg\_signal + white\_noise

8: Synthesize and modulate brown\_noise.  
Brown\_noise (or Brownian noise) exhibits correlations between time-series values.

8.1: brown\_noise  $\leftarrow$  cumulative random Gaussian-distributed values.  
8.2: eeg\_signal  $\leftarrow$  eeg\_signal + brown\_noise

9: Standardize eeg\_signal  
Adapt the amplitude of eeg\_signal to fit within a predetermined range.

End of Algorithm

---

**Fig. 3.** Pseudocode illustrates the synthesis of an EEG signal through the combination of varied frequency bands, notably Delta, and three noise types: pink, white, and brown. The culminating signal undergoes normalization to maintain a specified amplitude.

As we move forward, collaborative validation with esteemed EEG specialists becomes pivotal. As the project transitions into a public phase, this collaboration will facilitate iterative feedback, ensuring that the simulations retain as much realism and accuracy as possible. This approach underlines the importance of balancing theoretical knowledge with practical insights from experienced professionals in the field.

#### 4.1 Synthesis of EEG Signals

Enriching our proficiency in signal analysis and comprehension necessitates tools capable of simulating EEG data, mirroring genuine patterns. Such simulations furnish avenues for testing nascent theories, affirming analysis techniques, and refining real EEG interpretations.

This segment illuminates the methodology underpinning the synthetic generation of EEG signals, emphasizing their importance, simulation techniques, and plausible applications. Within this segment, we elucidate techniques employed for the synthetic simulation of Electroencephalogram (EEG) signals, leveraging mathematical functions and established Python libraries. The veracity of these simulated signals vis-à-vis their genuine counterparts is also appraised.

##### 4.1.1 Simulation of EEG Frequency Bands

EEG signals comprise various frequency bands, each indicative of distinct neural activities and states of consciousness. It is crucial to note that the simulations of these frequency bands are grounded in the information elaborated upon in Section 3.2. Each band is representative of specific neural patterns and consciousness states, as evidenced in prior studies [16, 18].

- **Delta Band:** Predominantly observed during profound sleep in adults, these waves are contrived using sine waves oscillating between 0 and 4 Hz.
- **Theta Band:** Largely detected during phases of shallow sleep and contemplative states, simulated via sine waves fluctuating between 4 and 7 Hz.
- **Alpha Band:** Customarily linked to tranquility, these waves are simulated within the 8 to 12 Hz frequency range.
- **Beta Band:** Emblematic of vigilant states, these waves are derived from frequencies surpassing 13 Hz.
- **Gamma Band:** Pertaining to cognition and alertness, gamma oscillations are simulated within a 30 to 70 Hz range.

Central to this simulation is the generate-band () function from Algorithm 1, which facilitates sine wave creation based on stipulated parameters, encompassing frequency bands, amplitude, span, noise, and more.

##### 4.1.2 Noise Integration

Given that authentic EEG is pervaded by multiple noise sources, it is essential to integrate noise within the simulations.

- **White Noise:** Defined by its unwavering spectral density across all frequencies, it's derived from the np.random.randn() function.

---

**Algorithm 2.** Synthesis of Spike-Wave Cluster in EEG Signals.

---

IIIInput: sfreq (sampling rate), group\_duration (optional, default 3 seconds)  
Output: group\_data (synthesized spike-wave cluster data)

```
1: generate_spike(amplitude, duration, sfreq) function:  
    1.1: Compute n_samples ← int(duration × sfreq)  
    1.2: Formulate spike employing a Gaussian function with a standard deviation of  
        n_samples/7  
    1.3: Return amplitude × spike / max(spike)  
2: generate_slow_wave(amplitude_wave, duration, sfreq) function:  
    2.1: Compute n_samples ← int(duration × sfreq)  
    2.2: Configure time ← array spanning from 0 to n_samples, incremented by 1/sfreq  
    2.3: Formulate slow_wave via a sinusoidal function with a 2 Hz frequency (Delta wave)  
    2.4: Return amplitude_wave × slow_wave  
3: Initialize amplitude_spike and duration_spike with random values  
4: Initialize amplitude_wave and duration_wave with random values  
5: Compute n_samples ← int(group_duration × sfreq)  
6: Initialize group_data with a zero-valued array of size n_samples  
7: Calculate n_spikes using a random value between 9 and 12  
8: Set current_start_index ← 0  
9: For _ in range(n_spikes) execute:  
    9.1: Refresh amplitude_spike and duration_spike with random values  
    9.2: Fabricate spike employing generate_spike function 9.3: If a random number is below  
        0.8, refresh amplitude_wave predicated on amplitude_spike;  
    9.4: Refresh duration_wave with a random value  
    9.5: Construct slow_wave via generate_slow_wave function  
    9.6: If current_start_index + spike length + slow_wave length is <= group_data length:  
        9.6.1: Append spike to group_data at current position  
        9.6.2: Append slow_wave to group_data at the subsequent position  
        9.6.3: Update current_start_index  
10: Return group_data
```

---

End of Algorithm

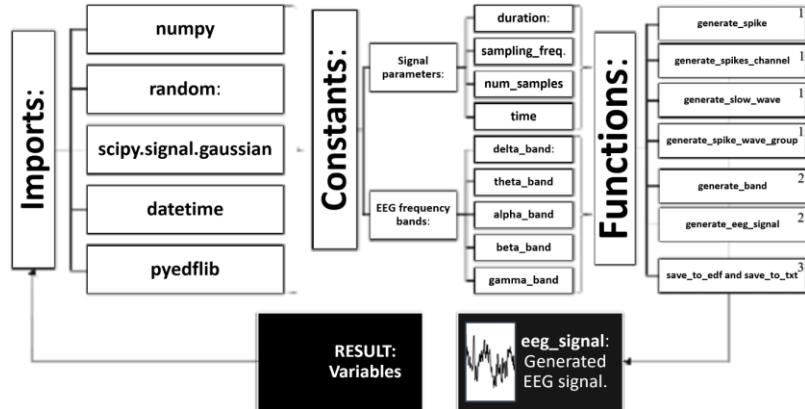
---

**Fig. 4.** This algorithm emulates the emergence of spike-wave clusters, a phenomenon recurrently observed within EEG signals. Individual spikes and slow waves are synthesized and amalgamated, resulting in a group pattern.

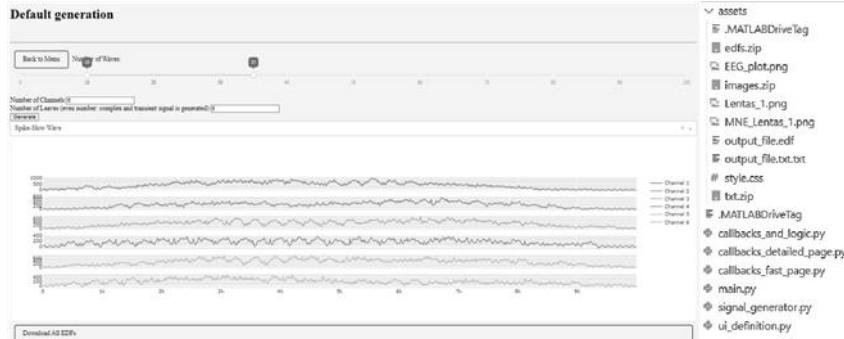
- **Pink Noise:** Exhibiting a frequency-dependent diminishing power spectrum, it's the culmination of aggregated white noise.
- **Brown Noise (or Brownian Noise):** Symbolizing the integrated accumulation of white noise, it portrays stochastic fluctuations dependent on time.

Subsequently, Fig. 3 illustrates a code for generating synthetic EEG signals by integrating various frequency bands with noise. For those unfamiliar with coding paradigms, this code showcases the emulation of an authentic EEG signal, encapsulating potential “interferences” or inherent noises characteristic of authentic measurements.

