



FONDO EDITORIAL

CONGRESO INTERNACIONAL DE INGENIERÍA DE SISTEMAS



UNIVERSIDAD
DE LIMA

DISEÑANDO EL PRESENTE Y EL FUTURO: INTELIGENCIA ARTIFICIAL PARA EL DESARROLLO SOSTENIBLE

ACTAS DEL VI CONGRESO INTERNACIONAL DE INGENIERÍA DE SISTEMAS

Congreso internacional de ingeniería de sistemas

Diseñando el presente y el futuro: inteligencia artificial para el desarrollo sostenible
Actas del VI Congreso Internacional de Ingeniería de Sistemas

FONDO EDITORIAL | CONGRESO INTERNACIONAL DE INGENIERÍA DE SISTEMAS



UNIVERSIDAD
DE LIMA

DISEÑANDO EL PRESENTE Y EL FUTURO: INTELIGENCIA ARTIFICIAL PARA EL DESARROLLO SOSTENIBLE

ACTAS DEL VI CONGRESO INTERNACIONAL DE INGENIERÍA DE SISTEMAS

Congreso Internacional de Ingeniería de Sistemas (6.º : 2023 : Lima, Perú)

Diseñando el presente y el futuro: Inteligencia artificial para el desarrollo sostenible. Actas del VI Congreso Internacional de Ingeniería de Sistemas / organizado por la Carrera de Ingeniería de Sistemas de la Universidad de Lima. Primera edición digital. Lima: Universidad de Lima, Fondo Editorial, 2024.

138 páginas: ilustraciones, diagramas, gráficos.

Texto en español e inglés.

Ponencias magistrales y ponencias del VI Congreso Internacional de Ingeniería de Sistemas (CIIS), denominado “Diseñando el presente y el futuro: Inteligencia artificial para el desarrollo sostenible”, el cual se realizó del 2 al 3 de noviembre del 2023.

Incluye referencias.

1. Ingeniería de sistemas – Congresos. 2. Inteligencia artificial -- Congresos. 3. Desarrollo sostenible – Congresos. I. Actas del VI Congreso Internacional de Ingeniería de Sistemas (6.º : 2023: Lima, Perú). II. Universidad de Lima. Fondo Editorial

005.1

C

6

ISBN 978-9972-45-642-8

Diseñando el presente y el futuro: inteligencia artifical para el desarrollo sostenible.

Actas del VI Congreso Internacional de Ingeniería de Sistemas 2023

Primera edición digital: junio, 2024

©

De esta edición:

Universidad de Lima

Fondo Editorial

Av. Javier Prado Este 4600,

Urb. Fundo Monterrico Chico, Lima 33

Apartado postal 852, Lima 100, Perú

Teléfono: 437-6767, anexo 30131

fondoeditorial@ulima.edu.pe

www.ulima.edu.pe

Diseño, edición y carátula: Fondo Editorial de la Universidad de Lima

Las Actas del Congreso Internacional de Ingeniería de Sistemas se publican bajo licencia Creative Commons Attribution 4.0 (CC BY 4.0)

ISBN 978-9972-45-642-8

ISSN 2810-806X (en línea)

Hecho el depósito legal en la Biblioteca Nacional del Perú n.º 2024-05807

COMITÉ ORGANIZADOR CIIS (2023)

PRESIDENTA DEL COMITÉ ORGANIZADOR:

- Dra. Nadia Rodríguez Rodríguez, Universidad de Lima, Perú

PRESIDENTE Y VICEPRESIDENTA DEL PROGRAMA:

- Mg. Franci Suni-Lopez, Universidad de Lima, Perú
- Dra. Nelly Condori Fernandez, Universidad Santiago de Compostela, España

COMITÉ CIENTÍFICO:

- Edwin Escobedo Cárdenas, Universidad de Lima, Perú
- Effie Lai-Chong Law, PhD, Durham University, England
- Dr. Guillermo Antonio Dávila Calle, Universidad de Lima, Perú
- Dr. Hernan Nina Hanco, Universidad de Lima, Perú
- Dr. Isaias Bianchi, Al-Farabi Kazakh National University, Kazakhstan
- Dr. Juan Gutiérrez Cárdenas, Universidad de Lima, Perú
- Dr. Manuel Castillo Cara, Universidad de Castilla-La Mancha, España
- Marco Antonio Sotelo Monge, PhD, Indra, España
- Michael Dorin, University of St. Thomas, Estados Unidos
- Ruth Maria Reategui Rojas, PhD, Universidad Técnica Particular de Loja, Ecuador

COMITÉ ORGANIZADOR LOCAL:

- Andrea Matuk Chijner, Universidad de Lima, Perú
- Carlos Torres Paredes, Universidad de Lima, Perú
- Hernán Quintana Cruz, Universidad de Lima, Perú
- Lourdes Ramírez Cerna, Universidad de Lima, Perú
- Pablo Rojas Jaen, Universidad de Lima, Perú
- Rocío del Pilar Checa Fernández, Universidad de Lima, Perú
- Rosario Guzmán Jiménez, Universidad de Lima, Perú

REVISORES CIENTÍFICOS:

- Carlos Alario, Universidad Carlos III de Madrid, España
- Hugo Alatrista, Pontificia Universidad Católica del Perú

- Miriam Amable, Universidad de Lima, Perú
- Dennis Barrios, Universidad Católica San Pablo, Perú
- César Beltrán, Pontificia Universidad Católica del Perú
- José Caballero, Universidad de Lima, Perú
- Guillermo Cámaras, Universidade Federal de Ouro Preto, Brasil
- Daniel Cárdenas, Universidad de Lima, Perú
- Patricia Castillo, Universidad Católica San Pablo, Perú
- Raul Díaz Parra, Universidad de Lima, Perú
- Matheus Fernando-Moro, Universidade Federal de Santa Catarina, Brasil
- Shruti Goel, Navis, Estados Unidos
- Juan Carlos Gutiérrez-Cáceres, Universidad Nacional de San Agustín de Arequipa, Perú
- Cristian López, Universidad de Ingeniería y Tecnología, Perú
- Juan Antonio Lossio-Ventura, National Institutes of Health, Estados Unidos
- Markus Mock, Universidad de Ciencias Aplicadas de Landshut, Alemania
- Javier Montoya, Escuela Politécnica Federal de Zúrich, Suiza
- Carlos Mugruza, Universidad Nacional Tecnológica de Lima Sur, Perú
- Denisse Muñante, École Nationale Supérieure d’Informatique pour l’Industrie et l’Entreprise, Francia
- Paul Quiróz, Universidad de Lima, Perú
- Óscar Ramos, Universidad de Lima, Perú
- Alvaro Talavera, Universidad del Pacífico, Perú
- Regina Ticona, Universidad Católica San Pablo, Perú
- Carlos Torres Paredes, Universidad de Lima, Perú
- Yván Túpac, Universidad Católica San Pablo, Perú
- José Valdivia, Universidad de Lima, Perú
- Elizabeth Vidal, Universidad Nacional de San Agustín de Arequipa, Perú
- Edgar Sarmiento, Universidad Nacional de San Agustín de Arequipa, Perú
- Edward Hinojosa, Universidad Nacional de San Agustín de Arequipa

Índice

PRESENTACIÓN	11
<i>Nadia Rodríguez Rodríguez</i>	
PONENCIAS MAGISTRALES	15
Beyond Boundaries: Generative AI for Sustainable Academic Advancements	17
<i>Mushtaq Bilal</i>	
Sostenibilidad y sistemas basados en inteligencia artificial	21
<i>Nelly Condori-Fernández</i>	
PONENCIAS	27
Planificación de una reestructuración sistémica de la unidad médica educativa de la UNCAUS	29
<i>Paola Budan, Patricia Zachman, Pablo Campestrini, Ruben Ernesto Andreu, Emmanuel Chavez</i>	
Towards Energy Sustainability: A Literature Review of Green Software Development	43
<i>Angelo Rodrigo Taco Jiménez</i>	
Heurísticas en la evaluación de la usabilidad de aplicaciones móviles: conceptos y aplicación	59
<i>Izabella Barros, Filipe de Assis Santos, Sharon Candini, Marcos Dias de Paula</i>	
Exploring Stroke Risk Identification by Machine Learning: A Systematic Review	69
<i>Lelis Raquel Atencia Mondragon, Melany Cristina Huarcaya Carbajal, Rosario Guzmán Jiménez</i>	

Predicción de la estabilidad de voltaje en redes eléctricas inteligentes <i>Victor Gil-Vera</i>	83
Neural Network Energy Control of Combustion Engines for Automotive Software Applications <i>Marcos Henrique Carvalho Silva, André Vinícius Oliveira Maggio, Armando Antônio Maria Laganá, João Francisco Justo Filho, Bruno Silva Pereira, Demerson Moscardini</i>	99
Diseño de un aplicativo que reconozca medicamentos a través de una cámara mediante inteligencia artificial “AIPills” <i>Carolina Aliaga, Jesús Domínguez, Iris Liña, Javier Acuña</i>	117
DATOS DE LOS AUTORES	129

Presentación

doi: <https://doi.org/10.26439/ciis2023.7075>

La Carrera de Ingeniería de Sistemas de la Universidad de Lima se complace en presentar las actas de la sexta edición del Congreso Internacional de Ingeniería de Sistemas (CIIS 2023), cuyo título fue “Diseñando el presente y el futuro: inteligencia artificial para el desarrollo sostenible”. Consideramos que dicha temática es importante, teniendo en cuenta el contexto global marcado por la escasez de recursos naturales, crisis logísticas, problemas ambientales, crisis sanitarias y disruptivas tecnológicas. La inteligencia artificial se presenta como una oportunidad excepcional para abordar barreras al desarrollo sostenible, tanto a nivel global como local.

Durante este evento, mantuvimos nuestra tradición de destacadas ponencias magistrales y presentaciones de artículos científicos, a través de las cuales expertos de clase mundial compararon sus conocimientos y experiencias. En ese sentido, destacamos las ponencias magistrales de Mushtaq Bilal, investigador postdoctoral en la Universidad del Sur de Dinamarca, quien se enfocó en el uso de la inteligencia artificial generativa para avanzar en la educación superior de manera sostenible. Por otro lado, Marvin Lopez, de la Universidad de California en Los Ángeles, Estados Unidos, compartió una ponencia titulada “AI and a Sustainable World” (“Inteligencia artificial y un mundo sostenible”), en la que destacó la importancia de la inteligencia artificial en la sostenibilidad, especialmente en temas de diversidad e inclusión. También tuvimos la participación de Francisco Escudero, egresado de la Facultad de Ingeniería Industrial de la Universidad de Lima, Perú, líder de la empresa Ernst & Young, quien compartió su experiencia en la ponencia titulada “Estudios sobre el efecto del uso de la inteligencia artificial en la

sostenibilidad del desarrollo de la empresa peruana”. Otra ponencia magistral estuvo a cargo de la doctora Nelly Condori-Fernández, profesora asistente en la Universidad de Santiago de Compostela, en España, e investigadora asociada en la Vrije Universiteit Amsterdam, Países Bajos, quien presentó su ponencia “Sustainability and Artificial Intelligent Systems” (“Sostenibilidad y sistemas de inteligencia artificial”), en la que destacó la sostenibilidad del *software* y la adaptación de servicios mediante algoritmos de inteligencia artificial. Finalmente, María Isabel Limaylla, máster en Ciencias de la Computación y candidata a doctora en la Universidad de La Coruña, España, compartió su enfoque sobre la optimización del proceso de ingeniería de *software*, utilizando técnicas de aprendizaje automático, en su ponencia titulada “Optimizando la clasificación de requerimientos de *software* mediante *machine learning*”¹.

Por otro lado, destacamos las ponencias de artículos científicos que fueron seleccionados después de un proceso riguroso de revisión por pares ciegos. Las contribuciones seleccionadas son de autores de Argentina, Perú, Brasil y Colombia. En ese sentido, quisieramos resaltar estas valiosas contribuciones como la realizada por Paola Budán, Patricia Zachman, Pablo Campestrini, Rubén Ernesto Andreu y Emmanuel Chávez, investigadores de la Universidad Nacional del Chaco Austral, Argentina, quienes presentaron una reestructuración sistemática de la unidad médica educativa de su universidad, una propuesta de modernización de esta institución. La presentación del autor Angelo Taco de la Universidad de Lima, Perú, exploró los avances más recientes en el campo del *software* verde y su impacto en la eficiencia del consumo de energía. También, Izabella Barros, Filipe de Assis Santos, Sharon Candini y Marcos Dias de Paula, todos ellos del Centro Universitário Alves Faria – UNIALFA, Brasil, presentaron su análisis de heurísticas y principios que se pueden aplicar para evaluar y mejorar la usabilidad de las interfaces. Asimismo, Lelis Raquel Atencia Mondragón, Melany Cristina Huarcaya Carbajal y Rosario Guzmán Jiménez, investigadoras de la Universidad de Lima, Perú, realizaron una revisión sistemática en las bases de datos Web of Science y Scopus para sistematizar los resultados de estudios de identificación del riesgo de accidentes cerebrovasculares y su relación con el *machine learning*. En su contribución, Víctor Gil-Vera de la Universidad Católica Luis Amigó, Colombia, empleó *deep learning* para predecir la estabilidad de las redes eléctricas inteligentes. Por su parte, Marcos Henrique Carvalho Silva, André Vinícius Oliveira Maggio, Armando Antônio Maria Laganá, João Francisco Justo Filho, Bruno Silva Pereira y Demerson Moscardini, todos ellos investigadores de la Universidade de São Paulo, Brasil, desarrollaron una arquitectura de red neuronal de dos capas para el control de la generación de energía en un motor de combustión interna. Finalmente, Carolina Aliaga, Jesús Domínguez, Iris Liña y Javier Acuña, todos ellos de la Universidad Nacional de Ingeniería, Perú, realizaron una propuesta de aplicación móvil de reconocimiento de pastillas en tiempo real para ayudar a personas con visión reducida.

1 Las exposiciones de los siguientes ponentes magistrales solo están disponibles en los videos del evento: Marvin López, Francisco Escudero y María Isabel Limaylla. Siga el vínculo en el nombre de cada uno para verlos.

Queremos expresar nuestra profunda gratitud y reconocimiento a todos los miembros del comité organizador por su incansable labor en el desarrollo del congreso. También, extendemos nuestro agradecimiento a los revisores, por brindarnos la oportunidad de enriquecer la calidad de los trabajos de investigación presentados en la conferencia. Por último, queremos agradecer enormemente a todos los investigadores que nos enviaron sus trabajos, los cuales destacaron por su impresionante potencia y calidad.

Dra. Nadia Katherine Rodríguez Rodríguez

Presidenta del comité organizador
del Congreso Internacional de Ingeniería de Sistemas
CIIS 2023

PONENCIAS

MAGISTRALES

Beyond Boundaries: Generative AI for Sustainable Academic Advancements

Mushtaq Bilal
mushtaq@sdu.dk
University of Southern Denmark

doi: <https://doi.org/10.26439/ciis2023.7076>

ABSTRACT. Since its launch in November 2022, Open AI's chatbot Generative Pre-trained Transformer, commonly known as ChatGPT, has become one of the most popular generative AI applications in the world (OpenIA, n. d.). Academics across the world are concerned about how ChatGPT is dramatically changing the pedagogical and research landscape. In this paper, I discuss some of the best practices for using ChatGPT for academic purposes.

KEYWORDS: ChatGPT, OpenAI, generative AI

MÁS ALLÁ DE LAS FRONTERAS: INTELIGENCIAS ARTIFICIALES GENERATIVAS PARA EL AVANCE ACADÉMICO SOSTENIBLE

RESUMEN. Desde que fue lanzado en noviembre del 2022, el chatbot transformador generativo preentrenado (generative pre-trained transformer, en inglés) de Open IA, más conocido como ChatGPT, se ha convertido en una de las aplicaciones de inteligencia artificial más populares del mundo (OpenIA, s. f.). Académicos a lo largo y ancho del mundo han expresado su preocupación acerca de cómo ChatGPT está transformando dramáticamente el panorama pedagógico y de la investigación. En este artículo discuto algunas de las mejores prácticas para usar ChatGPT con propósitos académicos.

PALABRAS CLAVE: ChatGPT, OpenAI, inteligencias artificiales generativas

INTRODUCTION

I have been writing about how to use AI apps for academic purposes for more than a year now. Below are the six points that I think we need to understand for using AI apps smartly.

1. USE AI FOR STRUCTURE AND NOT FOR CONTENT

When it comes to using AI apps for academic writing, understanding the difference between structure and content is crucial. It is a bit tricky to understand this difference because structure and content are intricately intertwined.

Content cannot exist without a structure, and we will have no structure if we have no content. We always have a lot of content based on the research that we are doing. But that content does not mean much if we do not structure it in the form of a research paper or a monograph.

Large language models like ChatGPT are trained on huge amounts of human-generated text. These models have a very good understanding of how we communicate, especially the way we structure our communication. But since these apps use a predictive model, the content they produce is mostly predictable. Predictable content, for our purposes, is of little use. Predictable structure, on the other hand, is very useful.

We have to learn to use generative AI to structure and not to generate content. For example, you can ask ChatGPT to give you an outline for a journal article, but you cannot ask it to write the article for you.

2. OUTSOURCE ACADEMIC LABOR TO AI BUT NOT THINKING

Imagine you have to look up a few resources related to your research project. You can go to the library and browse the physical catalog. Suppose you find a few relevant papers. You go to the shelf to pick up physical copies of the relevant journals.