### Synthetic EEG Signal Generator of Morphologies Associated with Epileptogenic Events



**Fig. 5.** An illustrative schematic of the signal-generator.py script.



**Fig. 6.** Results stemming from the default generation paradigm. a) Generation interface showcasing Dash indicators. b) Real-time visualization of file generation within the assets directory.

#### 4.1.3 Emulation of Distinctive EEG Phenomena

Recognizing and emulating distinctive EEG patterns, especially those concomitants with clinical manifestations, is paramount. The functions `generatespike()`, `generateslow-wave()`, and `generate-spike-wave-group()` are indispensable for simulating spike waves, slow waves, and spike-slow wave clusters, respectively, in alignment with the theory previously delineated under "EEG Signals and Key Features."

Consequently, Fig. 4 emphasizes the emulation of a distinctive EEG phenomenon: the spike-wave cluster. This pattern is ubiquitously observed in EEG, particularly in certain disorders. The code synthetically renders this pattern, facilitating training and research endeavors.

#### 4.2 EEG Synthetic Signal Generator

The signal generator module is quintessential in synthesizing EEG datasets. Previously delineated functions enabled the generation of EEG signals, each harboring unique characteristic.

For a detailed understanding, it is crucial to refer to the theoretical descriptions of these waveforms, definitions of EEG frequency bands, and a comprehensive explanation of the generating functions provided in Section 3.2.

The software design emphasizes three core elements—modularity, scalability, and consistency—essential for a robust and reliable implementation. These elements are manifest in the tool’s architecture, which segregates specific functionalities into distinct modules: user interface (UI) definition, signal generation, and callback management. Fig. 5 provides a schematic representation of the script used for signal generation, highlighting the modular structure that incorporates essential libraries, constant parameters, and functions to produce a coherent and customizable EEG signal output.

The Python script outlined above and visualized in Fig. 5 is designed with a clear separation of concerns, allowing for independent development, testing, and maintenance of each component. The ‘imports’ section lists the essential libraries that provide the mathematical and signal processing functionalities required to generate EEG signals.

The ‘constants’ delineate the signal parameters and EEG frequency bands, which are fundamental to simulating the diverse aspects of EEG signals accurately. The ‘functions’ are a suite of tools developed to construct the EEG signal, incorporating various waveform patterns, such as spikes, slow waves, and their combinations, thus simulating complex neurological phenomena.

This structure not only aids in creating a clear and maintainable codebase but also ensures that the signal generation process is transparent and adaptable to changes in requirements or enhancements in EEG signal research.

### 4.3 Application Overview

Situated within the realm of EEG research, this endeavor is oriented towards the synthetic generation of EEG signals, manifesting distinct morphologies such as spike-waves, slow-waves, and spike-slow wave amalgamations. Engineered in Python, leveraging Dash, the application proffers two predominant operational modes:

- **Default Generation:** Here, users primarily define parameters like channel count for visualization, wave intervals per channel, and desired signal sheet count.

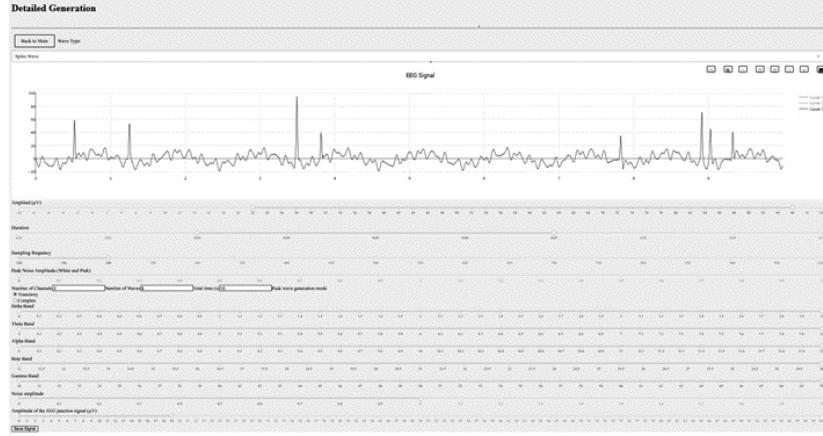
As depicted in Fig. 6, selection tools are available for waveform types, wave count per channel, sheet count (considering it generates complex and transient signals), and channel count. Additionally, an export functionality allows formats including “.txt”, “.edf”, and “.png”. An integrated Plotly visualization offers real-time insights before exportation.

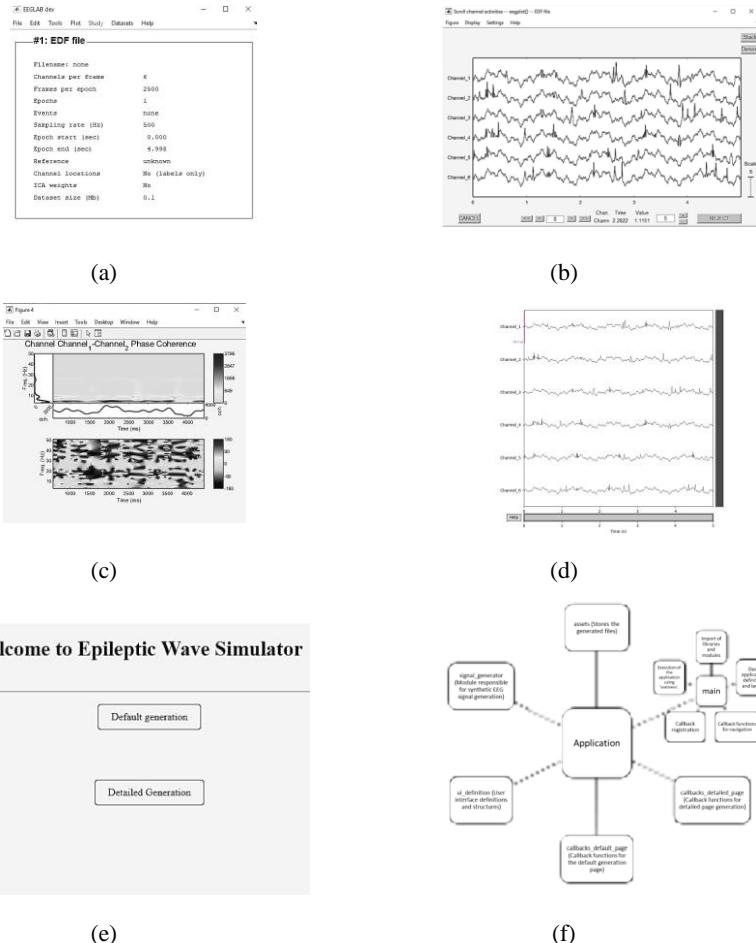
- **Detailed Generation:** This mode endows users with intricate control over generation parameters, as visualized in Fig. 7. Parameters encompass waveform amplitude, duration, sampling rate, and noise infusion.

Users can refine parameters: waveform selection, amplitude range in  $\mu\text{V}$ , signal duration in seconds, sampling frequency, and noise integration.

For compounded EEG signals, users have the flexibility to define frequency bands such as delta, theta, alpha, beta, and gamma, inclusive of noise conditions and EEG

## Synthetic EEG Signal Generator of Morphologies Associated with Epileptogenic Events



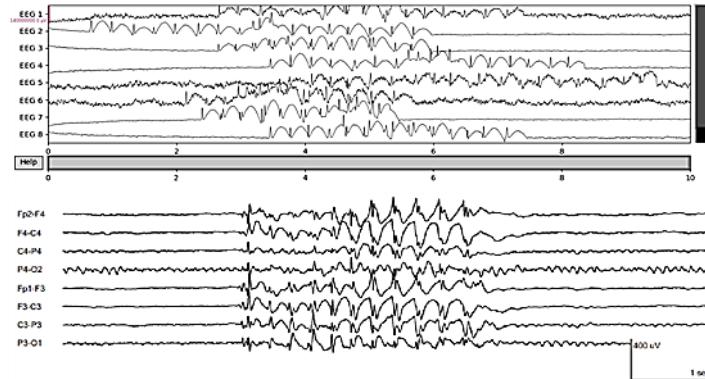


**Fig. 9.** a) Integration of the “.edf” file, synthesized within our application, into MATLAB’s EEGLAB. b) Temporal channel display within EEGLAB. c) Validation of signal authenticity via coherence analysis in EEGLAB. d) Illustration of spike waveforms within a 6-second viewing window. e) Initial snapshot of the application, spotlighting both rapid and detailed generation facets. f) Conceptual diagram underlining the application’s modular architecture.

In Fig. 9 the initial three illustrations (a-c) are derived from EEGLAB, showcasing the integration and analysis capabilities of this software with the signals generated by the “EEG signal generation tool for epileptogenic morphologies”. These sections demonstrate how the “.edf” file, synthesized by our application, is incorporated into EEGLAB followed by the display of temporal channel analyses and the validation of signal authenticity via coherence analysis.

Conversely, illustrations (d-f) represent various facets of the “EEG Synthetic Signal Generator for Epiloptogenic Morphologies” application. These include the portrayal of spike waveforms within a specific time frame, an initial snapshot of the application interface, and a conceptual diagram that delineates its modular structure. Together,

### Synthetic EEG Signal Generator of Morphologies Associated with Epileptogenic Events



**Fig. 10.** A Comparative Display of Synthetically Generated EEG Signal (top) and EEG Images fragments from John M. Stern's "Atlas of EEG Patterns".

these elements highlight the application's versatility in EEG signal generation and its compatibility with EEG processing tools like EEGLAB. This integration underscores the potential of the tool to provide EEG signals with valuable information for processing, analysis and study, especially in the context of epileptogenic morphologies.

#### 4.2 Signal Generation Precision

Upon juxtaposition of signals exhibited within our application against those within EEGLAB, there emerges a notable uniformity. Such congruence predicates that resultant analyses on the signal are both valid and analogous across diverse platforms. Nonetheless, an exhaustive similarity analysis remains pending. Leveraging externalized tools, exemplified by EEGLAB, validates the simulator's congruence and compatibility.

Such synergies pave the way to amalgamate the proficiencies inherent in both platforms, ensuring that the system interoperates seamlessly within industry standards. This facilitates integration with various platforms, thereby spawning datasets that catalyze algorithmic development in EEG signal analysis. Fig. 10 illustrates the tool's ability to reproduce realistic EEG signal patterns, comparing a synthetically generated signal with a real.

#### 4.3 Future Work

The next phase of development for this project is to undergo meticulous scrutiny by the medical fraternity. Such peer reviews are indispensable for affirming the authenticity of the generated signals and can unearth potential enhancements to the tool. Continuous feedback from medical experts remains vital to synchronize the tool with contemporary trends and revelations within the electroencephalography domain.

This process will not only validate the precision of the signal generation but also open avenues for its application in medical research and diagnostics. The goal is to establish the tool as a reliable resource for generating EEG data, particularly in areas where real data may be limited or inaccessible.

## 5 Conclusions

Electroencephalography (EEG) has steadfastly remained an instrumental paradigm in discerning cerebral dynamics. The meteoric advancements in analytical methodologies, coupled with integrated toolsets, have exponentially magnified EEG's pertinence. This endeavor endeavors to bridge the lacuna in synthetic EEG signal generation, facilitating the synthesis of waveforms mirroring genuine EEG morphologies. By harnessing mathematical paradigms and Python-centric programming, this tool has been meticulously engineered to simulate an array of EEG attributes, ranging from diverse frequency bands to specific events like spike waveforms.

An authentic EEG signal simulation mandates the infusion of noise, thereby ensuring data representation fidelity in real-world scenarios. The modular code architecture accentuates the project's adaptability and scalability, preemptively addressing prospective advancements in biosignal research. Its innate compatibility with renowned tools, such as EEGLAB, solidifies its prospective role in multi-platform integrations and expansive collaborations.

Importantly, the generation of synthetic EEG signals offers significant benefits, particularly in the realm of machine learning. Tools such as the one developed in this project contribute significantly to the training of intelligent systems, which require large datasets for effective learning. The synthetic signals generated can provide a rich, controlled variety of data, crucial for training robust machine learning models, especially in applications where real EEG data might be scarce or difficult to obtain.

In essence, while this initiative accentuates and augments the offerings of pre-existing platforms, it concurrently introduces a distinctive suite of features, poised to revolutionize EEG signal synthesis and simulation realms. Future directions encompass presenting this project to the medical domain, soliciting invaluable feedback to enhance signal precision and utility.

Potential extensions could also include a wide variety of default configurations tailored to medical requirements. This application, with its multifaceted offerings, could seamlessly integrate into the toolkit of EEG researchers, propelling the realm of EEG signal synthesis and simulations to unprecedented heights.

**Acknowledgments.** The fruition of this research has been facilitated by the unwavering support of the “Beca de Estímulo Institucional de Formación de Investigadores” (BEIFI) from the Programa Integral de Fortalecimiento Institucional (PIFI) at IPN. We extend our profound gratitude to IPN, primarily through the aegis of projects SIP20230872 and SIP20230780.

## References

1. Michel, C. M., Murray, M. M.: Towards the utilization of EEG as a brain imaging tool. *Neuroimage*, vol. 61, no. 2, pp. 371–385 (2012) doi: 10.1016/j.neuroimage.2011.12.039
2. Niedermeyer, E., da-Silva, F. L.: *Electroencephalography: Basic principles, clinical applications, and related fields*. 5th edn. Lippincott Williams & Wilkins, Baltimore, MD, USA (2005)

3. Brunner, C., Billinger, M., Seeber, M., Mullen, T. R., Makeig, S.: Volume conduction influences scalp-based connectivity estimates. *Frontiers in Computational Neuroscience*, vol. 10 (2016) doi: 10.3389/fncom.2016.00121
4. Bigdely-Shamlo, N., Mullen, T., Kothe, C., Su, K. M., Robbins, K. A.: The prep pipeline: standardized preprocessing for large-scale EEG analysis. *Frontiers in Neuroinformatics*, vol. 9 (2015) doi: 10.3389/fninf.2015.00016
5. Martínez-Barros, M. I., Trout-Guardiola, G.: Conceptos básicos de electroencefalografía. *Duazary*, vol. 3, no. 1, pp. 18–23 (2006)
6. Yeung, N., Bogacz, R., Holroyd, C., Nieuwenhuis, S., Cohen, J.: Simulated EEG data generator. MRC Brain Network Dynamics Unit <https://data.mrc.ox.ac.uk/dataset/simulated-eeg-data-generator>
7. ECG simulator. Data Science Automation (DSA), EMERSON (2012) <https://www.ni.com/es/support/downloads/tools-network/download.ecg-simulator.html#373418>
8. Dolinský, P., Andráš, I., Michaeli, L., Grimaldi, D.: Model for generating simple synthetic ECG signals. *Acta Electrotechnica et Informatica*, vol. 18, no. 3, pp. 3–8 (2018) doi: 10.15546/aeei-2018-0019
9. Nick-Aznan, N. K., Atapour-Abarghouei, A., Bonner, S., Connolly, J. D., Al-Moubayed, N., Breckon, T. P.: Simulating brain signals: Creating synthetic EEG data via neural-based generative models for improved SSVEP classification. In: 2019 International joint conference on neural networks (IJCNN), pp. 1–8 (2019) doi: 10.1109/IJCNN.2019.8852227
10. Escrivá-Muñoz, J., Galea-Cazorla, A., González-Pijuán, C., Vallverdú, M., Caminal, P., Jensen, E. W.: Generación de bioseñales sintéticas mediante series de Fourier variantes en el tiempo. In: Actas de las XXXVII Jornadas de Automática, Comité Español de Automática, pp. 227–233 (2016) doi: 10.17979/spudc.9788497498081.0227
11. Swartz Center for Computational Neuroscience: What is EEGLAB? (2004)
12. MNE. Open-source python package for exploring, visualizing, and analyzing human neurophysiological data: MEG, EEG, SEEG, ECOG, NIRS, and more. (2012) <https://mne.tools/stable/index.html>
13. Oostenveld, R., Praamstra, P.: The five percent electrode system for high-resolution EEG and ERP measurements. *Clinical neurophysiology*, vol. 112, no. 4, pp. 713–719 (2001) doi: 10.1016/S1388-2457(00)00527-7
14. van-Drongelen, W.: Signal processing for neuroscientists: An introduction to the analysis of physiological signals. Elsevier Inc, Burlington (2007)
15. Stern, J. M.: *Atlas of EEG patterns*. second edition, Lippincott Williams & Wilkins, A Wolters Kluwer business, Philadelphia (2001)
16. Buzsáki, G.: *Rhythms of the brain*. Oxford University Press, Madison Avenue, New York (2006)