This whole process, as you can imagine, is quite laborious. You could have easily done all this on an app like Google Scholar or PubMed.

AI-powered apps are to Google Scholar what Google Scholar is to a physical brick-and-mortar library. I will give you the example of an AI-powered app called Scite. Suppose you come across a paper published by two Nobel laureates working in a prestigious lab. Because of their Nobel prizes and their stature, most of us would think that they have presented irrefutable evidence. Now imagine you want to find out if there is any evidence that contrasts the claims of these Nobel prize winners. You will have to read a lot of papers to find that out. Google Scholar will not be much help.

But the Scite app will tell you in a matter of seconds the contrasting and supporting evidence to the claims made by those Nobel laureates (AI for Research, n. d.).

In this case, we are using AI to outsource our labor but not our thinking. We cannot outsource our thinking because of the point I made earlier about predictable content.

3. TREAT AI AS A RESEARCH ASSISTANT, NOT A SUPERVISOR

Imagine you hire a research assistant and you assign them a task. They complete the assigned task. Will you check how your assistant did or will you simply take what they did and put it in your journal article or research report? Chances are you will check it and give them feedback.

Think of AI apps as your research assistants and not your supervisors. I try to imagine AI apps as smart, willing, eager-to-learn research assistants. They can do certain tasks very efficiently, but I still have to check their output.

4. DO NOT OVER-RELY ON AI AND DO NOTFORGET TO USE YOUR COMMON SENSE

It hardly needs to be said that we should use our common sense, but when it comes to AI, you would be surprised by the number of people who absolutely refuse to use their common sense.

Let me give you an example. On the ChatGPT homepage, it is clearly written that it “may occasionally generate incorrect information” (ChatGPT, n. d.) In their naivete, the makers of ChatGPT assumed that anyone using it will read this.

Many people did not bother with it. Among them was a New York lawyer who used ChatGPT to supplement his legal research (Lawyer Who Used ChatGPT, 2023). ChatGPT gave him fake citations to cases that did not even exist. He did not stop there. He asked ChatGPT to give him case reports to those fake citations. ChatGPT complied and generated fake reports to those fake citations.

The lawyer took this bundle of fakery and submitted it in a federal court. As for the judge to whom this fakery was submitted, let’s just say that he was not happy.

5. AI IS NEITHER THE FANTASIZED UTOPIA NOR THE FEARED DYSTOPIA

When it comes to AI, a lot of people tend to think in terms of extremes. They think AI is going to either solve all their problems (like you press a button and AI writes you a research paper) or take over the world and we will be ruled by robots.

Neither of these positions are helpful. Instead of thinking in these extremes, we should try to understand them as what they actually are.

6. ENGAGE WITH AI APPS

This brings me to my final point, which is that we should engage with these apps. AI apps are here to stay and if we do not engage with them, we will not be able to equip our students with the latest tools that they will need in the marketplace.

Finally, we should try to combine artificial intelligence with human intelligence and not with human stupidity.

REFERENCES

- AI for Research. (n. d.) Scite.Ai. Accessed 4 November 2023. <https://scite.ai>.
- ChatGPT. (n. d.) OpenAI. Accessed 4 November 2023. <https://openai.com/chatgpt>.
- Lawyer Who Used ChatGPT Faces Penalty for Made Up Citations (2023, November 4). *The New York Times*. Accessed 4 November 2023. <https://www.nytimes.com/2023/06/08/nyregion/lawyer-chatgpt-sanctions.html>.

Sostenibilidad y sistemas basados en inteligencia artificial

Nelly Condori-Fernández

n.condori.fernandez@usc.es

<https://orcid.org/0000-0002-1044-3871>

Universidad Santiago de Compostela, España

doi: <https://doi.org/10.26439/ciis2023.7077>

RESUMEN. La inteligencia artificial (IA) ha evolucionado con avances como los lenguajes de alto nivel de programación (Python, por ejemplo) y las redes neuronales profundas o redes de aprendizaje profundo. Estos avances han impulsado el auge de la IA, con desarrollos como XAI, Small Data e ImageNet. La IA generativa está cambiando la economía y se espera que tenga un impacto significativo en áreas como la creación de contenidos, el desarrollo de *software* y el *marketing*. La Comisión Europea propone una regulación de la IA basada en un enfoque de riesgo, con diferentes niveles de riesgo y requisitos según la categoría de IA. La sostenibilidad del *software* es multidimensional, pues abarca aspectos técnicos, económicos, ambientales y sociales. La explicabilidad y transparencia en los modelos de IA son cruciales para garantizar la responsabilidad y la confianza en su uso. La integración de sistemas de IA con sistemas y procesos heredados implica consideraciones técnicas y económicas; puede generar beneficios, como la optimización de procesos, pero también requiere inversiones significativas.

PALABRAS CLAVE: inteligencia artificial, sostenibilidad del *software*, sistemas de IA.

SUSTAINABILITY AND ARTIFICIAL INTELLIGENT-BASED SYSTEMS

ABSTRACT. Artificial intelligence (AI) has evolved with advancements such as deep learning, Python, and deep neural networks. These advancements have driven the rise of AI, with developments like XAI, Small Data, and ImageNet. Generative AI is changing the economy and is expected to have a significant impact in areas such as content creation, software development, and marketing. The European Commission proposes AI regulation based on a risk approach, with different levels of risk and requirements according to the AI category. Software sustainability is

multidimensional, covering technical, economic, environmental, and social aspects. Explainability and transparency in AI models are crucial to ensure accountability and trust in their use. Integrating AI systems with legacy systems and processes involves technical and economic considerations and can generate benefits such as process optimization but also requires significant investments.

KEYWORDS: artificial intelligence, software sustainability, AI systems.

1. INTRODUCCIÓN

La inteligencia artificial (IA) ha evolucionado a través de diferentes etapas, desde la IA tradicional hasta la moderna IA. La tradicional incluía sistemas expertos, redes neuronales poco profundas (shallow NN), lenguaje Prolog y lógica difusa. Los avances en ciencia de datos tuvieron un hito con el desarrollo de Deep Blue, seguido por la moderna IA con GPU (*graphics processing unit*), aprendizaje profundo (*deep learning*), *machine learning* (ML) en Python (Raschka et al., 2020) y redes neuronales profundas. Estos avances han impulsado el auge de la IA, con desarrollos como IA aplicable (Xu et al., 2019), Small Data, ImageNet, sistemas inteligentes verdes (Martínez-Fernández et al., 2023), aprendizaje por refuerzo (Rolf et al., 2023), etcétera.

La transición de la unidad central de procesamiento (CPU) a la unidad de procesamiento gráfico (GPU) ha acelerado este proceso, permitiendo avances en IA generativa basada en modelos base de *transformers* y GAN (*generative adversarial network*), que ahora forman parte de la sociedad. Este rápido cambio ha hecho que, aunque estas tecnologías estaban presentes, ahora se conviertan en una realidad y sean más visibles para otras disciplinas, lo que a su vez plantea nuevos retos.

La inteligencia artificial generativa (GAI, por sus siglas en inglés), al mejorar su tecnología está cambiando la economía y eso se traducirá en beneficios como, por ejemplo, una mayor productividad. Se espera que las empresas utilicen cada vez más la GAI para la creación de contenidos, el desarrollo de *software*, el *marketing*, las ventas y el servicio al cliente. Estas capacidades tendrán un impacto en diversas industrias y beneficiarán tanto a los consumidores como a las empresas (Bank of America Corporation, 2023).

La industria de la inteligencia artificial está en constante evolución. El AI 100 de CB Insights es una lista anual que reconoce a las cien empresas privadas de IA más prometedoras a nivel mundial. El año 2023, los ganadores fueron empresas enfocadas en áreas que dan soporte al desarrollo de sistemas y aplicaciones inteligentes, así como también a infraestructuras de IA generativa, al análisis de emociones y al desarrollo de humanoides de propósito general, entre otros avances innovadores en el campo de la inteligencia artificial (CB Insights, 2023).

Los sistemas de inteligencia artificial abarcan una amplia gama de áreas. El *core* de la IA generativa se aplica en campos diversos: turismo, finanzas, navegación, robótica, salud, videojuegos, domótica, redes sociales, agricultura, *marketing*, compras en línea, comercio electrónico y educación. La sostenibilidad desde el punto de vista de la ingeniería de *software* (Condori-Fernández & Lago, 2018), el rol de los ingenieros de requisitos (Franch et al., 2023) y su regulación (Clarke, 2019), son aspectos clave en el desarrollo e implementación de estos sistemas. También lo es el establecimiento de los alcances de la IA en estas áreas. Por ejemplo, en el caso de los robots domésticos para adultos mayores que viven solos o de los robots sociales, es crucial establecer límites claros para garantizar su uso ético y seguro.

La Comisión Europea propuso un marco de regulación para la IA en la Unión Europea (UE) en abril de 2021, basado en un enfoque de riesgo. El proyecto de ley busca definir y clasificar los sistemas de IA según su nivel de riesgo: algunos serían prohibidos por riesgos inaceptables, otros —considerados de alto riesgo— estarían sujetos a requisitos y obligaciones, y aquellos con riesgo limitado tendrían pocas obligaciones. El Consejo de la UE y el Parlamento europeo están negociando las últimas etapas de la legislación, que incluye enmiendas para ampliar la lista de sistemas de IA prohibidos y para establecer obligaciones, tanto para la IA de propósito general como para los modelos de lenguajes como ChatGPT. El proyecto de ley prohíbe prácticas de IA que representen un riesgo inaceptable, como el uso de técnicas subliminales manipulativas y la explotación de grupos vulnerables. También restringe el uso de la identificación biométrica en tiempo real en espacios públicos, excepto en casos limitados (European Parliamentary Research Service, 2023).

Sin embargo, aunque existe este esfuerzo por regular la IA, falta consenso para definir lo que es un sistema inteligente. La Comisión Europea propone una definición en la legislación de la UE, que se basa en una previamente utilizada por la Organización para la Cooperación y el Desarrollo Económicos. Según el artículo 3(1) del proyecto de ley, un sistema inteligente (o basado en IA) es un *software* desarrollado con técnicas y enfoques específicos que le permiten generar resultados (como contenido, predicciones, recomendaciones o decisiones) que influyen en los entornos con los que interactúa. Todo ello con el fin de alcanzar objetivos definidos por humanos (OECD, 2023).

Por consiguiente, los requisitos para los sistemas de inteligencia artificial engloban aspectos fundamentales que deben tenerse en cuenta durante su desarrollo (Franch et al., 2023). Esto incluye requisitos relacionados con los datos, como la necesidad de que sean accesibles, interoperables, reutilizables y sostenibles, así como con la confiabilidad del sistema, que comprende, entre otras, la necesidad de contar con agencia y supervisión humana.

Así mismo, la sostenibilidad del *software*, también considerada como un requisito de calidad (Condori-Fernández & Lago, 2018), es un concepto multidimensional que abarca aspectos técnicos, económicos, ambientales y sociales. En términos técnicos, implica garantizar la seguridad, la robustez y una adecuada gobernanza de datos. Desde un punto de vista económico, se relaciona con la privacidad y la seguridad. En el ámbito ambiental, busca fomentar la reutilización de datos para reducir el impacto en el medio ambiente. En cuanto al aspecto social, la sostenibilidad del *software* se vincula con la seguridad, el bienestar y la transparencia.

El desafío radica en cómo integrar estas dimensiones de manera efectiva en el desarrollo de *software*, para garantizar que los sistemas de IA cumplan con estándares éticos, transparentes y respetuosos de la privacidad, así como para asegurar que el *software* sea sostenible en el tiempo y contribuya positivamente en diversos aspectos de la sociedad.

Sin embargo, debido al continuo cambio de las tecnologías de desarrollo, los modelos de sostenibilidad para sistemas inteligentes necesitan ser operacionales y flexibles. Por ejemplo, la explicabilidad y la transparencia en los modelos de inteligencia artificial son aspectos cruciales, especialmente en aplicaciones críticas como la salud y las finanzas. Los modelos de IA suelen ser complejos y difíciles de interpretar, lo que dificulta comprender el razonamiento detrás de sus decisiones. En este contexto, la transparencia de los sistemas de IA es fundamental para garantizar la responsabilidad y la confianza en su uso. Evaluar la interpretabilidad de los modelos de IA se vuelve prioritario para abordar el desafío de la explicabilidad y la transparencia, y para asegurar que las decisiones tomadas por estos sistemas sean comprensibles y puedan ser justificadas de manera clara y ética.

La integración de sistemas de inteligencia artificial con sistemas y procesos heredados es otro aspecto crucial que involucra consideraciones tanto técnicas como económicas. Desde un punto de vista técnico, esta integración debe asegurar la compatibilidad y la interoperabilidad entre los sistemas existentes y las nuevas soluciones de IA. Esto puede requerir la adaptación de interfaces, la gestión de datos y la implementación de estándares de seguridad. En el ámbito económico, la integración eficiente de la IA con los sistemas existentes puede generar beneficios como la optimización de procesos, la reducción de costos operativos y la mejora en la toma de decisiones. Sin embargo, también puede implicar inversiones significativas en infraestructura y capacitación de personal. La integración exitosa de la IA con los sistemas existentes requiere un enfoque estratégico que considere los aspectos técnicos y los económicos, para así maximizar su impacto y beneficios.

REFERENCIAS

- Bank of America Corporation (2023). *Artificial intelligence: a real game changer*. <https://business.bofa.com/en-us/content/economic-impact-of-ai.html>
- CB Insights (2023). *AI 100: The most promising artificial intelligence startups of 2023*. <https://www.cbinsights.com/research/artificial-intelligence-top-startups-2023/>
- Clarke, R. (2019). Regulatory alternatives for AI. *Computer Law & Security Review*, 35(4), 398-409. <https://doi.org/10.1016/j.clsr.2019.04.008>
- Condori-Fernández, N. & Lago, P. (2018). Characterizing the contribution of quality requirements to software sustainability. *Journal of Systems and Software*, 137, 289-305. <https://doi.org/10.1016/j.jss.2017.12.005>
- European Parliamentary Research Service (2023). *Artificial intelligence act*. [https://www.europarl.europa.eu/RegData/etudes/BRIE/2021/698792/EPRS_BRI\(2021\)698792_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/BRIE/2021/698792/EPRS_BRI(2021)698792_EN.pdf)

- Franch, X., Jedlitschka, A., & Martínez-Fernández, S. (2023). A requirements engineering perspective to AI-based systems development: a vision paper. En A. Ferrari & B. Penzenstadler (Eds.), *Requirements engineering: foundation for software quality* (pp. 223-232). Springer. https://doi.org/10.1007/978-3-031-29786-1_15
- Martínez-Fernández, S., Franch, X., & Durán, F. (2023). Towards green AI-based software systems: an architecture-centric approach (GAISSA). En *49th Euromicro Conference on Software Engineering and Advanced Applications - SEAA* (pp. 432-439). <https://doi.org/10.1109/SEAA60479.2023.00071>
- OECD. (2023). Recommendation of the Council on artificial intelligence. *OECD Legal Instruments*: <https://legalinstruments.oecd.org/en/instruments/OECD-LEGAL-0449#mainText>
- Raschka, S., Patterson, J. & Nolet, C. (2020). Machine learning in Python: main developments and technology trends in data science, machine learning, and artificial intelligence. *Information*, 11(4), 193. <https://doi.org/10.3390/info11040193>
- Rolf, B., Jackson, I., Müller, M., Lang, S., Reggelin, T. & Ivanov, D. (2023). A review on reinforcement learning algorithms and applications in supply chain management. *International Journal of Production Research*, 61(20), 7151-7179. DOI: 10.1080/00207543.2022.2140221
- Xu, F., Uszkoreit, H., Du, Y., Fan, W., Zhao, D., & Zhu, J. (2019). Explainable AI: a brief survey on history, research areas, approaches and challenges. En J. Tang, M.Y. Kan, D. Zhao, S. Li & H. Zan (Eds.), *Natural language processing and chinese computing* (pp. 563-574). Springer. https://doi.org/10.1007/978-3-030-32236-6_51

PONENCIAS

Planificación de una reestructuración sistémica de la unidad médica educativa de la Universidad Nacional del Chaco Austral - UNCAUS

Paola Budan

pbudan1@gmail.com

Universidad Nacional del Chaco Austral, Argentina

Patricia Zachman

ppz@uncaus.edu.ar

Universidad Nacional del Chaco Austral, Argentina

Pablo Campestrini

pablomanuelcampestrini@gmail.com

Universidad Nacional del Chaco Austral, Argentina

Ruben Ernesto Andreu

rubenandreu@uncaus.edu.ar

Universidad Nacional del Chaco Austral, Argentina

Emmanuel Chávez

emmaignacio.chavez@gmail.com

Universidad Nacional del Chaco Austral, Argentina

Recibido: 24 de junio del 2023 / Aceptado: 13 septiembre del 2023

doi: <https://doi.org/10.26439/ciis2023.7078>

RESUMEN. En este artículo se presenta un proyecto para la reestructuración sistémica de la unidad médica educativa dependiente de la Universidad Nacional del Chaco Austral, en Argentina. Esta unidad médica dispone de una variedad de datos sobre sus pacientes, que actualmente no se encuentran automatizados en una historia clínica por paciente. Esto dificulta obtener información con alto valor agregado para la toma de decisiones a partir de los mencionados historiales, como también el desarrollo de herramientas para el entrenamiento de los médicos en formación de la Universidad. Por ello, haciendo uso de técnicas y herramientas sistémicas, se planifican cambios tendientes a transformar los datos en conocimiento estructurado. Para conseguirlo, se prevé idear innovaciones que incorporen herramientas informáticas en general, como aquellas basadas en inteligencia artificial (IA), orientadas a la representación y manipulación del conocimiento, con el objetivo de crear modelos lo suficientemente potentes para estudiar situaciones de la vida real. Asimismo, para que la reestructuración sea sistémica, se idean mecanismos para que los actuales empleados acepten los cambios propuestos sin sentirse subestimados.

PALABRAS CLAVE: reestructuración / transformaciones sistémicas / herramientas de entrenamiento

PLANNING A SYSTEMIC RESTRUCTURING OF THE UNCAUS MEDICAL EDUCATION UNIT

ABSTRACT. In this article, we present a project to achieve the systemic restructuring of the Medical Educational Unit, dependent on the National University of Chaco Austral, Argentina. This Medical Unit has a variety of data about its patients, which is currently not automated in a patient's Medical History. Because of that, it is difficult to obtain information with high added value for decision-making based on these records, as well as the development of tools for training medical students at the University. Using systemic techniques and tools, we planned changes to transform the data into structured knowledge. We are considering innovations through the incorporation of computer tools, such as databases and others based on Artificial Intelligence (AI), with the aim of representation and manipulation of knowledge to create models powerful enough to study real-life situations. Likewise, for the restructuring to be systemic, mechanisms are devised so that current employees accept the proposed changes without feeling underestimated.

KEYWORDS: restructuring / systemic transformations / training tools.

1. INTRODUCCIÓN

La unidad médica educativa (UME) perteneciente a la Universidad Nacional del Chaco Austral (UNCAUS), Argentina, es un centro de salud que atiende a la población del interior de la provincia del Chaco. Aproximadamente 1500 pacientes acuden allí semanalmente, no solo para ser atendidos, sino también por los diferentes servicios que esta unidad brinda. Actualmente, la variedad de datos sobre la casuística y los procedimientos que se realizan en la UME, se mantienen, en su mayoría, en archivos de papel, mientras que los circuitos para el registro de la información son poco estructurados. En consecuencia, no se lleva a cabo un proceso de clasificación de la información que permita obtener conocimiento relevante para la salud pública. Por ejemplo, la UME no cuenta con un sistema automatizado de historias clínicas por paciente, lo que redunda en poca información de valor agregado que sirva de soporte a la toma de decisiones. Ante preguntas como: ¿Cuántos pacientes tuvieron neumonía bilateral en el último año?, ¿qué tratamientos se prescriben con mayor frecuencia?, ¿cuál fue el promedio de días de recuperación de un paciente?, por citar algunos ejemplos, resulta poco factible obtener respuestas correctas en tiempo y forma. Se entiende que disponer de información de este tipo es útil no solo para realizar un mapa de las patologías que mayormente afectan a la población que concurre a la UME, sino también para tomar decisiones estratégicas con respecto a otros servicios, como por ejemplo el de farmacia. La importancia de tener este tipo de registros y utilizarlos para tomar decisiones acertadas, y también como herramientas educativas para los estudiantes de Medicina, aparece en numerosas investigaciones actuales (Fu et al., 2022; Harahap et al., 2022; Lokmic-Tomkins et al., 2023; Medlock et al., 2023).

Cumplir con el propósito de reestructurar la información con la que se cuenta y obtener datos de utilidad con fines administrativos y de enseñanza, implica reestructurar también los circuitos de trabajo existentes y encontrar un mecanismo correcto para la representación y la manipulación de la información. A su vez, se considera la posibilidad de emplear técnicas de inteligencia artificial (IA) bajo un marco de uso ético y moral, especialmente para obtener sistemas de entrenamiento para los profesionales médicos en formación. Así es que en este trabajo se presenta un proyecto de reestructuración sistémica para la UME, que abarca aspectos organizacionales y técnicos. Se tomarán en cuenta algunas etapas de la metodología de los sistemas blandos (MSB) (Checkland & Haynes, 1994; Kish et al., 2016; Torlak & Müteldili, 2014), así como también el rediseño de una organización que soporte los cambios propuestos, atendiendo principalmente a su idiosincrasia y valores (Schvarstein, 1998).

Desde el punto de vista técnico, se busca incorporar IA para estructurar el conocimiento existente, para crear pautas de razonamiento en base a un análisis del conocimiento ya estructurado y para sentar las bases para crear una estructura de conocimiento y un mecanismo de razonamiento que permitan obtener respuestas justificadas a las consultas que se hagan sobre la casuística de la UME¹.

1 Los objetivos fueron fijados en el marco de un proyecto de investigación de la UNCAUS denominado “Diseño y desarrollo de una metodología para estructurar el conocimiento y detectar patrones de razonamiento en el dominio de la unidad médica educativa (UME)”.

Este trabajo se organiza de la siguiente manera: en primera instancia se presenta la metodología a seguir para la reestructuración; seguidamente, se presenta la organización bajo estudio y se detalla la problemática, tanto en forma no estructurada como estructurada; luego se describen las transformaciones previstas para la organización. Finalmente, nos referiremos a los avances del proyecto, a los resultados previstos en un trabajo futuro y esbozaremos conclusiones.

2. METODOLOGÍA

Para comprender el alcance de la situación actual, los cambios que se requieren y aproximarnos a cómo esos cambios pueden afectar a la UME, se trabajará con algunas etapas de la conocida MSB (Checkland & Haynes, 1994; Kish et al., 2016 ; Torlak & Muceldili, 2014), aunque adaptadas a las necesidades de nuestro proyecto. Se sabe que la MSB es una metodología flexible, en la cual la forma de idear los cambios para solucionar un problema tiende a disminuir las tensiones en su posterior implementación (Reynolds & Holwell, 2010). Resulta de especial utilidad en un contexto, como el nuestro, en el que los procedimientos se vienen llevando a cabo de manera rutinaria hace muchos años. Y, principalmente, en el que cualquier transformación que se realice tendrá un impacto en los seres humanos, tanto en quienes trabajan en la UME como en quienes requieren asistencia médica. A lo largo del artículo se irán describiendo los pasos seleccionados de la MSB, a medida que se documenta su aplicación. En líneas generales, se desarrollarán:

- La definición no estructurada del problema, por medio de una descripción textual que detalla los acontecimientos que ocurren en la realidad de la UME y los elementos del problema.
- Una definición del problema, estructurada por medio de una gráfica, en la que se precisan las necesidades actuales, los involucrados en la reestructuración de la UME, los principales beneficiarios, los intereses reales y la ideología imperante en la institución.
- La definición de cambios necesarios y deseables, en la que específicamente detallaremos las transformaciones que se piensan llevar a cabo para resolver el problema. Nos basaremos en la intuición de la MSB sobre la definición de transformaciones, pero la forma en la que expresaremos las transformaciones será el detalle de los cambios que se consideran ya como modificaciones factibles. En la perspectiva abordada, la definición de cambios es una etapa en la que se hace una simbiosis entre la definición de transformaciones y la elaboración de los modelos conceptuales para realizarlas.

Es en el marco de esta metodología que se propondrán los cambios técnicos a implementar. Atravesando la MSB, se tendrá en cuenta la metodología del diseño de organizaciones y en

organizaciones (Schvarstein, 1998), a fin de considerar los aspectos que podrían hacer fracasar la nueva propuesta para trabajar: chequeo y detección permanente de situaciones que evidencian falta de intencionalidad de cambio, fallas estratégicas en la gestión del cambio, fallas en la comunicación, etcétera. Estas consideraciones son necesarias, pues —para asegurar el éxito de la implementación— no se puede obviar el hecho de que se está trabajando con seres humanos que vienen desempeñando sus funciones de una manera a la que ya están acostumbrados y que les resulta cómoda.

Esta propuesta se desarrolla en el marco de un proyecto de investigación básica que se encuentra en sus primeros estadios. Por ello no podemos mencionar aún detalles sobre la implementación, aunque la culminación de esta etapa está prevista para fines del año 2024. Sin embargo, ya se están realizando las siguientes actividades: (i) indagar las ventajas de traducir conocimiento no estructurado a conocimiento estructurado en el dominio de aplicación, (ii) estudiar técnicas existentes que permitan llevar a cabo lo propuesto en la actividad, (iii) realizar una comparación entre las técnicas existentes y que son posibles de implementar, y (iv) especificar criterios que permitan modelizar los datos de una manera adecuada según el dominio de aplicación. Finalmente, de entre las técnicas exploradas, elegir la que mejor se adapte al caso de estudio.

De la lectura de lo anterior puede deducirse que se está en una fase de exploración de antecedentes, al mismo tiempo que se están planificando los cambios para reestructurar la UME.

3. LA UME: UNA ORGANIZACIÓN A REESTRUCTURAR

La UME es un centro de atención a la salud creado con la finalidad de dar respuesta a la preventión y promoción de la salud de la región. Asimismo, fue creada con fines educativos, para otorgar herramientas que apunten a mejorar la enseñanza de los estudiantes de la carrera de Medicina que se desarrolla en la UNCAUS. La UME brinda servicios en diferentes áreas de la salud, y cuenta con las siguientes especialidades: clínica médica, cirugía general, traumatología, pediatría, cardiología, oftalmología, kinesiología, ginecología, nutrición, psicología, psiquiatría, urología, odontología y neurología. Por otro lado, tiene laboratorio de análisis clínicos, rayos X, neonatología, vacunatorio, farmacia y salas de estudios específicos. Además, espacios de internación en la unidad coronaria y en salas de internación general e intermedia para un total de catorce camas, una unidad de cuidados intensivos con capacidad para cinco pacientes y dos quirófanos. Tiene también una sala de recepción de pacientes —shock—, cuya finalidad es contener temporalmente a las personas derivadas en ambulancia, y una sala de atención primaria para los pacientes que acuden a la UME por prestaciones de mínima complejidad como la toma de presión arterial, curaciones de heridas simples, suministro de insulina, entre otros.

Específicamente, la UME está ubicada en la ciudad de Presidencia Roque Sáenz Peña, provincia del Chaco, Argentina. En la ciudad, además de la UME, se dispone de un hospital

público y cuatro centros asistenciales privados. Sin embargo, la UME es el único instituto-escuela que posibilita la formación de los futuros médicos egresados de la Universidad. Así es que se cuenta con un móvil que recorre el interior de la provincia para realizar atención primaria de la salud, que incluye servicios esenciales de control y estudios elementales vinculados con la salud visual. Es empleado por docentes y estudiantes de las carreras de salud para la práctica real de lo aprendido en las aulas.

En promedio, se atienden 170 consultas por día más, aproximadamente, 130 turnos diarios para diagnósticos por imágenes. Cabe destacar que se reciben pacientes de localidades de toda la provincia. Sin embargo, toda la casuística que se atiende y el conocimiento que de ella se obtiene, se registra solamente de forma manual. En la actualidad no existen sistemas como la historia clínica electrónica, ni algún otro método para analizar los datos estadísticos que se desprenden de la casuística local. Esto resulta en información muy costosa de obtener para la toma de decisiones estratégicas de las áreas relacionadas a la UME.

La Figura 1 sintetiza la problemática desde un punto de vista estructurado. Es posible que los beneficiarios y los involucrados en el diseño de la solución se entiendan como similares. Sin embargo, los roles son diferentes. Por ejemplo, alumnos avanzados de la carrera de Ingeniería en Sistemas están involucrados en el diseño de la base de datos y de la ontología, pero, a la vez, son beneficiados, porque en base a esto adquieren o mejoran sus competencias profesionales.

Figura 1

Estructura de la situación problemática que involucra a la UME



A partir de la exploración de la situación actual de la organización, se detecta la necesidad de proponer cambios con respecto a la forma de trabajar y a los instrumentos requeridos para hacerlo. Estos cambios implican:

- Contar con un sistema de historias clínicas electrónicas.
- Aplicar métodos proporcionados por la IA para hacer significativa la casuística para la toma de decisiones.
- Desarrollar herramientas basadas en IA para el entrenamiento de los futuros médicos de la universidad.
- Realizar sesiones periódicas con el equipo de gestión de la UME, a fin de facilitar la posterior implementación de los cambios que se propongan.
- Realizar sesiones en las que se comunique al personal de la UME y de la carrera de Medicina las mejoras que se vayan implementando.

A continuación, nos referiremos a los cambios que se estiman necesarios de implementar para alcanzar los objetivos de reestructuración sistémica.

4. DEFINICIÓN DE TRANSFORMACIONES

En esta etapa, nos referiremos a las transformaciones como cambios, dado que no seguimos exactamente la MSB, sino que hacemos una adecuación de tal metodología. Hasta el momento, se ha detectado un cambio prioritario y urgente, y un cambio deseable, que insume mayor esfuerzo en su realización. Se detallan ambos a continuación:

Cambio 1: implementación de una historia clínica electrónica. Para este cambio (prioritario y urgente) se prevé construir una base de datos (BD)² en la que se registren los datos personales de los pacientes, sus signos y síntomas, y los resultados de sus estudios complementarios. La migración de los datos del papel al sistema se puede realizar a partir de una fecha determinada hacia atrás, o a partir de la fecha en la que se implemente el sistema. Esto es una decisión de la gestión de la UME.

Desafíos del cambio propuesto: (i) definir el modelo estructural de historia clínica que mejor se adapte a las necesidades, (ii) desarrollar la BD y poblarla en un tiempo prudente³.

Justificación del cambio: La necesidad de automatizar los registros de los que se dispone con fines administrativos y de decisión estratégica. La posibilidad de perder información valiosa por un imprevisto (como un incendio, por ejemplo).

Cambio 2: desarrollo de un sistema de entrenamiento en diagnósticos médicos, a partir de una ontología que sea capaz de justificar el porqué de un determinado diagnóstico presuntivo.

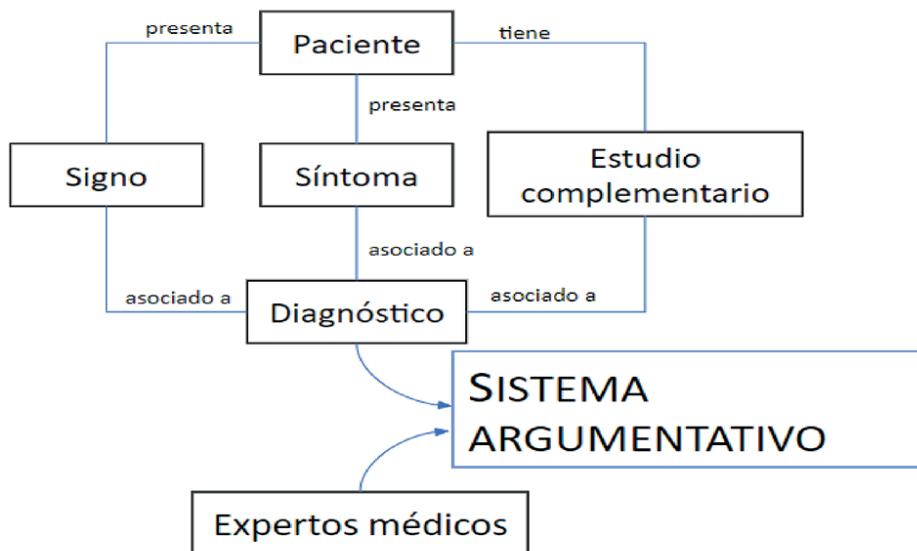
2 El modelo conceptual inicial de la BD puede encontrarse en el siguiente enlace: <https://dbdiagram.io/d/649ca73102bd1c4a5e385505>

3 Es un proyecto de investigación pequeño en una universidad joven, con limitaciones de presupuesto.

Para llevar a cabo este cambio (que es deseable, aunque no prioritario) se toma como base la propuesta de ElAssy et al. (2022), quienes ya desarrollaron una ontología para obtener guías médicas. La ontología propuesta por los autores define conceptos básicos como la anatomía del paciente, sus síntomas y diagnósticos. En nuestro caso, se prevé agregar el concepto de estudios complementarios. Además, en el sistema que se pretende implementar, las fuentes con las cuales se puede entrenar la ontología son las que aporta la casuística propia de la UME, pero también el estándar CIE-114⁴. En caso de que hubiese una duda diagnóstica, un sistema basado en argumentación sería el encargado de determinar el diagnóstico correcto, según la información de la que se dispone, y justificar su decisión. La Figura 2 expresa esta transformación.

Figura 2

Sistema de entrenamiento en diagnósticos presuntivos basado en ontología



Nota. Basado en la arquitectura de ElAssy et al. (2022).

Se decide usar una ontología por ser una herramienta que permite simplificar la complejidad del dominio mediante una conceptualización (Guarino et al., 2009), y porque le permite a la computadora interpretar el conocimiento y procesarlo sin ambigüedades. Existen numerosos métodos y herramientas para la construcción de ontologías (Al-Aswadi et al., 2020; Guzmán Luna et al., 2012; Subhashini & Akilandeswari, 2011).

⁴ Clasificación Internacional de Enfermedades. Ver: <https://www.who.int/es/news/item/11-02-2022-icd-11-2022-release>

Sin embargo, lo que se obtenga a partir de esta ontología como diagnóstico presuntivo, puede ser contradictorio con lo que se exprese en la CIE-11 o, incluso, con lo que sostienen fuentes expertas en la temática. Es allí donde se estima conveniente la posibilidad de desarrollar un sistema argumentativo para el diagnóstico presuntivo. La utilidad de este tipo de sistemas en el área de la medicina está ampliamente documentada (Doumbouya et al., 2015; Fejer et al., 2022; González Ramos, 2022).