# **Propuesta de sistema computacional para incendios forestales y clasificación de días con riesgo a incendio usando temperatura y humedad en una reserva natural, caso de estudio**

Carlos Sebastián Maya-Rojina, Luis Pastor Sánchez-Fernández,  
Mario Eduardo Rivero-Ángeles

Instituto Politécnico Nacional, Centro de Investigación en Computación,  
CDMX, México

{cmayar2022, l.sanchez, erivero}@cic.ipn.mx

**Resumen.** Se propone un sistema computacional para prevención, evaluación de riesgo y monitoreo de incendios forestales integrando diferentes herramientas tales como simuladores, redes de sensores e índices de vulnerabilidad, además, se profundiza en el estudio de caso sobre clasificación de días en los que hubo vulnerabilidad a incendios en una reserva ecológica utilizando datos meteorológicos de temperatura y humedad y los incendios registrados los últimos 22 años (2001-2023), aplicando y comparando entre sí diferentes algoritmos de clasificación, métodos de selección de instancias y de atributos. Se propone el agregado de índices de vulnerabilidad como entrada al clasificador, la implementación de métodos de balanceo y de selección de instancias, ampliar los experimentos usando los clasificadores con buenos resultados y descartar los que tuvieron un bajo desempeño.

**Palabras clave:** Incendios forestales, Estudio de caso de clasificación, vulnerabilidad a incendios.

## **Proposal for a Computer System for Forest Fires and Classification of Days with Fire Risk Using Temperature and Humidity in a Nature Reserve, Case Study**

**Abstract.** A computational system for prevention, risk assessment and monitoring of forest fires is proposed, integrating different tools such as simulators, sensor networks and vulnerability indexes. In addition, a case study on the classification of days in which there was vulnerability to fires in an ecological reserve using meteorological data of temperature and humidity and the fires recorded in the last 22 years (2001-2023) is studied in depth, applying and comparing different classification algorithms, instance and attribute selection methods. It is proposed to add vulnerability indices as input to the classifier, implement balancing and instance selection methods, extend the experiments

*Carlos Sebastián Maya-Rojina, Luis Pastor Sánchez-Fernández, Mario Eduardo Rivero-Ángeles*

using the classifiers with good results and to discard the ones that performed poorly.

**Keywords:** Forest fires, classification case study, vulnerability to fires.

## 1. Introducción

Los incendios forestales suelen tener consecuencias graves para el ecosistema, tales como pérdida de flora, fauna y de patrimonio biocultural, erosión del suelo, liberación de niveles altos de CO<sub>2</sub> a la atmósfera, deforestación, fragmentación de ecosistemas entre otros [5, 6]. Según la CONAFOR, uno de los factores principales en la propagación de incendios es la limitada capacidad de respuesta para su tratamiento [7]. Por lo tanto, es importante el desarrollo de herramientas tecnológicas para su detección temprana, monitoreo y prevención.

En este trabajo se plantea en lo general un sistema computacional para atender el problema de los incendios forestales y se detallan los resultados de un primer acercamiento a la clasificación de los días propensos a incendios, tomando como caso de estudio una reserva natural y utilizando datos meteorológicos de temperatura y humedad, así como los días en los que sucedieron incendios de los últimos 22 años, haciendo uso de diferentes preprocesamientos y técnicas de clasificación, y se hace una comparación entre ellas respecto a su Sensibilidad, Precisión, Medida F1 y Especificidad. El sistema computacional propuesto así como los resultados pueden contribuir al desarrollo de un sistema de prevención, alerta temprana y monitoreo implementado en la reserva.

## 2. Descripción general del sistema computacional propuesto

Se plantea el desarrollo e integración de diferentes herramientas computacionales para generar un ecosistema alrededor de los incendios forestales: un simulador de incendios, la simulación de una red de sensores interaccionando con el simulador, la clasificación de días vulnerables y la creación de un índice de vulnerabilidad, el componente a explayar en el artículo es únicamente el primer acercamiento a la clasificación, el resto de herramientas se describen en su primera etapa de desarrollo y su objetivo final, esto para enmarcar el trabajo de los clasificadores dentro de un conjunto.

### 2.1. Simulador de incendios

Utilizando autómatas celulares, teniendo como características principales de cada celda: la cantidad de combustible, vulnerabilidad actual a un fuego, probabilidad de dispersión de un fuego a celdas vecinas (afectada por la inclinación y por la cantidad de viento) y siguiendo reglas de dispersión conocidas de los incendios forestales, capaz de reproducir el comportamiento de un incendio.

Actualmente su enfoque de desarrollo es a proporcionar un entorno de simulación para la realización de pruebas de la dinámica de una red de sensores con los incendios

forestales. Sin embargo, en el futuro los valores deben ser “mapeados” a la realidad o comparados con simuladores espaciales existentes, para su validación (tarea compleja por la escases de datos de la forma a través del tiempo de incendios forestales).

El desarrollo de esta herramienta podría funcionar, además del entorno para la simulación de una red de sensores, como asistencia en el combate a incendios, tanto de manera preventiva (identificar zonas clave para la instalación de tanques de agua, mayor frecuencia en la vigilancia) como durante el incendio (indicando al cuerpo de bomberos un plan de acción óptimo para la reducción de daños). Se encontraría limitada por la cantidad de datos disponibles para su validación, y ya validada, por los datos disponibles del área a implementarse, así como por la naturaleza caótica de los incendios.

## **2.2. Simulador de red de sensores**

Su objetivo inicial es evaluar diferentes esquemas de comunicación (que determinan las probabilidades de envío de mensaje y de despertar, como las funciones de probabilidad y el algoritmo que sigue cada nodo) implementados en la red, en relación a su capacidad de monitorear un incendio, así como de disminuir su consumo energético (dado que los nodos estarán instalados en áreas sin un acceso constante a fuentes de energía, es necesario que sean óptimos energéticamente hablando), permitiendo generar y corroborar un modelo matemático de cada esquema.

Esta sección del sistema computacional también permite evaluar diferentes configuraciones de la red, sus posicionamientos adecuados para un mejor monitoreo y capacidad de detección, así como los primeros pasos para la simulación de técnicas de enrutamiento de información (en el que un nodo no tiene alcance al nodo objetivo por la distancia y necesita recurrir a nodos intermedios para hacer llegar el mensaje).

## **2.3. Clasificación de días vulnerables a incendios**

Se ejecutaron pruebas con diferentes clasificadores, targets y preprocesamientos. Esta parte del modelo computacional será expliado en las siguientes secciones.

## **2.4. Índice de vulnerabilidad**

Implementando un sistema difuso para obtener un índice de vulnerabilidad hora a hora, utilizando los datos disponibles de temperatura y humedad, su desarrollo permitirá indicar al personal de reserva una primera alerta y debería ser implementado como atributo de apoyo en la clasificación, así como sentar las bases de un sistema difuso más integral que tome en cuenta características propias de la vegetación y factores humanos tales como la cantidad de interacción de una zona de la reserva con personas, el momento del ciclo escolar (que define la cantidad de población estudiantil que accede a C.U.), etc.

### **3. Estado del arte - clasificadores**

Alonso-Fontenla et. al. 2003 [3] Presentan un sistema integrando redes neuronales para la predicción de riesgo a incendio, un sistema que apoye en el combate a incendios y un sistema de asistencia en la planeación de la recuperación de áreas quemadas. La sección de predicción de riesgo se enfoca a Galicia (comunidad autónoma de España, 36,000km<sup>2</sup>, utilizando los datos de incendios de 13 años (1988-2001) y las variables de temperatura del mismo día y de días previos, humedad diaria, precipitación y el histórico de incendios, con un total de 13,906 muestras de incendio y 125,156 de no incendio, utilizaron una estrategia de crecimiento de redes neuronales, en la que se agregan capas y neuronas de manera progresiva hasta alcanzar un óptimo, obtuvieron una Exactitud de 78.9%, una Sensibilidad de 90.4% y una especificidad de 67.4%.

Sakr-Elhajj et. al, 2011 [1] Propusieron un sistema de predicción de incendios forestales orientado a zonas con poca infraestructura, utilizando Redes Neuronales Artificiales y Máquinas de Soporte Vectorial utilizando las variables del día anterior al incendio de 8 años (2000-2008): mínima y máxima temperatura del día, promedio de humedad y de velocidad del viento, radiación solar total y el acumulado del nivel de precipitación empezando por el 1ro de Octubre, para predecir la cantidad de incendios que habrían en el Líbano cada día para la temporada de incendios, con clasificadores entrenados para cada mes, alcanzando un accuracy de 94.21%. Sin embargo, no se mencionan otras medidas de evaluación (el accuracy podría ser de 95% si solo hubo un 5% de días con incendios y se clasifican todos como sin incendios), ni la proporción de días con o sin incendio.

Chang-Zhu et. al. 2013 [2] Utilizaron regresión logística para predicción de incendios de 28 años (1980-2009) utilizando puntos de incendios (2,359) en una provincia de China (454,800km<sup>2</sup>) y separándolos de puntos del mismo día en otra locación (con una proporción aproximada de 1.5 días sin incendio por cada día con incendio en el muestreo), utilizando mapas de variables de densidad de población, elevación, inclinación, distancia a caminos, promedio anual de temperatura y precipitación, promedio diario de velocidad de viento, temperatura y humedad, precipitación, mínima temperatura y humedad, máxima temperatura y tiempo con radiación solar, y el tipo de vegetación, una precisión de 51.6%, sensibilidad de 72.7% y especificidad de 0.78%.

Oulad-Mousannif et. al. 2019 [4] utilizaron técnicas de data mining, redes neuronales y máquinas de soporte vectorial, para clasificar entre regiones con incendio y regiones sin incendio empleando datos de la densidad de vegetación, temperatura de superficie y anomalía térmica, todos provenientes de satélites con una resolución espacial de 1km y diaria de 1 día, en un área de 20,000 km<sup>2</sup> en el centro de Canadá, con incendios de un año (2013-2014), con 386 totales y 418 muestras agregadas de no incendio (que pertenecen a datos de la zona donde hubo un incendio, de otro día) ; alcanzando un 97% de precisión, con 98% de sensibilidad.

En nuestra propuesta nos enfocamos a un área mucho más específica (1.245 km<sup>2</sup>), implicando una menor cantidad de datos de incendios, utilizando únicamente datos de temperatura y humedad, una expansión de los atributos y selección de los mismos, enfocando el proyecto a la predicción y a medidas preventivas de incendios de áreas relativamente pequeñas, evaluando el sistema de una manera más cercana a la implementación.

## 4. Materiales y métodos

### 4.1. Descripción de los datos utilizados para las pruebas de clasificación

Se utilizaron dos fuentes de datos para esta sección del sistema computacional. La primera, de datos meteorológicos que fue obtenida del Programa de Estaciones Meteorológicas del Bachillerato Universitario (PEMBU), de la estación meteorológica del Plantel Sur del Colegio de Ciencias y Humanidades (CCH-Sur), que es de libre acceso. La segunda, del histórico de incendios, proporcionada por la Reserva Ecológica del Pedregal de San Ángel (REPSA) como parte de la colaboración académica realizada para este proyecto.

Los datos meteorológicos consisten en Fecha y hora, y los valores de Temperatura, Humedad Relativa, Rapidez del viento sostenido, Dirección del viento sostenido, Rapidez de racha, Dirección de racha, Presión barométrica, Precipitación, Radiación Solar, Índice UV y Dosis UV censados por la estación cada media hora desde enero del 2001 hasta enero del 2023 siendo un total de 387169 muestras.

Los datos de incendios consisten en Número de Identificación del incendio, Fecha, Periodo, Año, Mes, Hora, Tipo de siniestro, X,Y, Ubicación, Acción, Foto y Superficie en m<sup>2</sup>, Superficie en ha, Zona, Clave, Elementos Bomberos, Duración (hrs.), Temperatura ambiental, Humedad ambiental, Temperatura de la superficie del fuego, Factor de inicio, Fuente de la información, Número de Identificación del reporte de incendio, Fecha de levantamiento, Técnica, Plano cartográfico y la Persona que Elaboró, registrados por el personal de la Secretaría Ejecutiva de la REPSA (SEREPSA) desde enero del 2001 hasta marzo del 2023, con un total de 322 incendios reportados.

### 4.2. Preprocesamiento

De la fuente de datos de incendios se empleó únicamente la información del día del incendio, ya que el resto de columnas no se consideran útiles para el momento para la clasificación, o se encuentran demasiado incompletas para su uso (Superficie del incendio). De la fuente de datos meteorológicos se utilizaron solamente los valores de temperatura y humedad relativa, puesto que son los datos más completos y de sensores económicos (pensando en una futura implementación en hardware de la red de sensores), sus valores fueron normalizados a un intervalo de 0 a 1 y las instancias con valores nulos fueron eliminadas del dataset.

**Expansión de atributos** De la fuente de información original de los datos meteorológicos se obtuvieron los siguientes valores tanto para temperatura como para humedad:

- Promedio de todos los datos.
- Valor más alto y más bajo.
- Promedio de los 5, 10 y 20 valores más altos y más bajos.

Estos fueron extraídos del día anterior al incendio y de los 5, 10 y 20 días precedentes al mismo. De lo anterior se obtuvieron un total de 72 atributos para la clasificación.

**Selección de atributos** Se implementaron tres métodos de selección de atributos.

*Carlos Sebastián Maya-Rojina, Luis Pastor Sánchez-Fernández, Mario Eduardo Rivero-Ángeles*

*Por rankeo de atributos* La selección se realizó tomando los primeros 10 atributos, dándoles puntuaciones a cada uno respecto a diferentes métricas, entre ellas:

- Ganancia de Información y Radio de Ganancia de Información - Calculan la ganancia de información de cada característica respecto a la variable objetivo usando la entropía condicional.
- $X^2$  - Determina si existe o no una relación significativa entre dos variables.
- ReliefF - Para cada instancia se mide la distancia a la instancia más cercana de la misma clase y a la más cercana perteneciente a otra clase, y actualiza el peso de cada atributo en función de las distancias obtenidas.

*PCA* Es una técnica estadística multivariable que reduce la dimensionalidad de un dataset, transformando el conjunto de variables correlacionadas entre sí a un conjunto de variables no correlacionadas entre sí llamadas componentes principales, estas variables principales están ordenadas de forma tal que las primeras mantienen la mayoría de la variación presente en el dataset original [10]. De ella se seleccionaron los primeros 10 atributos.

*Manual* Se eligieron los 11 atributos que se consideraron con mayor injerencia en la vulnerabilidad a incendios en la zona. Los atributos seleccionados fueron:

- Promedio de temperatura del día anterior.
- Promedio de temperatura de los 5 días anteriores.
- Temperatura más alta del día anterior.
- Promedio de 5 temperaturas más altas del día anterior.
- Temperatura más alta de los 5 días anteriores.
- Promedio de 5 temperaturas más altas de los 5 días anteriores.
- Humedad más alta del día anterior.
- Promedio de 5 humedades más altas del día anterior.
- Promedio de 5 humedades más bajas del día anterior.
- Promedio de 5 humedades más bajas de los 5 días anteriores.
- Promedio de 10 humedades más bajas de los 5 días anteriores.