Desafíos del cambio propuesto: el equipo que lleva a cabo esta investigación es novel y la implementación del cambio propuesto requiere no solamente que se haga efectivo el cambio anterior, sino también que se tenga el tiempo suficiente para armar la ontología y traducir el conocimiento a reglas que puedan ser manipuladas por un sistema argumentativo.

Justificación del cambio: la implementación de un sistema de este tipo podría servir para la formación de los profesionales médicos, ayudándolos a tomar decisiones más precisas y rápidas sobre los posibles diagnósticos de un paciente, lo que podría mejorar la atención médica en un futuro. Esta transformación se puede entender como la introducción de tecnología de vanguardia en la región.

La implementación de estos dos cambios de índole técnica ideados hasta el momento trae consigo la necesidad de capacitar y motivar constantemente a los empleados que en la actualidad cumplen funciones en la UME, de manera que adquieran nuevas habilidades (como realizar consultas a una BD), al mismo tiempo que no se sientan desplazados por una aplicación. Es decir, existe un tercer cambio, subyacente a los dos planificados, que está orientado al rediseño de los circuitos administrativos actuales, para que respalden el uso de los sistemas. En él, deberá tenerse en cuenta que el factor humano es un elemento central.

Implementar un nuevo sistema o introducir tecnología no se trata únicamente de incorporar herramientas y procesos automatizados. Es esencial reconocer que los miembros de la organización son quienes impulsan y hacen posible cualquier transformación exitosa. Considerar sus necesidades, capacidades y preocupaciones, así como fomentar una cultura de superación y adaptación, es crucial para asegurar la aceptación y la eficacia de las transformaciones propuestas en esta organización. No debemos perder de vista que son las personas las que impulsarán el éxito y la sostenibilidad de las transformaciones en la UME.

5. AVANCES DEL PROYECTO, RESULTADOS PREVISTOS Y TRABAJO FUTURO

En este momento, el equipo de investigación está abocado al diseño e implementación de la BD para las historias clínicas, para poder dedicar el año 2024 al desafío de implementar el segundo cambio, aunque sea de manera gradual y parcialmente. La prioridad, más allá de la reestructuración técnica, es que las personas que desempeñan los diversos roles en la UME, se

sientan atraídas por los cambios, y a gusto con la nueva propuesta. Se espera terminar el año 2023 con la BD poblada y en uso. Es así como a corto plazo se pretende:

- Para agosto-septiembre: finalizar la modelización y desarrollar la estructura de la BD relacional en base al dominio de aplicación, que funcionará bajo un entorno web.
- Octubre-noviembre: cargar paulatinamente las historias clínicas, comenzando por aquellas que pertenezcan a los docentes de la UNCAUS. Esto nos dará un *feedback* de cómo se siente el personal administrativo de la UME utilizando el nuevo sistema.
- Noviembre-diciembre: realizar las pruebas que permitan validar, de forma primaria, la construcción de la BD y su desempeño frente a los datos almacenados.

Con respecto al segundo cambio, se dispone de una justificación exhaustiva basada en antecedentes y en la exploración de características técnicas del porqué se decide estructurar el conocimiento desorganizado del que se dispone en una ontología. Si bien se puede pensar que la BD y la ontología técnicamente se solapan, destacamos que los usos que se les dará son muy diferentes. Además, la misma ontología puede obtenerse a partir de un traspase de la BD a conceptos, para reutilizar la información de la que se disponga oportunamente. Se prevé que este avance también se encuentre finalizado para el 2024.

6. CONCLUSIONES

La MSB es un enfoque estructurado para abordar problemas complejos y mal estructurados en entornos sociales y organizativos, como el de la UME. Fue desarrollada para tratar problemas donde no hay una solución técnica clara y objetiva. Su enfoque se basa en la idea de que los problemas en estos entornos están influenciados por factores sociales, culturales, políticos y subjetivos, por lo que requieren una comprensión más profunda y una aproximación más flexible que los métodos tradicionales basados en la ingeniería. Es por ello que se decidió utilizarla en este proyecto.

En este proyecto de investigación se han identificado dos cambios para reestructurar la UME. El primero se refiere a la implementación de una historia clínica electrónica, mediante la creación de una base de datos que registre la información de los pacientes. Este cambio es prioritario y urgente debido a la necesidad de automatizar los registros existentes, uniformar e integrar la información circulante y evitar la pérdida de datos valiosos. El segundo cambio propuesto implica desarrollar un sistema de entrenamiento en diagnósticos médicos basado en una ontología. Este cambio, deseable pero no prioritario, busca utilizar una ontología existente y ampliarla para incluir conceptos de estudios complementarios. Se plantea la posibilidad de emplear un sistema argumentativo para respaldar los diagnósticos presuntivos y justificar las decisiones tomadas.

Es importante destacar que la implementación de estos cambios técnicos implica considerar el factor humano en la UME. La capacitación y motivación de los empleados son fundamentales para garantizar el éxito y la aceptación de las transformaciones.

En resumen, a partir de la aplicación de la MSB, el proyecto de reestructuración de la UME se enfoca en cambios técnicos que buscan mejorar la gestión de la información y el entrenamiento en diagnósticos médicos. Sin embargo, se reconoce que el éxito de estos cambios depende en gran medida del factor humano y de garantizar la participación y adaptación de los miembros de la organización.

Estas conclusiones, propias de las etapas iniciales resultantes del avance de investigación, nos orientan a la profundización de técnicas que permitan traducir el conocimiento no estructurado en conocimiento estructurado en el dominio de la salud, así como a la generación de criterios comparativos de eficiencia de estas técnicas, para seleccionar aquellas que mejor se adapten a cada situación de estudio en particular.

Consideramos que es parte del camino para desarrollar una metodología que nos permita detectar la correlación existente entre el conocimiento que describe un determinado dominio de aplicación, para así formalizar las bases que alimenten un sistema de soporte a la decisión inteligente.

REFERENCIAS

- Al-Aswadi, F. N., Chan, H. Y., & Gan, K. H. (2020). Automatic ontology construction from text: a review from shallow to deep learning trend. *Artificial Intelligence Review*, 53, 3901-3928. <https://doi.org/10.1007/s10462-019-09782-9>
- Checkland, P. B., & Haynes, M. G. (1994). Varieties of systems thinking: the case of soft systems methodology. *System Dynamics Review*, 10(2-3), 189-197.
- Doumbouya, M. B., Kamsu-Foguem, B., Kenfack, H., & Foguem, C. (2015). Combining conceptual graphs and argumentation for aiding in the teleexpertise. *Computers in Biology and Medicine*, 63, 157-168. <https://doi.org/10.1016/j.combiomed.2015.05.012>
- ElAssy, O., de Vendt, R., Dalpiaz, F., & Brinkkemper, S. (2022). A semi-automated method for domain-specific ontology creation from medical guidelines. En A. Augusto, A. Gill, D. Bork, S. Nurcan, I. Reinhartz-Berger & R. Schmidt (Eds.), *Enterprise, business-process and information systems modeling* (pp. 295-309). Springer. https://doi.org/10.1007/978-3-031-07475-2_20
- Fejer, H. N., Hasan, A. H., & Sadiq, A. T. (2022). A survey of Toulmin argumentation approach for medical applications. *International Journal of Online & Biomedical Engineering*, 18(2), 26-39. <https://doi.org/10.3991/ijoe.v18i02.28025>

- Fu, S., Thorsteinsdottir, B., Zhang, X., Lopes, G. S., Pagali, S. R., LeBrasseur, N. K., Wen, A., Liu, H., Rocca, W. A., Olson, J. E., St. Sauver, J., & Sohn, S. (2022). A hybrid model to identify fall occurrence from electronic health records. *International Journal of Medical Informatics*, 162, 104736. <https://doi.org/10.1016/j.ijmedinf.2022.104736>
- González Ramos, O. E. (2022). Sistema de recomendación de artículos científicos en el ámbito de la medicina: caso de estudio cáncer de mama. Diagnóstico, tratamiento y prevención [Tesis de Maestría, Benemérita Universidad Autónoma de Puebla]. <https://hdl.handle.net/20.500.12371/18295>
- Guarino, N., Oberle, D., & Staab, S. (2009). What is an ontology? En S. Staab & R. Studer (Eds.), *Handbook on ontologies* (pp. 1-17). Springer. <https://doi.org/10.1007/978-3-540-92673-3>
- Harahap, N. C., Handayani, P. W., & Hidayanto, A. N. (2022). Barriers and facilitators of personal health record adoption in Indonesia: Health facilities' perspectives. *International Journal of Medical Informatics*, 162, 104750. <https://doi.org/10.1016/j.ijmedinf.2022.104750>
- Kish, K., Bunch, M. J., & Xu, B. J. (2016). Soft systems methodologies in action: Environment, health & Shanghai's elderly. *Systemic Practice and Action Research*, 29, 61-77. <https://doi.org/10.1007/s11213-015-9353-4>
- Lokmic-Tomkins, Z., Gray, K., Cheshire, L., Parolini, A., Sharp, M., Tarrant, B., Hill, N., Rose, D., Webster, M., Virtue, D., Brigne, A., Waring, R., Broussard, F., Tsirgialos, A., & Cham, K. M. (2023). Integrating interprofessional electronic medical record teaching in preregistration healthcare degrees: A case study. *International Journal of Medical Informatics*, 169, 104910. <https://doi.org/10.1016/j.ijmedinf.2022.104910>
- Guzmán Luna, J. A., López Bonilla, M., & Durley Torres, I. (2012). Metodologías y métodos para la construcción de ontologías. *Scientia Et Technica*, 17(50), 133-140. <https://www.redalyc.org/articulo.oa?id=84923878033>
- Medlock, S., Ploegmakers, K. J., Cornet, R., & Pang, K. W. (2023). Use of an open-source electronic health record to establish a “virtual hospital”: A tale of two curricula. *International Journal of Medical Informatics*, 169, 104907. <https://doi.org/10.1016/j.ijmedinf.2022.104907>
- Reynolds, M., & Holwell, S. (Eds.). (2010). *Systems approaches to managing change: a practical guide*. Springer. <https://doi.org/10.1007/978-1-84882-809-4>
- Schvarstein, L. (1998). Diseño de organizaciones y en organizaciones. En L. Schvarstein, *Diseño de organizaciones. Tensiones y paradojas* (pp. 63-173). Paidós.

Subhashini, R., & Akilandeswari, J. (2011). A survey on ontology construction methodologies. *International Journal of Enterprise Computing and Business Systems*, 1(1), 60-72.

Torlak, N. G., & Muceldili, B. (2014). Soft systems methodology in action: the example of a private hospital. *Systemic Practice and Action Research*, 27, 325-361. <https://doi.org/10.1007/s11213-013-9290-z>

Towards Energy Sustainability: A Literature Review of Green Software Development

Angelo Rodrigo Taco Jimenez

angelotacoj@gmail.com

<https://orcid.org/0000-0001-9806-5379>

Universidad de Lima, Perú

Received: July 11, 2023 / Accepted: September 12, 2023

doi: <https://doi.org/10.26439/ciis2023.7079>

ABSTRACT. In the organizational and business environment, the increasing consumption of electrical energy by IT equipment poses a challenge in terms of cost as well as environmental impact. To address this problem, a literature review is proposed to collect and examine the most recent developments in the field of green software and their impact on energy efficiency. To carry out this literature review, the PICo search strategy was adapted and implemented and a total of 23 relevant articles were selected. In relation to the problem addressed, the concept of green software, which seeks to create efficient and sustainable programs that optimize energy consumption, has been developed. The tools and practices of sustainable software design, techniques for the development of energy-efficient systems and approaches on how to address the problems of energy consumption in data centers and cloud computing are explored.

KEYWORDS: literature review / green software / energy consumption / energy efficiency / sustainability

HACIA LA SOSTENIBILIDAD ENERGÉTICA: UNA REVISIÓN DE LITERATURA DEL DESARROLLO DE SOFTWARE VERDE

RESUMEN. En el ámbito organizacional y empresarial, el creciente consumo de energía eléctrica por parte de los equipos informáticos representa un desafío en términos de costo, así como también de impacto ambiental. Para abordar esta problemática se propone una revisión de literatura para recopilar y examinar los avances más recientes en el campo del *software* verde y su impacto en la eficiencia del consumo de energía. Para llevar a cabo esta revisión de literatura, se adaptó y aplicó la estrategia de búsqueda PICo y se seleccionaron un total de 23 artículos

relevantes. En relación a la problemática abordada, se ha desarrollado el concepto de *green software*, el cual busca crear programas eficientes y sostenibles que optimicen el consumo de energía. Se exploran las herramientas y prácticas de diseño de *software* sostenible, técnicas para el desarrollo de sistemas eficientes en mención de consumo energético y enfoques en cómo abordar los problemas del consumo de energía en centros de datos y los servicios basados en la nube.

PALABRAS CLAVE: revisión de literatura, software verde, consumo de energía, eficiencia energética, sostenibilidad

1. INTRODUCTION

In the business environment, efficiency in the use of information technology (IT) equipment is of vital importance to carry out operations effectively. However, it has been observed that this equipment consumes a considerable amount of electrical energy, which results in a significant expense for companies and a considerable impact on the environment (Masanet et al., 2020). Energy consumption is mainly attributed to equipment hardware, which is primarily responsible for energy consumption.

In order to reduce the environmental impact of technology, in 1992, the United States Environmental Protection Agency introduced the Energy Star Program, which seeks to promote the production and use of energy-efficient electrical products (Boyd et al., 2008). Despite the fact that IT equipment is essential for managing large volumes of information in the era of digitization, the energy consumption of data servers worldwide accounted for approximately 1 % in 2020, although this figure is expected to increase significantly over the next 10 years (Masanet et al., 2020).

Among the most prominent companies estimated to have high annual energy consumption are Google and Facebook. According to López et al. (2019), these companies have implemented measures to counteract their impact on energy consumption. One example is Google's server energy consumption optimization policy, which has resulted in the establishment of the world's most sustainable data center in terms of environmental metrics. These centers consume up to five times less electricity than other data centers (López et al., 2019). For its part, Facebook has called on the services of Power Assure, a company specialized in optimizing electricity consumption in data centers. This company offers a software to monitor the consumption of servers, which turns them off when they are inactive or turns them on when necessary. Thanks to this solution, it is possible to achieve energy savings of up to 80 % (López et al., 2019).

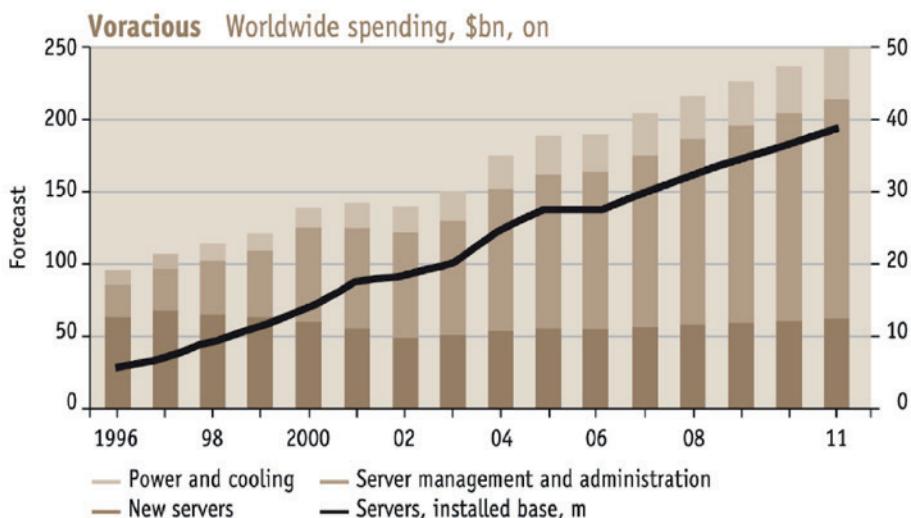
The adoption of green software practices complements the aforementioned initiatives of large companies to optimize energy consumption (Abdullah et al., 2015). Green software focuses on the design and development of programs that generate a positive impact on economic, social and environmental aspects, thus avoiding any direct or indirect negative impact on these areas. By implementing solutions and policies to optimize electricity consumption, companies can achieve significant cost savings and contribute to a more sustainable future for all (Kern et al., 2015).

Recent research has shown that the use of optimized software can generate savings of more than 140 % compared to non-optimized software (Capra et al., 2012). This highlights the importance of considering energy consumption in sustainable software design and development. To achieve this, work is being done to implement the green software methodology, which involves the creation of software that follows specific energy efficiency metrics and promotes the proper use of computer hardware, thus avoiding overloads and reducing energy consumption during task execution (Beghoura et al., 2017).

According to Bustamante et al. (2014), in 2006, data centers in the United States used US\$ 4,5 billion worth of electricity. Furthermore, it is estimated that most enterprise data centers will invest a similar amount of money in energy (power and cooling) and hardware infrastructure over the next five years, as mentioned by analyst Gartner (Kumar, 2007). This situation poses a significant challenge in terms of cost and sustainability.

To illustrate the importance of implementing sustainable measures, we will rely on Figure 1 (*Where the cloud meets the ground*, 2008), which shows an estimate of energy consumption.