#### **4.3. Algoritmos de selección de instancias**

*Eliminación de meses con bajo porcentaje de incendios* Se eliminaron los meses que contenían menos del 3 y del 5% de incendios de los últimos 22 años.

**Target** Se utilizaron dos targets diferentes. El primero, en el que los días anteriores a cuando hubo un incendio tienen un valor de 1 y el resto de días tienen un 0; el segundo, en el que se aplicó una ventana en la que el día anterior, el mismo día y un día posterior al incendio tienen un valor de 1 y el resto de días tienen un 0, pensando en que la reserva era más vulnerable a incendios el día mismo del incendio, pero que esta vulnerabilidad existía un día anterior y un día posterior (no se genera ni se disipa de manera inmediata), este segundo target fue utilizado únicamente para cuando se implementó una selección de instancias en los datos.

#### **4.4. Clasificadores supervisados utilizados**

**Naive Bayes** Basado en la regla de Bayes, supone que los atributos son independientes entre sí, simplificando el sistema [9], construye reglas que permiten clases predictivas para nuevos datos, es fácil de implementar e interpretar y puede aplicarse sin complicación a datasets extensos, sin embargo, requiere computar una gran cantidad de probabilidades condicionales.

**Redes Neuronales Artificiales** Del campo de la Inteligencia Artificial, están inspiradas en el funcionamiento biológico del sistema nervioso, se conectan por "capas" de varias neuronas y se utiliza un proceso de aprendizaje con base en ejemplos para optimizar la función de clasificación [11], son ampliamente utilizadas para problemas de clasificación e inferencia, guardan información a lo largo de toda la red y trabajan bien con información incompleta, sin embargo requieren procesos paralelos para mejorar los tiempos de entrenamiento y no poseen interpretabilidad de los resultados.

**CN2 Inductor de Reglas** Induce reglas "Si... entonces..." usando entropía o error laplaciano como su heurística de búsqueda [12], funciona bien para conjuntos de datos con ruido independiente de su extensión, sin embargo, tiene problemas para representar la interacción entre variables y con datasets desbalanceados.

**Máquina de Soporte Vectorial** Proviene de los modelos lineales, se transforma el espacio de entrada haciendo uso de combinación no lineal y generando un límite de decisión [9], requiere pocos datos para su entrenamiento, sin embargo, son lentas en su entrenamiento y en implementación, dependiendo de la extensión de los datos, pueden requerir grandes cantidades de memoria disponible.

### **5. Resultados y discusión**

#### **5.1. Diseño experimental**

Los experimentos se realizaron combinando la selección de instancias, la elección de atributos y el target. Dando un total de 80 experimentos.

Siendo las 3 formas de selección de instancias:

- Sin selección de instancias.
- Seleccionando únicamente los meses con más del 3% de incendios.
- Seleccionando únicamente los meses con más del 5% de incendios.

Las 4 formas de selección de atributos:

- Por rankeo, los 10 primeros.
- PCA, los 10 primeros.
- Manual, los 11 considerados más adecuados.
- Sin selección.

Los 4 clasificadores:

- Naive Bayes.
- Redes Neuronales.
- Inductor de reglas CN2.

**Tabla 1.** Tabla de los resultados utilizando los datos sin selección de instancias y el target puntual.

		Datos sin Selección de Instancias, Target puntual			
Método de selección de atributos	Matriz de confusión/ Medidas de desempeño	Clasificador			
		Naive Bayes	Red Neuronal	CN2	SVM
Top 10	TN	3973	5147	5090	4667
	FP	1222	48	105	528
	FN	31	124	129	90
	TP	105	12	7	46
	Sensibilidad	0.7721	<b>0.0882</b>	0.0515	<b>0.3382</b>
	Especificidad	0.7648	<b>0.9908</b>	0.9798	0.8984
	Precisión	<b>0.0791</b>	<b>0.2000</b>	0.0625	<b>0.0801</b>
	F1	<b>0.1435</b>	<b>0.1224</b>	0.0565	<b>0.1296</b>
	TN	3234	5044	4960	4939
	FP	1871	61	145	166
PCA	FN	13	129	120	122
	TP	123	7	16	14
	Sensibilidad	<b>0.9044</b>	0.0515	<b>0.1176</b>	0.1029
	Especificidad	0.6335	0.9881	0.9716	<b>0.9675</b>
	Precisión	0.0617	0.1029	0.0994	0.0778
	F1	0.1155	0.0686	<b>0.1077</b>	0.0886
	TN	5134	6203	6160	5656
	FP	1141	72	115	619
	FN	100	177	175	150
	TP	87	10	12	37
Manual	Sensibilidad	0.4652	0.0535	0.0642	0.1979
	Especificidad	<b>0.8182</b>	0.9885	<b>0.9817</b>	0.9014
	Precisión	0.0708	0.1220	<b>0.0945</b>	0.0564
	F1	0.1230	0.0743	0.0764	0.0878
	TN	3234	5044	4960	4939
	FP	1871	61	145	166
	FN	13	129	120	122
	TP	123	7	16	14
	Sensibilidad	<b>0.9044</b>	0.0515	<b>0.1176</b>	0.1029
	Especificidad	0.6335	0.9881	0.9716	<b>0.9675</b>
Sin Selección	Precisión	0.0617	0.1029	0.0994	0.0778
	F1	0.1155	0.0686	<b>0.1077</b>	0.0886

- Máquina de Soporte Vectorial.

Los 2 tipos de target

- Día puntual.

**Tabla 2.** Tabla de los resultados utilizando sin datos de meses con > 3% de incendios y el target puntual.

<b>Datos Selección de Meses &gt; 3%, Target puntual</b>					
Método de selección de atributos	Matriz de confusión/ Medidas de desempeño	Clasificador			
		Naive Bayes	Red Neuronal	CN2	SVM
Top 10	TN	2738	3587	3498	2825
	FP	905	56	145	818
	FN	61	137	142	91
	TP	87	11	6	57
	Sensibilidad	0.5878	0.0743	0.0405	<b>0.3851</b>
	Especificidad	0.7516	0.9846	0.9602	0.7755
	Precisión	<b>0.0877</b>	0.1642	0.0397	0.0651
	F1	<b>0.1526</b>	0.1023	0.0401	<b>0.1114</b>
	TN	2151	3281	3208	3230
	FP	1192	62	135	113
PCA	FN	29	119	114	125
	TP	105	15	20	9
	Sensibilidad	<b>0.7836</b>	<b>0.1119</b>	<b>0.1493</b>	0.0672
	Especificidad	0.6434	0.9815	0.9596	<b>0.9662</b>
	Precisión	0.0810	<b>0.1948</b>	<b>0.1290</b>	<b>0.0738</b>
	F1	0.1468	<b>0.1422</b>	<b>0.1384</b>	0.0703
	TN	3407	4023	3957	3447
	FP	671	55	121	631
	FN	122	178	168	158
	TP	63	7	17	27
Manual	Sensibilidad	0.3405	0.0378	0.0919	0.1459
	Especificidad	<b>0.8355</b>	<b>0.9865</b>	<b>0.9703</b>	0.8453
	Precisión	0.0858	0.1129	0.1232	0.0410
	F1	0.1371	0.0567	0.1053	0.0641
	TN	2151	3281	3208	3230
	FP	1192	62	135	113
	FN	29	119	114	125
	TP	105	15	20	9
	Sensibilidad	<b>0.7836</b>	<b>0.1119</b>	<b>0.1493</b>	0.0672
	Especificidad	0.6434	0.9815	0.9596	<b>0.9662</b>
Sin Selección	Precisión	0.0810	<b>0.1948</b>	<b>0.1290</b>	<b>0.0738</b>
	F1	0.1468	<b>0.1422</b>	<b>0.1384</b>	0.0703

- Ventana.