Figure 1
Energy consumption from 1996 to 2011



Note. From *Where the cloud meets the ground* (2008).

It is interesting to note how the increase in the number of servers in data processing centers has led to an increase in the energy consumption required for cooling and maintenance. This trend poses significant challenges in terms of energy efficiency and sustainability at the enterprise level.

In summary, the adoption of green software practices emerges as a key solution to address energy consumption in the business environment (Munoz et al., 2017b). The implementation of green software methodology allows maximizing the energy efficiency of equipment through the development of optimized programs in terms of energy consumption. Therefore, it is crucial to conduct a thorough review of the current state of energy consumption and evaluate possible sustainable software alternatives.

2. BACKGROUND

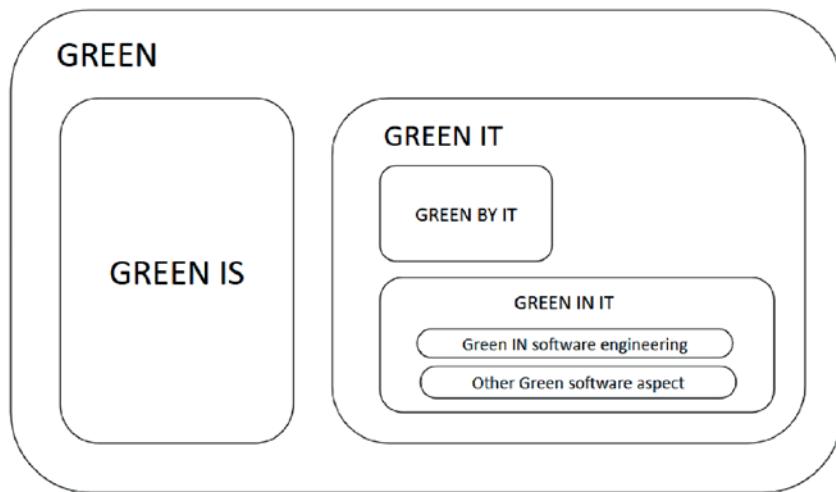
2.1 Green information technology

According to Hernández (2016), two different concepts that describe aspects related to information technology and its impact on sustainability are put forward: green information technologies (Green IT) and green information systems (Green IS).

The term *green IT* is used to refer to any action or initiative that is carried out using technologies and processes that are environmentally friendly in all stages of the life of information and communication systems and technologies. On the other hand, the concept of *green IS* refers to the procedures adopted by an organization with the aim of improving its environmental performance. It is considered a way to address and reduce the negative effects that information technologies can have on the environment (Hedwig et al., 2009; Hernández, 2016).

Figure 2, presented by Hernández (2016), provides a visual support that illustrates the terminology related to green technologies.

Figure 2
Terms associated with green technology



Note. From ¿Por dónde empezar para aplicar prácticas verde/sostenibles en el proceso de desarrollo del software y obtener un producto verde/sostenible? [Where to begin to implement practice green/sustainable in the development process of software and get a green/sustainable product?], by A. Hernández, 2016, 18 Convención Científica de Ingeniería y Arquitectura, IX Simposio Universitario Iberoamericano sobre Medioambiente (SUIMA), p. 3

Hernández (2016) provides a detailed description of the subdivisions found within the term *green IT*. One of these subdivisions is *green IN IT*, which refers to information technologies, either software or hardware. In turn, two distinct approaches can be identified within *green in IT*. The first is *green in software engineering*, which focuses on the process and product of green software development. The second approach is *other green software aspect*, which addresses the business processes and governance related to green software implementation.

On the other hand, the term *green by IT* is used when information technologies are used as tools to achieve green objectives. This involves minimizing waste production and reducing energy consumption through the implementation of specific applications and methods. It is crucial to consider these subdivisions within the scope of *green IT* in order to develop appropriate and effective solutions to sustainability challenges in the field of technology (Hernández, 2016).

2.2 Sustainable software engineering

The importance of software maintainability as a fundamental quality requirement is increasingly evident today. As Venters et al. (2017) highlight, the ability to maintain and upgrade software is a key factor in ensuring the durability and effectiveness of a product. In other words, software sustainability plays a critical role in the long-term success of any software development project. However, sustainability is not limited to software durability alone, but also encompasses its impact on the environment.

Although software itself does not consume energy, it has a significant impact on the energy consumption of the hardware on which it runs. Data centers, mobile devices and smart devices are just a few examples of devices that are affected by software energy consumption.

It is in this context where green technology becomes relevant, as it seeks to use hardware resources in a sustainable way in order to reduce environmental impact. To achieve this, it is necessary to review software development methodologies and promote the creation of more sustainable software. Software engineers play a key role in this process, as they must consider the impact on energy consumption of each design and implementation decision in the final system. Microsoft Learn (2023), through a course, presents two key philosophies for sustainable software engineering:

- **Everyone must be involved in solving the climate problem:**

Sustainable software engineering promotes the involvement of everyone in solving the climate problem, and small changes can have a big impact. Environmentalists work across all engineering disciplines, and standardizing the discussion of sustainability in technical meetings can lead to major changes in any organization.

- **Sustainability alone is sufficient to justify our work:**

As sustainable software engineers, we know that creating sustainable applications is beneficial because of their lower cost, higher performance and resilience. But the main reason is sustainability.

The development of software that is easy to maintain is a goal highlighted by González (2018), who states that this allows necessary changes to be made efficiently and cost-effectively to adapt to changes in the business, rather than replacing the software entirely. In this way, it is possible to extend the useful life of the software and make it more sustainable. In addition, Akinli (2013) mentions that various green metrics can be used to assess the environmental impact of software, such as the percentage of CPU usage, storage medium, work throughput and system energy consumption in kilowatt hours (kWh). The application of these metrics is essential to monitor the influence of information technologies and systems on the environment, as well as to evaluate the performance of companies that choose to implement sustainable approaches to software development.

On the other hand, Padilla et al. (2023) point out that the software programming process involves electrical energy consumption, and as the amount of code increases, so does the energy expenditure, which has an impact on the carbon footprint and the environment. Danny van Kooten, a programmer, has proposed the reduction of lines of code as a way to contribute to the fight against climate change within the technology industry (Padilla et al., 2023). According to calculations made by Ramos, this modification could have a significant impact on the reduction of CO₂ emissions, equivalent to stopping driving a car for 421 000 kilometers or reducing CO₂ emissions by 59 tons per month. It is important to note that reducing lines of code not only has the potential to reduce energy consumption and CO₂ emissions but also can simplify and improve software efficiency, reduce maintenance costs and improve software durability (Padilla et al., 2023).

3. METHODOLOGY

The main purpose of the study was to analyze the most recent advances in energy saving through green software. To conduct this research, a review process was chosen based on the methodology proposed by Nina et al. (2021) but adapting it to the objective of this research, instead of performing a systematic mapping as the aforementioned authors did; i.e., a focused and specific review of the relevant literature was carried out.

First, planning was carried out to identify the interest, population and current context of the review. Subsequently, questions applicable to the review were formulated and a search for articles was conducted using keywords and constructing search strings. Finally, articles related to the research were filtered and selected. These steps were carried out in detail to ensure a thorough and rigorous review of the existing literature on the topic.

3.1 Study planning

The first step began by conducting a study planning using the PICo technique:

- Population: Articles selected to address the questions posed.
- Interest: Identification of progress in the field of study.
- Context: Application of green software for the reduction of energy consumption.
- The following four questions were identified:
 - What are the current tools and frameworks that promote energy sustainable software design?
 - What techniques and principles are recommended to optimize energy efficiency in software development?
 - What strategies are employed in resource planning to manage energy consumption in data centers and cloud services?
 - How can virtual machine allocation algorithms be optimized to reduce energy consumption in data centers and cloud computing platforms?

3.2 Article search

As a second step, a search for articles was carried out in renowned databases such as Scopus, IEEE and ACM, which are the most frequently used for studies related to computer systems, information technologies, among other specialties. These databases were chosen not only because of their renown but also because of the precision they offer when performing detailed searches using keywords, which speeds up and improves the selection of relevant publications. The search for articles was focused on the topic of software development aimed at reducing energy consumption. As a result, 92 articles were obtained. Each of these were reviewed and evaluated based on their abstract and where they were published, either in a journal or a conference.

This paper mainly focuses on the analysis of trends in the field of software engineering, green computing, cloud services, green software, energy saving, data centers, intelligent software, software development. An analysis of articles published between 2016 and 2022 is presented. The filtering process included reviewing titles and abstracts to select those related to the study.

To be included in the research, the articles had to be from databases or journals ranked Q1 or Q2, be directly related to the main topic and be available in English or Spanish. In addition, the articles presented at recognized international symposia in the field of computer engineering and informatics were included.

On the other hand, the inclusion of articles from journals ranked Q3 or lower was rejected, as well as those whose focus was far from the main topic. Likewise, articles derived

from international symposia that were not within the specific field of computer engineering and informatics were discarded.

Finally, after filtering the articles, a total of 23 papers were selected, including journal articles and papers presented at conferences, which met the acceptance criteria established above. These papers were subject to a detailed analysis to identify trends and approaches related to software development aimed at reducing energy consumption, with the purpose of answering the questions posed in section 3.1. This selection and analysis process ensured the inclusion of only the most important and highest quality papers in the research.

4. RESULTS

4.1 What are the current tools and frameworks that promote energy sustainable software design?

According to the research conducted by Georgiou et al. (2020), two main categories of literature that focus on promoting sustainable and energy-efficient software development can be identified. On the one hand, there are those centered on the generation and application of tools and frameworks that facilitate the task and monitoring of sustainable software development. On the other hand, there are papers that explore and evaluate various design lines and development techniques that can be applied in a wide range of projects.

Munoz et al. (2017a) took a significant step along the way by developing a plugin that monitors the performance and energy efficiency of security interfaces in mobile operating systems. This line of research and development is complemented by other efforts, such as that of Dorn et al. (2019), who introduced the Producing Green Applications Using Genetic Exploration algorithm. This tool has the ability to identify variants of a program based on specific code transformation criteria, enabling optimal energy consumption without compromising software functionality. These advances are testimony to the growth and diversity in energy sustainability-oriented strategies in software development.

Yeganeh et al. (2019) presented the development of a dynamically priced capacity planning tool, which was designed specifically for green data centers in mobile networks seeking to efficiently balance energy consumption and operational costs. The main focus was on determining the optimal number of servers and balancing the cost of operation with service waiting times. This tool provides a significant advance in the search for solutions for a more sustainable software design.

Finally, Cruz and Abreu (2017) developed a tool focused on improving energy consumption in mobile devices. In a similar but more technical approach, Mancebo et al. (2018) proposed a framework that uses physical and digital modules, such as Energy Efficiency Tester and Software Energy Assessment, to accurately measure the energy consumption of a program during its execution.

4.2 What techniques and principles are recommended to optimize energy efficiency in software development?

In energy efficiency-oriented software design, there are principles and techniques that must be considered to ensure an effective implementation. In line with this, it is imperative to mention the energy focused virtual machine selection policy (Mandal et al., 2020). This technique focuses on the dynamic consolidation of virtual machines (VMs). By considering crucial aspects such as host server overload conditions and the current state of the VMs, it seeks to achieve two main goals: a significant reduction of energy consumption and minimization of service level agreement (SLA) violations.

Pereira et al. (2017) introduced the SPectrum-based energy leak localization. This technique is based on statistical analysis and execution tracing to identify critical points in the source code where less efficient energy consumption occurs. The proposal by Conoci et al. (2018) show us a strategy that seeks to efficiently leverage multiple processing threads on modern processors by setting precise energy limits.

Finally, in the context of the development of the Internet of Things (IoT) and fog computing, Lenka et al. (2019) stress the importance of optimizing energy efficiency through specialized routing protocols for IoT sensing infrastructure. They propose an approach that involves the creation of a rendezvous region in the center of the network area and adopts clustering and multipathing techniques. These strategies have been shown to effectively reduce power consumption and extend the lifetime of IoT network infrastructure.

It is clear that to effectively address the challenges of optimization and energy efficiency in software development, it is critical to take an interdisciplinary approach. Collaboration among diverse specialists offers a more holistic and effective approach to sustainability in this domain.

4.3 What strategies are employed in resource planning to manage energy Consumption in data centers and cloud services?

Currently, a number of approaches focused on resource planning have been recognized with the purpose of addressing the challenges of energy consumption in data centers and cloud services. Within this line, several studies have emphasized the implementation of advanced algorithms that directly correlate with energy optimization. Garg et al. (2019) not only analyzed this relationship but also highlighted the importance of reliability and stability of running applications.

On the one hand, Haddad et al. (2021) proposed a biphasic methodology focused on efficiency and sustainability. This methodology emphasizes, in its first phase, the optimal allocation of computing resources through a binary search algorithm, ensuring adequate attention to the demands of the IT area. And in its second phase, priority is given to the integration of

sustainable electrical resources, such as photovoltaic panels and wind turbines, complemented with energy storage systems to ensure continuity.

In addition, the use of machine learning techniques has been explored to find efficient solutions to this problem. Sahoo et al. (2018) developed a framework that uses machine learning to optimize task scheduling. In doing so, they managed to obtain promising results in terms of efficiency and resource optimization.

Hu et al. (2021) provide another perspective by introducing a fine-grained heterogeneous power distribution model for geographically dispersed data centers. This model, together with a two-phase online algorithm, seeks to minimize energy costs and the derived distribution gap. Simulated results confirm its effectiveness.

4.4 How can virtual machine allocation algorithms be optimized to reduce energy consumption in data centers and cloud computing platforms?

Several techniques have been proposed in the literature with the objective of improving the allocation of virtual machines and reducing their energy consumption (Gupta et al., 2018). One such technique is virtual machine migration, which uses specific algorithms to optimize available resources (Hu et al., 2021).

Another approach is workload balancing, which seeks to improve the efficiency of existing algorithms (Liu et al., 2016) or predict the load that will be presented on different VM resources to perform efficient migrations (Wu et al., 2017; Li et al., 2018).

In addition, it is taken into consideration that the growth in demand for cloud-based computing services has led to the need to increase the energy efficiency of data centers. To address this challenge, an energy-efficient hybrid framework has been proposed by Alarifi et al. (2020). This framework combines request scheduling and server consolidation, allowing virtual machines to be allocated more efficiently. Client requests are ranked according to their energy and time requirements, and specialized algorithms are used to manage resource migration and consolidation. Results indicate that an energy-efficient hybrid is superior to other approaches, offering improved energy efficiency, performance and cost savings.

In addition, approaches that combine container and virtual machine migration have been proposed with the goal of reducing energy consumption (Gholipour et al., 2020). Algorithms that take into account the target energy load and available resources have also been developed to determine the optimal allocation of virtual machines and thus reduce the final energy consumption (Mohammadhosseini et al., 2019).

Finally, idle virtual machines, consuming up to 70 % of the total server energy, present a significant challenge. An innovative algorithm called Active & Idle Virtual Machine Migration (Hossain et al., 2020), inspired by Ant Colony Optimization, has emerged to address this

issue. This tool relocates idle virtual machines, promoting significant energy savings and optimizing efficiency in data centers. These advances in green software point to future innovations that further refine the management of virtual machines in ecological terms.

5. CONCLUSIONS

The technology sector is undergoing a transition to more sustainable and energy-efficient practices, especially in software development and data center management. This research focuses on understanding the current state of these initiatives and identifying areas of opportunity.

Despite the existence of multiple tools and techniques aimed at fostering sustainability in programming, a significant gap is evident: the lack of integrated and structured methodologies for projects specifically dedicated to green software. While existing tools offer solutions to improve energy efficiency at the code level, the absence of a coherent methodological approach could slow down the actual implementation of these practices in technology projects.

In the realm of data centers and cloud-based services, there is a tendency to rely on simulations rather than testing in real scenarios. While simulations are valuable for conceptualizing and evaluating initial proposals, their limitation lies in not being able to capture all the uncertainties and variabilities that arise in real-world situations. Strategies that prove successful in a controlled environment may not be as successful in a practical context.

It is imperative, therefore, to conduct further research in real-world scenarios in order to validate the proposed solutions for energy management in data centers. Furthermore, it would be beneficial for the technology industry to advocate for the development and adoption of comprehensive methodologies, specifically targeted at sustainable software, thus facilitating its implementation throughout the development lifecycle.

REFERENCES

- Abdullah, R., Abdullah, S., Din, J., & Tee, M. (2015). A systematic literature review of green software development in collaborative knowledge management environment. *International Journal of Advanced Computer Technology (IJACT)*, 4(1), 63-80. <https://www.ijact.org/ijactold/volume4issue1/IJ0410057.pdf>
- Akinli, S. (2013). Green software development and design for environmental sustainability. *11th International Doctoral Symposium on Empirical Software Engineering (IDoESE 2013)*, ID183. https://www2.umbc.edu/eseiw2013/idoese/pdf/eseiw2013_IDoESE_183.pdf
- Alarifi, A., Dubey, K., Amoon, M., Altameem, T., El-Samie, F. E. A., Altameem, A., Sharma, S. C., & Nasr, A. A. (2020). Energy-efficient hybrid framework for green cloud computing. *IEEE Access: practical innovations, open solutions*, 8, 115356–115369.

- Beghoura, M. A., Boubetra, A., & Boukerram, A. (2017). Green software requirements and measurement: random decision forests-based software energy consumption profiling. *Requirements Engineering*, 22(1), 27-40. <https://doi.org/10.1007/s00766-015-0234-2>
- Boyd, G., Dutrow, E., & Tunnessen, W. (2008). The evolution of the ENERGY STAR® energy performance indicator for benchmarking industrial plant manufacturing energy use. *Journal of Cleaner Production*, 16(6), 709-715. <https://doi.org/10.1016/j.jclepro.2007.02.024>
- Bustamante, F. P., Guzman, C. A. P., & Vargas, J. D. L. (2014). Análisis de la aplicación del Green IT en las organizaciones. *Twelfth LACCEI Latin American and Caribbean Conference for Engineering and Technology*. <https://www.laccei.org/LACCEI2014-Guayaquil/RefereedPapers/RP235.pdf>
- Capra, E., Francalanci, C., & Slaughter, S. A. (2012). Is software “green”? Application development environments and energy efficiency in open source applications. *Information and Software Technology*, 54(1), 60–71.
- Conoci, S., Di Sanzo, P., Ciciani, B., & Quaglia, F. (2018). Adaptive performance optimization under power constraint in multi-thread applications with diverse scalability. *Proceedings of the 2018 ACM/SPEC International Conference on Performance Engineering (ICPE '18)*, 16-27. <https://doi.org/10.1145/3184407.3184419>
- Cruz, L., & Abreu, R. (2017). Performance-based guidelines for energy efficient mobile applications. *2017 IEEE/ACM 4th International Conference on Mobile Software Engineering and Systems (MOBILESoft)*, 46-57. <https://doi.org/10.1109/MOBILESoft.2017.19>
- Dorn, J., Lacomis, J., Weimer, W., & Forrest, S. (2019). Automatically exploring tradeoffs between software output fidelity and energy costs. *IEEE Transactions on Software Engineering*, 45(3), 219-236. <https://doi.org/10.1109/tse.2017.2775634>
- Garg, R., Mittal, M., & Son, L. H. (2019). Reliability and energy efficient workflow scheduling in cloud environment. *Cluster Computing*, 22(4), 1283-1297. <https://doi.org/10.1007/s10586-019-02911-7>
- Georgiou, S., Rizou, S., & Spinellis, D. (2020). Software development lifecycle for energy efficiency: Techniques and tools. *ACM Computing Surveys*, 52(4), 1-33. <https://doi.org/10.1145/3337773>
- Gholipour, N., Arianyan, E., & Buyya, R. (2020). A novel energy-aware resource management technique using joint VM and container consolidation approach for green computing in cloud data centers. *Simulation Modelling Practice and Theory*, 104. <https://doi.org/10.1016/j.simpat.2020.102127>

- González, A. H. (2018). La sostenibilidad y el software. *Dilemas contemporáneos: Educación, Política y Valores*, 5(2), artículo 44.
- Gupta, G., Singh Khichar, G., Rathi, R., & Singh, R. (2018). Energy-aware and cost effective VM allocation strategy based on Best Fit MultiValued Binpacking algorithm. *2018 8th International Conference on Cloud Computing, Data Science & Engineering (Confluence)*, 647–652.
- Haddad, M., Da Costa, G., Nicod, J.-M., Péra, M.-C., Pierson, J.-M., Rehn-Sonigo, V., Stolf, P., & Varnier, C. (2021). Combined IT and power supply infrastructure sizing for standalone green data centers. *Sustainable Computing: Informatics and Systems*, 30, 100505. <https://doi.org/10.1016/j.suscom.2020.100505>
- Hedwig, M., Malkowski, S., & Neumann, D. (2009). Taming energy costs of large enterprise systems through adaptive provisioning. *ICIS 2009 Proceedings*, 140. <http://aisel.aisnet.org/icis2009/140>
- Hernández, A. (2016). ¿Por dónde empezar para aplicar prácticas verdes/sostenibles en el proceso de desarrollo del software y obtener un producto verde/sostenible? [Where to begin to implement practice green/sustainable in the development process of software and get a green/sustainable product?] *18 Convención Científica de Ingeniería y Arquitectura, IX Simposio Universitario Iberoamericano sobre Medioambiente (SUIMA)*. <https://www.researchgate.net/publication/312538106>
- Hossain, M. K., Rahman, M., Hossain, A., Rahman, S. Y., & Islam, M. M. (2020). Active & idle virtual machine migration algorithm- a new ant colony optimization approach to consolidate virtual machines and ensure green cloud computing. *2020 Emerging Technology in Computing, Communication and Electronics (ETCCE)*, 1-6.
- Hu, X., Li, P., & Sun, Y. (2021). Minimizing energy cost for green data center by exploring heterogeneous energy resource. *Journal of Modern Power Systems and Clean Energy*, 9(1), 148–159. <https://doi.org/10.35833/MPCE.2019.000052>
- Kern, E., Dick, M., Naumann, S., & Hiller, T. (2015). Impacts of software and its engineering on the carbon footprint of ICT. *Environmental impact assessment Review*, 52, 53-61. <https://doi.org/10.1016/j.eiar.2014.07.003>
- Kumar, R. (2007). *Eight critical forces shape enterprise data center strategies*. Gartner.
- Lenka, R. K., Rath, A. K., & Sharma, S. (2019). Building reliable routing infrastructure for green IoT network. *IEEE Access: practical innovations, open solutions*, 7, 129892–129909.
- Li, Z., Yan, C., Yu, L., & Yu, X. (2018). Energy-aware and multi-resource overload probability constraint-based virtual machine dynamic consolidation method. *Future Generation Computer Systems*, 80, 139-156. <https://doi.org/10.1016/j.future.2017.09.075>

- Liu, Y., Shu, W., & Zhang, C. (2016). A parallel task scheduling optimization algorithm based on clonal operator in green cloud computing. *Journal of Communications*, 11(2), 85–191.
- López, M., Huedo, E., & Garbajosa, J. (2019). *Green IT: tecnologías para la eficiencia energética en los sistemas TI* [Green IT: energy efficient technologies for systems]. Fundación Madrid+d para el Conocimiento.
- Mancebo, J., Arriaga, H. O., García, F., Moraga, M. Á., de Guzmán, I. G.-R., & Calero, C. (2018). EET: a device to support the measurement of software consumption. *GREENS '18: Proceedings of the 6th International Workshop on Green and Sustainable Software*, 16-22.
- Mandal, R., Mondal, M. K., Banerjee, S., & Biswas, U. (2020). An approach toward design and development of an energy-aware VM selection policy with improved SLA violation in the domain of green cloud computing. *The Journal of Supercomputing*, 76(9), 7374-7393.
- Masanet, E., Shehabi, A., Lei, N., Smith, S., & Koomey, J. (2020). Recalibrating global data center energy-use estimates. *Science*, 367(6481), 984-986. <https://doi.org/10.1126/science.aba3758>
- Microsoft Learn. (2023). *Introducción a la ingeniería de software sostenible* [An introduction to sustainable software engineering] [Video]. Microsoft. <https://learn.microsoft.com/es-es/training/modules/sustainable-software-engineering-overview/2-overview>
- Mohammadhosseini, M., Toroghi Haghigat, A., & Mahdipour, E. (2019). An efficient energy-aware method for virtual machine placement in cloud data centers using the cultural algorithm. *The Journal of Supercomputing*, 75, 6904-6933. <https://doi.org/10.1007/s11227-019-02909-3>
- Munoz, D.-J., Montenegro, J. A., Pinto, M., & Fuentes, L. (2017a). Green security plugin for pervasive computing using the HADAS toolkit. *2017 IEEE 15th Intl Conf on Dependable, Autonomic and Secure Computing, 15th Intl Conf on Pervasive Intelligence and Computing, 3rd Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress (DASC/PiCom/DataCom/CyberSciTech)*, 796-803. <https://doi.org/10.1109/DASC-PICom-DataCom-CyberSciTec.2017.136>
- Munoz, D.-J., Pinto, M., & Fuentes, L. (2017b). Green software development and research with the HADAS toolkit. *ECSA '17: Proceedings of the 11th European Conference on Software Architecture: Companion Proceedings*, 205-211. <https://doi.org/10.1145/3129790.3129818>
- Nina, H., Pow-Sang, J. A., & Villavicencio, M. (2021). Systematic mapping of the literature on secure software development. *IEEE Access: Practical Innovations, Open Solutions*, 9, 36852-36867. <https://doi.org/10.1109/access.2021.3062388>

- Padilla, A. F. A., Ávila, E. S. B., & Solórzano, R. A. T. (2023). Programación verde en el software [Green software programming]. *Revista UNESUM-Ciencias*, 7(1), 187-196. <https://revistas.unesum.edu.ec/index.php/unesumciencias/article/view/419>
- Pereira, R., Carçao, T., Couto, M., Cunha, J., Fernandes, J. P., & Saraiva, J. (2017). Helping programmers improve the energy efficiency of source code. *ICSE-C '17: 2017 Proceedings of the 39th International Conference on Software Engineering Companion*, 238-240. <https://doi.org/10.1109/ICSE-C.2017.80>
- Sahoo, S., Sahoo, B., & Turuk, A. K. (2018). An energy-efficient scheduling framework for cloud using learning automata. *2018 9th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, 1-5. <https://doi.org/10.1109/ICCCNT.2018.8493692>
- Venters, C. C., Seyff, N., Becker, C., Betz, S., Chitchyan, R., Duboc, L., McIntyre, D., & Penzenstadler, B. (2017). Characterising sustainability requirements: A new species, red herring, or just an odd fish? *ICSE '17: 39th International Conference on Software Engineering: Software Engineering in Society Track*, 3-12. <https://hdl.handle.net/1807/75783>
- Where the cloud meets the ground. (2008, October 25). *The Economist*. <https://www.economist.com/special-report/2008/10/25/where-the-cloud-meets-the-ground>
- Wu, Y., Tornatore, M., Ferdousi, S., & Mukherjee, B. (2017). Green data center placement in optical cloud networks. *IEEE Transactions on Green Communications and Networking*, 1(3), 347-357. <https://doi.org/10.1109/tgcn.2017.2709327>
- Yeganeh, H., Salahi, A., & Pourmina, M. A. (2019). A novel cost optimization method for mobile cloud computing by capacity planning of green data center with dynamic pricing. *Canadian Journal of Electrical and Computer Engineering*, 42(1), 41-51.

Heurísticas en la evaluación de la usabilidad de aplicaciones móviles: conceptos y aplicación

Izabella Barros

izabellabl.iza@gmail.com

Centro Universitário Alves Faria – UNIALFA, Brasil

Filipe de Assis Santos

filipeabnersantos@gmail.com

Centro Universitário Alves Faria – UNIALFA, Brasil

Sharon Candini

Sharonrose18@hotmail.com

Centro Universitário Alves Faria – UNIALFA, Brasil

Marcos Dias de Paula

marcosdias.projetos@gmail.com

Centro Universitário Alves Faria - UNIALFA, Brasil

Recibido: 11de julio del 2023 / Aceptado: 12 de septiembre del 2023

doi: <https://doi.org/10.26439/ciis2023.7080>

RESUMEN. La usabilidad es un factor esencial en el desarrollo de productos e interfaces, pues busca que los usuarios puedan utilizar un sistema de manera eficaz, eficiente y satisfactoria. La definición de la Organización Internacional de Normalización (ISO), desarrollada en conjunto con la Comisión Electrotécnica Internacional (IEC, por sus siglas en inglés) destaca que la usabilidad está relacionada con la capacidad de un producto para ser utilizado por usuarios específicos para lograr objetivos específicos en un contexto determinado. Hay varias heurísticas y principios que se pueden aplicar para evaluar y mejorar la usabilidad de las interfaces. Entre ellos destacan los principios de eficiencia, *learnability, memorability, satisfaction y errors*. Este artículo presenta, a través de una metodología de revisión bibliográfica, los conceptos y aplicaciones de las heurísticas de usabilidad y su importancia en la evaluación de aplicaciones

móviles. También presenta las heurísticas de Nielsen como la base más utilizada en el desarrollo de sistemas para evaluar la usabilidad de aplicaciones móviles.

PALABRAS CLAVE: tecnologías de la información, aplicaciones móviles, interfaz, usabilidad, heurística.

HEURISTICS IN EVALUATING THE USABILITY OF MOBILE APPLICATIONS – CONCEPTS AND APPLICATION

ABSTRACT. Usability is an essential factor in the development of products and interfaces, seeking to ensure that users can use a system effectively, efficiently and satisfactorily. The International Organization for Standardization (ISO) and International Electrotechnical Commission (IEC) definition highlights that usability is related to the ability of a product to be used by specific users to achieve specific goals in a given context. There are several heuristics and principles that can be applied to evaluate and improve the usability of interfaces. Among them, the principles of efficiency, learnability, memorability, satisfaction and errors stand out. This article presents, through a bibliographic review methodology, the concepts and applications of usability heuristics, their importance in the evaluation of mobile applications and also presents Nielsen's heuristics as the most used basis in the development of systems for evaluating the usability of mobile applications.

KEYWORDS: information technology, mobile applications, interface, usability, heuristics.

1. INTRODUCCIÓN

La usabilidad es un factor esencial en el desarrollo de productos e interfaces, pues busca que los usuarios puedan utilizar un sistema de manera eficaz, eficiente y satisfactoria. La definición de la Organización Internacional de Normalización (ISO), trabajada en conjunto con la Comisión Electrotécnica Internacional (IEC por sus siglas en inglés), destaca que la usabilidad está relacionada con la capacidad de un producto para ser utilizado por usuarios específicos para lograr objetivos específicos en un contexto determinado.

Hay varias heurísticas y principios que se pueden aplicar para evaluar y mejorar la usabilidad de las interfaces. Entre ellos destacan los principios de eficiencia, aprendibilidad, memorabilidad, satisfacción y errores. Estos principios tienen como objetivo garantizar que el usuario pueda realizar tareas rápidamente, aprender fácilmente las funciones del sistema, recordarlas incluso después de un período de inactividad, sentirse satisfecho con el uso del sistema y cometer pocos errores durante el proceso.

Además, la referencia muestra que la usabilidad es especialmente importante en las aplicaciones móviles, dado el alto porcentaje de dispositivos móviles utilizados para acceder a internet en Brasil y la gran cantidad de desinstalaciones de aplicaciones. Para asegurar la fidelidad y satisfacción de los usuarios, es fundamental que las aplicaciones móviles ofrezcan una buena experiencia de usuario. En este sentido, la evaluación heurística es una técnica ampliamente utilizada, que permite identificar problemas de usabilidad y mejorar la calidad de las interfaces.

Se pueden aplicar varias heurísticas en la evaluación de la usabilidad, como las heurísticas de Nielsen, por ejemplo, que cubren aspectos como visibilidad del estado del sistema, compatibilidad con el mundo real, control y libertad del usuario, consistencia y estándares, retroalimentación sobre el estado del sistema, prevención de errores, detección, reconocimiento en lugar de recuerdo, flexibilidad y eficiencia de uso, diseño estético y minimalista, y ayuda y documentación. Es importante señalar que la evaluación de la usabilidad de las interfaces móviles presenta algunas diferencias en relación a las interfaces web, debido al tamaño de la pantalla y al contexto de uso. Las heurísticas móviles enfatizan aspectos como la flexibilidad, la eficiencia de uso, el diseño minimalista, la visibilidad del estado del sistema y la prevención de errores. Estas diferencias deben tenerse en cuenta para garantizar que las interfaces móviles satisfagan las necesidades y expectativas de los usuarios.

Al aplicar estas heurísticas y principios, los profesionales pueden crear interfaces más intuitivas y fáciles de usar, que brinden una experiencia positiva a los usuarios y aumenten así la probabilidad de compromiso y uso continuo de las aplicaciones móviles.

La metodología utilizada para la elaboración de este artículo fue una revisión bibliográfica para conocer los conceptos y aplicaciones de las heurísticas de usabilidad y su importancia en la evaluación de aplicaciones móviles. Destacan en particular las heurísticas de Nielsen, que

son la base más utilizada para la implementación de sistemas de evaluación de usabilidad de aplicaciones móviles.

2. HEURÍSTICAS EN LA EVALUACIÓN DE LA USABILIDAD

El término usabilidad tiene muchas definiciones. La Organización Internacional para la Estandarización y la Comisión Electrotécnica Internacional definen la usabilidad en ISO 9241-11 como la medida en que un producto puede ser utilizado por usuarios específicos para lograr objetivos específicos (la precisión y la integridad con la que los usuarios logran objetivos específicos), la eficiencia (los recursos gastados en relación con la precisión y la exhaustividad con la que los usuarios logran los objetivos) y la satisfacción (la comodidad y aceptabilidad del uso) en un contexto de uso específico (International Organization for Standardization, 2018).

El estándar también tiene las siguientes definiciones:

- a) Eficiencia: implica el deber ser eficiente para ser utilizado. Es decir, el usuario debe ser capaz de realizar el mayor número de tareas por unidad de tiempo al utilizar el sistema. Cuanto mayor sea la usabilidad, más rápido podrá alcanzar su objetivo y completar la tarea.
- b) Facilidad de aprendizaje: el sistema debe ser fácil de aprender. Los usuarios deben ser capaces de aprender por sí mismos las principales funcionalidades del sistema.
- c) Memorabilidad: se refiere a tener que ser fácil de recordar, lo que hace que los usuarios ocasionales puedan usarlo incluso después de un cierto período de inactividad. Los usuarios deben poder usar el sistema sin tener que pasar por una curva alta de aprendizaje.
- d) Satisfacción: el sistema debe ser agradable y garantizar la satisfacción del usuario al utilizarlo.
- e) Errores: el sistema debe tener una baja tasa de ocurrencia de errores cuando los usuarios lo están utilizando. Esto no se relaciona con los errores del sistema, sino con la cantidad de errores que comete el usuario para completar una tarea determinada. Hay heurísticas que definen qué es importante considerar en términos de usabilidad cuando el objetivo es la calidad del *software*.