## 5.2. Parámetros utilizados en cada clasificador

- Naive Bayes.
  - Sin parámetros.
  - Red neuronal Perceptrón Multicapa, con 3 capas escondidas de 50, 100 y 20 neuronas.
  - 3 capas ocultas.

*Carlos Sebastián Maya-Rojina, Luis Pastor Sánchez-Fernández, Mario Eduardo Rivero-Ángeles*

**Tabla 3.** Tabla de los resultados utilizando sin datos de meses con >3% de incendios y el target de ventana.

Datos Selección de Meses >3%, Target de ventana					
Método de selección de atributos	Matriz de confusión/ Medidas de desempeño	Clasificador			
		Naive Bayes	Red Neuronal	CN2	SVM
Top 10	TN	2728	3699	3443	2872
	FP	1065	94	350	921
	FN	156	417	367	280
	TP	305	44	94	181
	Sensibilidad	0.6616	0.0954	0.2039	<b>0.3926</b>
	Especificidad	0.7192	<b>0.9752</b>	0.9077	0.7572
	Precisión	<b>0.2226</b>	0.3188	0.2117	<b>0.1642</b>
	F1	<b>0.3332</b>	0.1469	0.2077	<b>0.2316</b>
	TN	2059	3014	2970	2529
	FP	1088	133	177	618
PCA	FN	90	160	210	216
	TP	240	170	120	114
	Sensibilidad	<b>0.7273</b>	<b>0.5152</b>	<b>0.3636</b>	0.3455
	Especificidad	0.6543	0.9577	<b>0.9438</b>	<b>0.8036</b>
	Precisión	0.1807	<b>0.5611</b>	<b>0.4040</b>	0.1557
	F1	0.2895	<b>0.5371</b>	<b>0.3828</b>	0.2147
	TN	2897	3628	3525	2302
	FP	903	172	275	1498
	FN	242	383	377	287
	TP	221	80	86	176
Manual	Sensibilidad	0.4773	0.1728	0.1857	0.3801
	Especificidad	<b>0.7624</b>	0.9547	0.9276	0.6058
	Precisión	0.1966	0.3175	0.2382	0.1051
	F1	0.2785	0.2238	0.2087	0.1647
	TN	2059	3014	2970	2529
	FP	1088	133	177	618
	FN	90	160	210	216
	TP	240	170	120	114
	Sensibilidad	<b>0.7273</b>	<b>0.5152</b>	<b>0.3636</b>	0.3455
	Especificidad	0.6543	0.9577	<b>0.9438</b>	<b>0.8036</b>
Sin Selección	Precisión	0.1807	<b>0.5611</b>	<b>0.4040</b>	0.1557
	F1	0.2895	<b>0.5371</b>	<b>0.3828</b>	0.2147

**Tabla 4.** Tabla de los resultados utilizando sin datos de meses con >5% de incendios y el target puntual.

Datos Selección de Meses >5%, Target puntual						
Método de selección de parámetros	Matriz de confusión/ Medidas de desempeño	Clasificador				
		Naive Bayes	Red Neuronal	CN2	SVM	
Top 10	TN	1890	2366	2316	2435	
	FP	545	69	119	0	
	FN	58	115	108	124	
	TP	66	9	16	0	
	Sensibilidad	0.5323	0.0726	0.1290	0.0000	
	Especificidad	0.7762	0.9717	0.9511	1.0000	
	Precisión	<b>0.1080</b>	0.1154	0.1185	NaN	
	F1	<b>0.1796</b>	0.0891	0.1236	0.0000	
	TN	1588	2371	2322	2432	
	FP	847	64	113	3	
PCA	FN	45	106	107	124	
	TP	79	18	17	0	
	Sensibilidad	<b>0.6371</b>	<b>0.1452</b>	<b>0.1371</b>	0.0000	
	Especificidad	0.6522	0.9737	0.9536	<b>0.9988</b>	
	Precisión	0.0853	<b>0.2195</b>	<b>0.1308</b>	0.0000	
	F1	0.1505	<b>0.1748</b>	<b>0.1339</b>	0.0000	
	TN	2551	2968	2921	2425	
	FP	486	69	116	612	
	FN	120	161	153	133	
	TP	49	8	16	36	
Manual	Sensibilidad	0.2899	0.0473	0.0947	0.2130	
	Especificidad	<b>0.8400</b>	<b>0.9773</b>	<b>0.9618</b>	0.7985	
	Precisión	0.0916	0.1039	0.1212	0.0556	
	F1	0.1392	0.0650	0.1063	0.0881	
	TN	1588	2371	2322	2432	
	FP	847	64	113	3	
	FN	45	106	107	124	
	TP	79	18	17	0	
	Sensibilidad	0.6371	<b>0.1452</b>	<b>0.1371</b>	0.0000	
	Especificidad	0.6522	0.9737	0.9536	<b>0.9988</b>	
Sin Selección	Precisión	0.0853	<b>0.2195</b>	<b>0.1308</b>	0.0000	
	F1	0.1505	<b>0.1748</b>	<b>0.1339</b>	0.0000	

- 50,100 y 20 neuronas.
- CN2 Inductor de reglas.
- Regla de ordenamiento= Ordenada.
- Algoritmo de cobertura: exclusivo.
- Medida de evaluación: entropía.
- Ancho de beam: 5.
- Cobertura mínima de la regla: 1.
- Longitud máxima de la regla: 5.

**Tabla 5.** Tabla de los resultados utilizando datos de meses con >5% de incendios y el target de ventana.

Datos Selección de Meses >5%, Target de ventana					
Método de selección de parámetros	Matriz de confusión/ Medidas de desempeño	Clasificador			
		Naive Bayes	Red Neuronal	CN2	SVM
Top 10	TN	2052	2559	2469	1919
	FP	721	214	304	854
	FN	188	324	334	222
	TP	231	95	85	197
	Sensibilidad	0.5513	0.2267	0.2029	0.4702
	Especificidad	0.7400	0.9228	0.8904	<b>0.6920</b>
	Precisión	<b>0.2426</b>	0.3074	0.2185	<b>0.1874</b>
	F1	<b>0.3370</b>	0.2610	0.2104	<b>0.2680</b>
	TN	1495	2138	2062	1418
	FP	761	118	194	838
PCA	FN	111	132	190	129
	TP	192	171	113	174
	Sensibilidad	<b>0.6337</b>	<b>0.5644</b>	<b>0.3729</b>	<b>0.5743</b>
	Especificidad	0.6627	<b>0.9477</b>	<b>0.9140</b>	0.6285
	Precisión	0.2015	<b>0.5917</b>	<b>0.3681</b>	0.1719
	F1	0.3057	<b>0.5777</b>	<b>0.3705</b>	0.2646
	TN	2120	2553	2516	1902
	FP	665	232	269	883
	FN	240	326	332	269
	TP	181	95	89	152
Manual	Sensibilidad	0.4299	0.2257	0.2114	0.3610
	Especificidad	<b>0.7612</b>	0.9167	0.9034	0.6829
	Precisión	0.2139	0.2905	0.2486	0.1469
	F1	0.2857	0.2540	0.2285	0.2088
	TN	1495	2138	2062	1418
	FP	761	118	194	838
	FN	111	132	190	129
	TP	192	171	113	174
	Sensibilidad	<b>0.6337</b>	<b>0.5644</b>	<b>0.3729</b>	<b>0.5743</b>
	Especificidad	0.6627	<b>0.9477</b>	<b>0.9140</b>	0.6285
Sin Selección	Precisión	0.2015	<b>0.5917</b>	<b>0.3681</b>	0.1719
	F1	0.3057	<b>0.5777</b>	<b>0.3705</b>	0.2646

- Máquina de Soporte Vectorial.
- Costo (C)= 1.
- Epsilon de regresión de pérdida: 0.1.
- Kernel: RBF.
- Tolerancia numérica: 0.0010.
- Límite de iteraciones: 100.