Según datos de la encuesta hecha por Kemp (2021), Brasil tenía 205,4 millones de conexiones de dispositivos móviles, equivalentes al 96,3 % de la población. Ante este escenario, es necesario que las aplicaciones móviles ofrezcan una buena experiencia de uso a los usuarios, con el fin de garantizar su fidelidad y satisfacción. Sin embargo, datos de referencia presentados por Statista (2020) muestran que la tasa de desinstalación de aplicaciones Android en la población brasileña es del 41,9 %. Las razones de este índice pueden ser la falta de coherencia, la mala comunicación con el usuario y los sistemas lentos (Wroblewski, 2011).

Para satisfacer a los usuarios se debe garantizar la calidad idónea de las interfaces. Con este objetivo, es fundamental la evaluación de la usabilidad, como destaca Shneiderman (2010), investigador en interacción hombre-máquina. Un principio de uso frecuente para la evaluación de la usabilidad es la evaluación heurística, que incluye la evaluación de la interfaz con un conjunto de procedimientos diseñados para identificar problemas de usabilidad. Las evaluaciones y los requisitos del usuario determinan qué heurística proporcionará la solución óptima. Para evaluar la usabilidad de una interfaz web, existen varias heurísticas. Un ejemplo son las de Nielsen, que abarcan la coherencia, el acuerdo del sistema con el mundo real y la visualización del estado del sistema. Hay otras heurísticas, como las de Tognazzini (2003) y las de Shneiderman y Plaisant (2010), que enfatizan la facilidad de aprendizaje del usuario y la eficiencia de la interfaz.

Tognazzini (2003) describe un conjunto de seis principios que deben ser considerados como la base de un buen proyecto. Estos son: visibilidad, retroalimentación, restricciones, mapeo, consistencia y entrega. Pero este conjunto de principios de diseño de interacción es más extenso, pues incluye, además de los mencionados anteriormente, los siguientes:

- a) Productividad: el proyecto debe permitir a los usuarios estar constantemente en actividad para que maximice su eficiencia.
- b) Anticipación: se trata de predecir los deseos, inquietudes y pasos que dará el usuario.
- c) Autonomía: pretende permitirle al usuario comprender y aprender rápidamente.
- d) Estándares (valores habituales): esto es para que los campos de texto con valores por defecto aparezcan seleccionados y evitar así que el usuario tenga que seleccionar todo, borrar y escribir.
- e) Daltonismo: aún si se usa el color para transmitir información, es necesario considerar elementos complementarios (por ejemplo, distintos tonos de gris, gráficos, o etiquetas de texto) para distinguir aspectos diferentes de la interfaz.
- f) Interfaces explotables: mantener despejados los caminos, tanto para llegar como para salir de la información.
- g) Ley de Fitts: el tiempo para alcanzar un objetivo determinado está en función de la distancia y el tamaño. Es decir, un elemento en la interfaz será más fácil de seleccionar si es grande y si requiere un menor desplazamiento del dedo (para el caso de los dispositivos móviles).

Shneiderman y Plaisant (2010), por su parte, se refieren a las ocho reglas de oro, que son los principios rectores de una lista de heurísticas utilizables que pueden guiar el diseño y la evaluación de la mayoría de los sistemas interactivos. Estas reglas son:

- a) Mantener la consistencia. Cuanto más diversas sean las formas de interacción, más difícil será usar la interfaz. Por lo tanto, mantener la consistencia es clave. Esto facilita

la adaptación de un momento particular que está viviendo el usuario a otras situaciones vividas anteriormente, facilitando así la decisión sobre qué acción tomar.

- b) Cumplir con la usabilidad universal. Determina las necesidades de diferentes usuarios, crea diseños flexibles y convierte contenido fácilmente. Las diferencias entre principiantes y expertos, grupos de edad, discapacidades y diversidad técnica enriquecen el conjunto de requisitos para la gestión del programa.
- c) Proporcionar retroalimentación informativa. El sistema debe proporcionar retroalimentación para cada acción del usuario. Para acciones repetitivas y pequeñas, la respuesta puede ser moderada, mientras que, para movimientos esporádicos y grandes, la respuesta debe ser más extensa. Una representación visual de objetos de interés puede proporcionar un entorno para mostrar los cambios de forma explícita.
- d) Incluir diálogos que indican el final de una acción. Las secuencias de una acción deben organizarse en grupos con principio, medio y final. La retroalimentación al completar un conjunto de acciones le da al usuario una sensación de logro, una percepción de alivio y una indicación de preparación para el siguiente conjunto.
- e) Evitar errores. Sistema para evitar que los usuarios cometan errores críticos. Si el usuario comete un error, la interfaz debe detectarlo y proporcionar instrucciones simples, constructivas y específicas para reanudar la operación.
- f) Permitir la fácil reversión de acciones. Una de las principales características que una interfaz tiene para ofrecer al usuario es poder devolver una acción, o incluso un grupo de acciones, que el usuario haya realizado durante su uso.
- g) Apoyar el control del usuario. Al crear la sensación de que el usuario tiene el control, se establece un nivel de confianza entre el usuario y la interfaz. Y esto sucederá siempre que los cambios en el entorno estén en línea con sus expectativas.
- h) Reducir la carga de memoria a corto plazo. Cada interfaz debe tener una jerarquía bien desarrollada para que el usuario pueda encontrar rápidamente la información que está buscando sin tener que seguir escribiendo datos en una página y compararlos con otros datos en otras páginas.

En cuanto a las heurísticas de Nielsen, es importante enfatizar que estas son una referencia importante para los diseñadores y desarrolladores que desean crear interfaces de aplicaciones móviles intuitivas y fáciles de usar. Nielsen (1994) creó un conjunto de heurísticas para evaluar la usabilidad de las interfaces de usuario, que originalmente fueron diseñadas para interfaces de escritorio, pero que pueden adaptarse para aplicaciones en interfaces móviles y web. Estas heurísticas consisten en:

- a) Visibilidad del estado del sistema. El sistema debe informar al usuario de cualquier tipo de evento, ya sea en términos de procesamiento, estado de una acción, tarea en

curso, actualización de las operaciones realizadas por el usuario o cualquier tipo de retroalimentación. Esta heurística está relacionada con el hecho de que, al dar decisiones informativas para usar el sistema, puede ayudar a los usuarios a comprender lo que está sucediendo.

- b) Compatibilidad entre el sistema y el mundo real. Estas heurísticas tratarán sobre un conjunto de principios que deben ser considerados al momento de diseñar interfaces, para que sean efectivas, eficientes y satisfactorias para el usuario final, sin necesidad de mucho conocimiento cognitivo o esfuerzo para entender cómo funciona el sistema. Los elementos de estas interfaces deben ser similares a los elementos con los que los usuarios están familiarizados en su entorno diario.
- c) Control y libertad del usuario. La aplicabilidad de esta heurística es fundamental para dar a los usuarios la sensación de que tienen el control del sistema y para minimizar su frustración y confusión. Al brindar la opción de deshacer o cancelar acciones, por ejemplo, los usuarios tienen más libertad para experimentar y explorar el sistema sin temor a cometer errores irremediables.
- d) Consistencia y patrones. Esta heurística tiene un principio fundamental de diseño de interfaz de usuario, que se refiere a la uniformidad y previsibilidad del comportamiento de los elementos de la interfaz en diferentes contextos a lo largo del tiempo. Este concepto ayuda a los usuarios a comprender e interactuar rápidamente con el sistema sin tener que aprender nuevas formas de navegar o de usar interfaces en cada sección.
- e) Retroalimentación sobre el estado del sistema. Esta heurística se refiere a la capacidad de un sistema para proporcionar a los usuarios una retroalimentación clara e inmediata que les informe sobre el estado de las acciones que realizan. Este propósito ayuda a los usuarios a entender lo que está pasando en el sistema o aplicación y a evaluar si la acción que realizaron fue exitosa o no, aumentando la confianza en la interfaz y reduciendo la posibilidad de error o confusión.
- f) Prevención de errores. Estas heurísticas son una parte crucial del diseño de interfaces de usuario efectivas, ya que ayudan a evitar problemas que podrían conducir a errores o fallas del usuario.
- g) Reconocimiento en lugar de recuerdo. Esta heurística sugiere que la interfaz de usuario debe diseñarse de tal manera que minimice la necesidad de memorización y favorezca, en cambio, la identificación rápida y fácil de las opciones de información relevantes. Esto se debe a que la memoria humana tiene limitaciones y se sobrecarga fácilmente, por lo que es importante que la interfaz presente la información y las opciones de forma clara y organizada, resaltando los elementos esenciales.
- h) Flexibilidad y eficiencia de uso. Esta heurística se refiere a la capacidad del sistema para permitir a los usuarios realizar sus tareas de diferentes formas, adaptándose al

nivel de experiencia y habilidad. La flexibilidad es importante porque los usuarios tienen diferentes necesidades y niveles de habilidad, y el sistema debe poder acomodarlos a todos. La interfaz debe diseñarse de tal manera que el usuario pueda realizar tareas de diferentes maneras (por ejemplo, a través de atajos de teclado o gestos de pantalla táctil).

- i) Diseño estético y minimalista. Esta heurística ayuda a garantizar que el diseño esté orientado al usuario y no solo que sea estéticamente agradable. Significa que el enfoque está en crear una interfaz que funcione bien y que sea fácil de usar para las personas.
- j) Ayuda y documentación. La aplicación de esta heurística es fundamental para un producto de *software* o una interfaz web, ya que ayuda al usuario a comprender cómo utilizar el producto y solucionar los problemas que puedan surgir. Además, una documentación clara y bien organizada reduce la necesidad de soporte al usuario y, en consecuencia, los costos para la empresa.

A la vista de estas heurísticas, cabe destacar las principales diferencias entre la evaluación de la usabilidad de las interfaces *web* y móvil, una de las cuales es el tamaño de la pantalla y otra el contexto de uso. En los dispositivos móviles, la pantalla suele ser más pequeña y las interacciones son más limitadas que en una computadora de escritorio o portátil, lo que puede afectar la aplicabilidad de ciertas heurísticas, como señala Shneiderman (2010).

Además, las heurísticas para *web* y para móvil pueden enfatizar diferentes aspectos de la usabilidad. Nielsen y Budiu (2012) subrayan la importancia de aspectos específicos de la usabilidad móvil, como la flexibilidad, la eficiencia de uso y el diseño minimalista, pero destacan la visibilidad del estado del sistema y la prevención de errores como los aspectos más importantes en los dispositivos móviles (debido al espacio limitado y a una mayor propensión a errores). Los profesionales que siguen estas heurísticas pueden asegurarse de que sus interfaces móviles satisfagan las necesidades y expectativas de los usuarios, brinden una experiencia de usuario satisfactoria y aumenten la probabilidad de que los usuarios continúen usando la aplicación.

3. CONCLUSIONES

Considerando los conceptos presentados en este artículo, la discusión sobre las heurísticas y la importancia de la usabilidad en el desarrollo de productos e interfaces de *software* con énfasis en las aplicaciones móviles, es claro que resulta sumamente importante analizar los principios heurísticos y de usabilidad, con el fin de viabilizar el diseño de interfaces que sean intuitivas y también que mejoren la experiencia del usuario, para así conseguir una navegación más fácil y comprensible para un mayor número de personas.

Los principios de eficiencia, aprendizaje, memorización, satisfacción y minimización de errores juegan un papel fundamental para que los usuarios alcancen sus objetivos de forma

eficaz y satisfactoria. Además, es esencial tener en cuenta el tamaño de la pantalla del dispositivo y los factores contextuales al abordar las disparidades de usabilidad entre las interfaces móviles y web.

La discusión de evaluación heurística representa un enfoque valioso para identificar problemas de usabilidad y mejorar la calidad de la interfaz, especialmente cuando se usan heurísticas como la de Nielsen.

En el contexto brasileño, donde los dispositivos móviles se utilizan ampliamente y las tasas de desinstalación de aplicaciones son altas, garantizar la lealtad y satisfacción del usuario depende de que las aplicaciones móviles brinden una experiencia de usuario superior. Al aplicar heurísticas de usabilidad e incorporar principios de diseño interactivo, los desarrolladores pueden crear interfaces que satisfagan de manera efectiva las necesidades y expectativas de los usuarios.

Se concluye que el desarrollo de productos móviles se beneficia mucho de los principios heurísticos y de usabilidad. Estos principios priorizan la creación de interfaces intuitivas y fáciles de usar. Estas interfaces aumentan el compromiso y mejoran la experiencia general de la aplicación. Los usuarios los encuentran más satisfactorios, lo que resulta en períodos más largos de uso de la aplicación.

REFERENCIAS

- Kemp, S. (2021). *Digital in Brazil: All the statistics you need in 2021. DataReportal – Global Digital Insights*. <https://datareportal.com/reports/digital-2021-brazil>
- International Standards Organization (2018). Ergonomics of human-system interaction. Part 11: Usability: Definitions and concepts (ISO 9241-11: 2018).
- Nielsen, J. (1994). Heuristic evaluation. En J. Nielsen & R. L. Mack (Eds.) *Usability inspection methods*. Wiley.
- Nielsen, J., & Budiu, R. (2012). *Mobile usability*. New Riders.
- Shneiderman, B., & Plaisant, C. (2010). *Designing the user interface: Strategies for effective human-computer interaction* (5ta ed.). Pearson.
- Statista (2020). *App uninstall rate worldwide in 2020*. <https://www.statista.com/>
- Tognazzini, B. (2003). *First principles of interaction design. Interaction design solutions for the real world*. <https://asktog.com/atc/principles-of-interaction-design/>
- Wroblewski, L. (2011). *Mobile first*. A Book Apart.

Exploring Stroke Risk Identification by Machine Learning: A Systematic Review

Lelis Raquel Atencia Mondragon
20190175@aloe.ulima.edu.pe
<https://orcid.org/0009-0002-7245-9577>
Universidad de Lima, Perú

Melany Cristina Huarcaya Carbajal
20192902@aloe.ulima.edu.pe
<https://orcid.org/0009-0005-1752-2950>
Universidad de Lima, Perú

Rosario Guzmán Jiménez
rguzman@ulima.edu.pe
<https://orcid.org/0000-0002-4550-7935>
Universidad de Lima, Perú

Received: June 27, 2023 / Accepted: September 12, 2023
doi: <https://doi.org/10.26439/ciis2023.7081>

ABSTRACT. This work aims to systematize previous studies on stroke risk identification and its relationship with machine learning. A systematic review was conducted using the Web of Science and Scopus databases. The information was organized into three sections: stroke risk factors, data preprocessing techniques and techniques for identifying stroke risk with an emphasis on the most important features. The main results are as follows: risk factors are divided into modifiable (work environment and air pollution) and non-modifiable (sex, family history). The most commonly used data preprocessing techniques are SMOTE, standardization and value elimination/imputation. The most commonly used techniques for identifying stroke risk include support vector machine, random forest, logistic regression, naïve Bayes, k-nearest neighbors and decision tree.

KEYWORDS: stroke / models / machine learning / risk / identification

EXPLORACIÓN DE LA IDENTIFICACIÓN DEL RIESGO DE ACCIDENTE CEREBROVASCULAR MEDIANTE MACHINE LEARNING: UNA REVISIÓN SISTEMÁTICA

RESUMEN. Este trabajo busca sistematizar los estudios sobre la identificación del riesgo de sufrir un accidente cerebrovascular (ACV) en las bases de datos Web of Science y Scopus y su relación con el *machine learning*. La información se organizó en tres secciones: factores de riesgo del ACV, técnicas de preprocesamiento de datos y técnicas para identificar el riesgo de ACV haciendo énfasis en las características más relevantes. Los principales resultados son los siguientes: los factores de riesgo se dividen en modificables (ambiente de trabajo y contaminación del aire) y no modificables (sexo, hipertensión). Las técnicas de preprocesamiento más utilizadas son SMOTE, estandarización y eliminación/imputación de valores. Las técnicas más usadas para identificar el riesgo de sufrir ACV son *support vector machine*, *random forest*, *logistic regression*, *naive Bayes*, *k-nearest neighbors* y *decision tree*.

PALABRAS CLAVE: accidente cerebrovascular, modelos, aprendizaje automático, riesgo, identificación

1. INTRODUCTION

Cerebrovascular accident (CVA) or stroke is an acute phenomenon that occurs due to obstructions that prevent blood flow to the brain (World Health Organization, 2021). Factors such as smoking, overweight or obesity, as well as high cholesterol and glucose levels, influence this disease (Sarfo et al., 2022). It is estimated that approximately one out of four people will be prone to a stroke after the age of 25 (The GBD 2016 Lifetime Risk of Stroke Collaborators et al., 2018). Each year, stroke affects approximately 15 million people and 5 million of this group become disabled (World Health Organization Regional Office for the Eastern Mediterranean, n.d.).