**Esquema de validación.** Se usó un esquema de validación cruzada estratificada con 5 pliegues.

**Medidas de desempeño seleccionadas** Se utilizaron las medidas de desempeño de: Sensibilidad, que el % de días con vulnerabilidad clasificados correctamente del total de vulnerables (indica la capacidad de identificar los días vulnerables dentro del total de días vulnerables); Precisión, que representa el % dentro de los clasificados con vulnerabilidad, los días que realmente son vulnerables acorde al target utilizado, entre más alto sea se evitarán falsas alarmas al cuerpo de bomberos; la Medida F1, que combina estas dos medidas de desempeño; y finalmente, como medida menos importante, se seleccionó la Especificidad, que indica el porcentaje de días clasificados como sin vulnerabilidad dentro del total de días sin vulnerabilidad.

### **5.3. Estudio comparativo**

Se obtuvieron las siguientes tablas, agrupadas por la selección de instancias. Para cada valor de Sensibilidad, Especificidad, Precisión y F1, se indica en **negritas** el valor más alto de cada clasificador por cada selección de instancias, en *cursiva* el mejor valor por cada selección de instancias, mientras que subrayado el mejor valor global.

### **5.4. Resultados generales**

Podemos observar que los resultados de los experimentos sin selección de atributos y con el uso de PCA son prácticamente los mismos.

La combinación de selección de instancias/atributos y clasificador con mejores resultados en la precisión y la medida F1 fue la red neuronal aplicada a los datos con selección de los meses con >5% de incendios y el target de ventana, detectando un total de 56% de los días vulnerables con una precisión del 59%; el clasificador con mejor resultado en la medida de Sensibilidad fue el clasificador Naive Bayes, con PCA/sin selección de atributos y sin selección de instancias, sin embargo, cuenta con una precisión de 0.0616, lo que implica un alto porcentaje de falsas alarmas.

## **6. Conclusiones y trabajo a futuro**

Uno de los factores negativos en los resultados fue el desbalance en el dataset, pues afecta directamente el desempeño de los clasificadores utilizados, así como el descarte prematuro de variables meteorológicas. Ante esto, se propone implementar maneras de equilibrar el dataset o aplicar algoritmos de selección y condensación de instancias únicamente a la clase mayoritaria.

Para la primera condensación de los datos (pasar de mediciones cada media hora a valores cada día), se propone agregar una división del día en dos, basado en la distribución de temperatura y humedad, día/noche y la integración del índice de vulnerabilidad del sistema difuso a las pruebas de clasificación.

Respecto al proceso de diseño de experimentos, se propone descartar los clasificadores con un mal desempeño general (SVM y CN2) y ampliar las pruebas con los clasificadores que dieron buenos resultados (Redes Neuronales, Naive Bayes).

Para los métodos de clasificación se propone probar otros algoritmos de clasificación, tales como redes neuronales tipo LSTM (con un método de aprendizaje

para datasets desbalanceados), sistemas neurodifusos u otros algoritmos más resilientes al desbalance de los datos.

La base de datos de incendios está probablemente sesgada, ya que el sistema de monitoreo actual en la REPSA es deficiente (generalmente las alarmas se dan por peatones que marcan a emergencias, suben un Twitter etiquetando al perfil de la reserva o algún miembro de la SEREPSA pasó en auto por las cercanías y logró vislumbrar el humo), es probable que haya habido incendios en la reserva sin que el equipo responsable se percatara de, y por lo tanto no se registrara.

Así mismo, los datos de la estación meteorológica están incompletos, desde una ausencia de datos por algunas horas hasta semanas enteras sin información y se desconoce el mantenimiento dado a la estación, o si hubo un cambio del equipo instalado. De la misma manera, la información disponible sobre los días en los que hubo incendios no indica la totalidad de los días en los que la reserva era vulnerable, ya que pudo haber días donde hubo una alta vulnerabilidad, pero no se inició un incendio ya que no hubo el factor humano (caótico) iniciador del fuego.

Dada la actual situación del monitoreo de incendios, podría implementarse el clasificador que dio mejores resultados (red neuronal entrenada con el target de ventana) en la reserva ecológica para que pueda dar alertas tempranas al cuerpo de bomberos y puedan aumentar la frecuencia de vigilancia de la reserva en caso de alerta de vulnerabilidad alta; sin embargo, la implementación en otras reservas naturales debe tomar muchas consideraciones dada la situación específica de la REPSA, tanto por sus altos niveles de interacción humana (y distribuida en ciclos relacionados con los semestres escolares), como las características específicas de su ecosistema nacido sobre piedra volcánica (con capacidades de filtrado de agua, retención de humedad y temperatura y relieve específicas), basado principalmente en matorral xerófilo y con un % considerable de especies invasoras flamables [8], que si bien lo hace único, también estas características limitan las posibilidades de implementar el mismo sistema en otras reservas (sería necesario una recalibración del clasificador).

## Referencias

1. Sakr, G. E., Elhajj, I. H., Mitri, G.: Efficient forest fire occurrence prediction for developing countries using two weather parameters. *Engineering Applications of Artificial Intelligence*, vol. 24, no. 5, pp. 888–894 (2011) doi: <https://doi.org/10.1016/j.engappai.2011.02.017>
2. Chang, Y., Zhu, Z., Bu, R., Chen, H., Feng, Y., Li, Y., Wang, Z.: Predicting fire occurrence patterns with logistic regression in Heilongjiang Province, China. *Landscape Ecology*, vol. 28, pp. 1989–2004 (2013) doi: 10.1007/s10980-013-9935-4
3. Alonso-Betanzos, A., Fontenla-Romero, O., Guijarro-Berdinas, B., Hernández Pereira, E., Andrade, M. I. P., Jiménez, E., Carballas, T.: An intelligent system for forest fire risk prediction and firefighting management in Galicia. *Expert systems with applications*, vol. 25, no. 4, pp. 545–554 (2003) doi: 10.1016/S0957-4174(03)00095-2
4. Sayad, Y. O., Mousannif, H., Al-Moatassime, H.: Predictive modeling of wildfires: A new dataset and machine learning approach. *Fire safety journal*, vol. 104, pp. 130-146 (2019) doi: 10.1016/j.firesaf.2019.01.006
5. Torres-Rojo, J. M.: Estudio de tendencias y perspectivas del sector forestal en América Latina al año 2020: informe nacional: México. 2nd Ed. México (2004)
6. Schwela, D. H., Goldammer, J. G., Morawska, L. H., Simpson, O.: Health guidelines for vegetation fire events: guideline document. pp. 219 (1999)

*Propuesta de sistema computacional para incendios forestales y clasificación de días ...*

7. CONAFOR - Gerencia de manejo del fuego: Programa de manejo del fuego, 2019. 1st Ed. CONAFOR, México (2019)
8. SEREPSA- La reserva ecológica del Pedregal de San Ángel: Atlas de riesgos, UNAM México (2012)
9. Clasificación de patrones: Métodos supervisados, Porta Zamorano, Jordi, Universidad Autónoma de Madrid <http://www.iula.upf.edu/materials/050418porta4.pdf>
10. Jolliffe, I. T.: Principal component analysis. 2nd Ed. Springer, New York – EUA (2002)
11. Flórez-López, R., Fernández-Fernández, J. M.: Las redes neuronales artificiales, fundamentos teóricos y aplicaciones prácticas. 2nd Ed. Netbiblo, España (2008)
12. Ceruto-Cordovés, T., Rosete-Suárez, A., Espín-Andrade, R.: Obtención de predicados difusos a partir de datos utilizando metaheurísticas. Revista Internacional de Investigación de Operaciones – RIIO, vol. 1, no. 1, pp. 29–37 (2010)



Electronic edition  
Available online: <http://www.rcs.cic.ipn.mx>



<http://rcs.cic.ipn.mx>



Centro de Investigación  
en Computación