In Peru, there has been an increase in stroke cases, and they are being considered one of the main causes of permanent disability in adults (Bernabé-Ortiz & Carrillo-Larco, 2021). The sequelae of this disease have an economic and health impact, affecting the quality of life of patients (Langhorne et al., 2000). According to studies conducted in the United States, the costs related to medical care, medications and loss of productivity reach significant figures (King et al., 2020).

Early detection and prevention of strokes are essential to reduce their impact. Identifying symptoms, such as vision problems as well as difficulty walking, reading or speaking, is crucial to seek help immediately (Centers for Disease Control and Prevention, 2022). It is estimated that about 80 % of strokes are preventable (Linn et al., 2014). In addition, researches that apply classification algorithms to identify stroke risk and related diseases have been conducted.

Different studies, including those carried out by Chantamit-o-pas and Goyal (2017), Alaa et al. (2019), Mohan et al. (2019), among others, have compared and evaluated the performance of various machine learning (ML) algorithms in predicting stroke risk. Some of these algorithms include deep learning (DL), naive Bayes (NB), support vector machine (SVM), random forest (RF), artificial neural network (ANN), adaptive boosting (AdaBoost) and gradient boosting (GB).

There is a gap in research conducted in Peru with respect to life cycle assessment (LCA) and ML. According to Chantamit-o-pas and Goyal (2017), future work using more risk factors is recommended. On the other hand, Dritsas and Trigka (2022) propose imaging-based studies and the use of DL techniques for stroke detection. However, so far, studies comparing and implementing ML algorithms to identify stroke risk have been mainly undertaken in countries such as the United States, England and China.

Unfortunately, no studies have been carried out for risk identification using ML algorithms based on Peruvian patient medical records, despite the fact that this population is also affected by strokes. Even the projects of the Peruvian Ministry of Health (MINSA) for the years 2020 to 2025 do not contemplate the use of ML for disease risk identification (Ministerio de Salud del Perú, 2020).

Castañeda-Guarderas et al. (2011) conducted a study that analyzed reports of stroke incidence in patients at the Cayetano Heredia Hospital between 2000 and 2009. In this study, arterial hypertension, atrial fibrillation and type 2 diabetes mellitus were identified as the most common associated conditions. One of the recommendations was to establish measures and interventions to reduce the mortality rate, prevent new events and improve patient outcomes.

Based on this context, the following research question arises: how has the application of machine learning algorithms in stroke risk detection been addressed in various studies?

In line with this, the overall objective of the present study is to perform a systematic review of studies related to the identification of stroke using ML. In addition, the following specific objectives are proposed: to identify the variables that significantly influence stroke risk, to identify the most appropriate preprocessing techniques, and to identify the characteristics of the most effective ML techniques. This compilation article is intended to provide an overview of the studies undertaken to date, providing a concise basis for achieving the abovementioned objectives.

2. METHODOLOGY

A systematic review of the literature was carried out with the purpose of identifying and analyzing relevant studies related to stroke risk identification using ML techniques. The main objective of this research was to gather detailed information on the most common risk factors, data preprocessing techniques and both risk identification algorithms and their major characteristics.

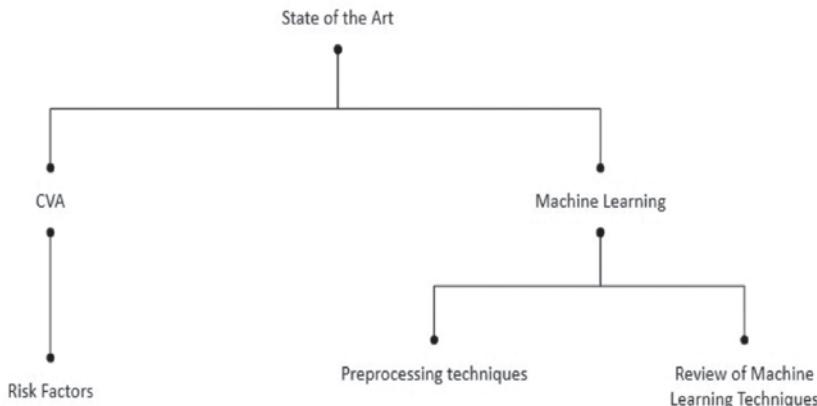
To perform the exhaustive search for studies, the renowned databases Web of Science and Scopus were accessed. The keywords “stroke,” “risk” and “machine learning” in combination with Boolean operators were used to identify relevant studies. Inclusion criteria include studies related to the implementation of ML techniques for stroke risk identification and studies addressing risk factors with a more health-related approach.

Once the relevant studies were identified, relevant information was extracted using a data extraction matrix. The extracted data was analyzed using a descriptive approach, focusing especially on the comparison of the techniques used in stroke risk identification. The results were presented in a clear and concise manner using comparison tables that summarized the risk factors, preprocessing techniques and identification algorithms used in the reviewed studies.

3. RESULTS

This section presents a structured analysis of the literature reviewed and includes two subsections: one directly related to LCA, which contains the identified risk factors, and the other to ML. In turn, this subsection contains two subdivisions, i.e., one referred to data preprocessing techniques and the other to ML techniques for LCA identification. The sections are displayed in Figure 1.

Figure 1
Map of the structure of the state of the art



3.1 CVA

CVA is a complex disease and one of the leading causes of mortality in the adult population. Several factors are known to influence patient risk, including demographic variables, comorbidities or genetics (Torres-Aguila et al., 2019).

3.1.1 Risk factors

Before collecting patient medical records to identify stroke risk, it is necessary to know which variables influence the risk for this disease. This subsection shows the factors found in articles focused on predicting strokes with ML. Subsequently, another list of variables gathered from articles focused on the factors found in recent years is presented.

Table 1 shows the variables included in some of the datasets used to identify stroke risk with ML from the literature review. As shown, all the datasets include variables such as age, sex and comorbidities. However, some of these differ in taking into account variables concerning patient habits such as lifestyle, tobacco or alcohol consumption. Furthermore, according to the dataset analyzed in the study by Hippisley-Cox et al. (2017), family history also affects stroke risk.

In Table 2, information on risk factors with a more medical approach was systematized. Therefore, these factors have less presence in the collected datasets. However, the articles found highlight their importance.

Table 1
Datasets used for CVA risk identification

Authors	Source	Number	Data
Dritsas and Trigka (2022)	Stroke Prediction Dataset – Kaggle	5 110	Sex, age, hypertension, heart disease, married, occupational status, residence, glucose, BMI, smoking.
Tazin et al. (2021)			
Ahammad (2022)			
Chantamit-o-pas and Goyal (2017)	UCI Machine Learning Repository	899	Age, sex, blood pressure, chest pain, smoking, family history, hypertension, cholesterol, pulse, blood vessels.
Khdair and Dasari (2021)	South African Heart Disease – KEEL Repository	462	Systolic blood pressure, smoking, LDL cholesterol, adiposity, family history, type A behavior, obesity, alcohol, age, coronary artery disease.
Qu et al. (2022)	Shenzhen Hospital of Guangzhou University of Chinese Medicine	711	Age, sex, smoking, alcoholic beverage intake, medical history, weight, height, blood pressure, BMI, cholesterol, triglycerides, glucose, hemoglobin, among others.
Jabal et al. (2022)	Patients from two academic centers	443	Age, sex, accident scale comorbidities, diabetes, hypertension, hyperlipidemia, blood glucose levels, blood pressure.

Table 2
Risk factors according to studies with a medical approach

Authors	Factors	Study Subject	Findings
Torres-Aguila et al. (2019)	Leukoaraiosis, other clinical complications, blood components, acute treatments, neurological complications, genetic factors.	General population	Age and sex, which are used as covariates in association studies such as GWAS, had a very weak influence, at least in the short term.
Zhang et al. (2019)	Atrial fibrillation, heart failure, hypertension, genetic factors, chronic kidney disease, obstructive sleep apnea, migraine with aura, work environment, air pollution.	General population	Internal and external risk factors are important for stroke prevention. More importantly, a thorough understanding of each risk factor provides specific guidance in practice.

According to the comprehensive literature review, twelve of the articles showed these variables: age, sex and diseases. The disease most frequently repeated as a variable in the datasets was hypertension.

Although the three abovementioned variables are the most common ones, according to Torres-Aguila et al. (2019), age and sex had a very weak influence on stroke risk. The newly identified characteristics, as shown in Table 2, are work environment and air pollution. These, despite having significance, were not included in the found datasets.

In summary, stroke risk factors can be classified into modifiable and non-modifiable. The main non-modifiable factors are usually sex and family history. On the other hand, the main modifiable factors are associated with the patients' health status, such as arterial hypertension, diabetes and hypercholesterolemia, and to habits such as alcohol and tobacco consumption.

3.2 Machine learning

Data processing is crucial for any application process with ML algorithms. This section gathers information on processing techniques and algorithms used for LCA risk identification with ML.

3.2.1 Preprocessing Techniques

In order to implement the techniques for the identification of stroke or similar diseases, it is necessary to preprocess the data. These techniques are useful to perform a correct and adequate training of algorithms since they can present null values, outliers, values with a format that is not in accordance with the type of variables used and can cause the results to be erroneous. Table 3 shows the main preprocessing techniques in the literature reviewed.

Table 3
Data preprocessing techniques used for CVA risk identification

Authors	Technique	Purpose
Mohan et al. (2019)	Removal of data with missing values, multiclass and binary classification.	Edit missing values.
Dritsas and Trigka (2022)	Redundant data reduction, variable selection, data discretization, resampling method.	Avoid degradation of prediction accuracy.
Chen et al.(2022)	Missing data processing: continuous variables were filled with linear imputation and categorical variables with mode.	Edit missing values.
Shoily et al. (2019)	Data standardization.	Work with quantitative data.
Tazin et al. (2021)	Missing data analysis, data balancing, one-hot encoding. Use of SMOTE.	Remove unnecessary data for better efficiency, convert qualitative variables into numbers for training, eliminate null values.

continues

continued

Authors	Technique	Purpose
Nusinovici et al. (2020)	Missing data imputation, multicollinearity, dummy variables for categorical factors.	Ensure better accuracy.
Lin et al. (2020)	LOWESS and standard deviation.	Eliminate illogical evaluations and adjust quantities to the same scale.
Qin et al. (2021)	Data standardization, SMOTE, hyperparameter optimization.	Normalize, balance and produce the best performance.
Zhang et al. (2022)	Elimination of variables with more than 30% missing data and R method.	Eliminate inconsistencies and identify correlated variables.

The findings in the table reveal a number of common techniques used in machine learning data preprocessing. Among the most recurrent techniques are missing data imputation, data standardization, redundant data removal, data balancing and variable selection. Mohan et al. (2019) focus on removing data with missing values to improve data integrity, while Shoily et al. (2019) advocate data standardization, which facilitates quantitative data analysis. Dritsas and Trigka (2022) prioritize redundant data reduction and variable selection as key approaches to maintain prediction accuracy. Tazin et al. (2021) emphasize the importance of data balancing, while Qin et al. (2021) focus on hyperparameter optimization. These techniques are applied in different contexts, contributing significantly to the quality of the results obtained in the process of data preparation for machine learning models. In summary, these findings underline the critical importance of data preprocessing in improving data quality, which is supported by the research of the aforementioned authors.

3.2.2 Techniques for CVA identification

In the literature reviewed, a number of different algorithms and techniques have been implemented for stroke risk identification. Depending on the authors and the proposed objectives, these techniques can be evaluated individually to test their performance. This individual evaluation occurs mainly when the authors develop a hybrid algorithm, such as that of Zhang et al. (2022), who implemented a model based on logistic regression (LR), ANN, RF and GB.

Another measure of evaluation occurs when the authors compare techniques to demonstrate which one is the best performing. Comparative articles are presented in most of the literature reviewed. Among them is Dritsas and Trigka (2022), who used a dataset with 5110 records and 11 features from the Kaggle platform. The authors compared more than five ML models, including NB, LR, RF and Stacking, in order to determine which one was the best performing in identifying stroke risk. As a result, the stacking method performed better on the basis of the area under the curve (AUC).

Another application of comparative articles can be seen in the work of Liu et al. (2021), whose main objective was to identify the main risk factors for stroke in a province in China. For this

purpose, they had two datasets. One contained 2000 records of stroke patients and the other one more than 27 000 records from a stroke prevention project in China. They were categorized into low risk, medium risk and high risk. Both datasets had more than 100 features. In order to meet their goal, they implemented decision tree (DT) and RF models. The DT algorithm showed that the main features were hypertension, physical inactivity and diabetes mellitus. While RF showed that the main features were hypertension, hyperlipidemia and physical inactivity.

As can be seen, the applications of the techniques are diverse. In the literature reviewed, some preference was observed for SVM, LR, NB, K-Nearest Neighbor (KNN), RF and DT.

As for SVM, Sailasya and Kumari (2021), Ahammad (2022) and Khdaire and Dasari (2021) chose this technique because it is useful for classification and regression of variables. In addition, Dinesh et al. (2018) claimed that this model is quite well known and used due to its efficiency. However, Ahammad (2022) acknowledged that its performance may decrease in datasets with a large number of variables. In turn, it can be observed that in the article by Nusinovici et al. (2020) the SVM showed the lowest AUC among the other models. The implemented dataset contains more than 10 000 records. Similarly, in the paper by Alaa et al. (2019), where the implemented dataset consisted of more than 400 000 records, the SVM accounted for the lowest AUC. On the other hand, the work of Mohan et al. (2019), where the dataset consisted of 303 records, the SVM algorithm obtained an average value among the other records. One contrast to mention is the paper by Lin et al. (2020), whose dataset consisted of more than 58 000 records and the SVM algorithm showed the best result. This may be due to the variables implemented.

Regarding the LR model, Dritsas and Trigka (2022), Khdaire and Dasari (2021) and Sailasya and Kumari (2021) highlighted its usefulness for binary classifications; Dinesh et al. (2018) agreed with the authors and added the efficiency of the model. However, they mentioned that, in case more variables were present, multinomial logistic regression was applied. Furthermore, Tazin et al. (2021) added that this model was quite widely used for the prediction of dichotomous variables.

Giving a focus on the NB model, Dinesh et al. (2018) mentioned that it is one of the best ML classification options due to its scalability. Furthermore, Dritsas and Trigka (2022) observed that it ensures the maximization probability according to the independence of the variables. Likewise, Shoily et al. (2019) claimed about its ease of use, its simplicity of handling when multiple variables are present, as well as its scalability and efficiency with discrete and continuous data. However, they remarked that it performs better on small datasets. Regarding the last point, no cases can be provided to support Shoily et al. (2019) except that the model has had average results in the different metrics.

The KNN model, according to Shoily et al. (2019), is the simplest algorithm because it does not require training. Moreover, Ahammad (2022) claimed that, by requiring a k value in order to calculate the nearest neighbors, it could be complicated in large datasets.

Dritsas and Trigka (2022) stated that RF creates a subset of instances for classification and regression tasks. For that reason, it is optimal in jobs. Tazin et al. (2021) performed a correlation between that mentioned by Dinesh et al. (2018) and the algorithm logic and explained that RF creates different decision trees per attribute. In addition, it can take care of data preprocessing. Dritsas and Trigka (2022) added that these trees are created during training. Moreover, they highlighted the flexibility of this model. Likewise, Ahammad (2022) highlighted the efficiency of RF with numerical and categorical variables; however, he pointed out that predictions may take time at the training stage.

Concerning the DT algorithm, Tazin et al. (2021) emphasized its usefulness for regression and classification. In addition, they alluded to its simplicity of understanding and replication and commented that one of its characteristics is its support for decision-making and the low need for data cleaning. Dritsas and Trigka (2022) complemented this point of view by saying that DT gives support in the reduction of errors as the model is built. Nikam et al. (2020) added that DT organizes features into different targets. Mohan et al. (2019) also highlighted the speed and simplicity of its implementation. On the other hand, Ahammad (2022) stated that the algorithm can obtain a good accuracy depending on the dataset. However, he detailed that it may present delays if the dataset is large.

Table 4 presents the main characteristics of the ML techniques found in the literature review.

Table 4

Advantages and disadvantages of machine learning techniques for CVA risk identification

ML Algorithm	Advantages	Disadvantages
SVM	Useful for classification and regression of variables.	Performance may decrease in datasets with large number of variables.
LR	Useful for binary classifications.	Need for multinomial logistic regression for multiple variables.
NB	Ease of use, scalability, efficiency with discrete and continuous data.	Not specified.
KNN	Simplicity, as it does not require a prior training process.	In large datasets, the choice of a K value in KNN can be complicated.
RF	Optimal performance in creating subsets of instances, flexibility in model building, efficiency with numerical and categorical variables	At the training stage, predictions may experience delays.
DT	Useful in regression and classification, easy to understand and replicate, low need data cleaning.	May experience delays when the dataset is large.

4. DISCUSSION

With respect to the section on risk factors, it should be noted that the authors agree on various characteristics, including age, sex, hypertension, among others. In addition, there are non-modifiable factors such as age, sex and family history, and modifiable factors such as arterial hypertension, diabetes, hypercholesterolemia and habits, including alcohol and tobacco consumption. It is worth mentioning that the need to explore the patient's medical history should be evaluated, since some diseases or comorbidities that are not so frequently observed should be considered in order to better identify the risk of suffering a CVA.

In the section on preprocessing techniques, which are fundamental for obtaining satisfactory results in identifying CVA risk, the discussion highlights the importance of similarities among the implemented techniques, as well as the need to evaluate and perform an exploratory analysis on the dataset. This ensures the implementation of appropriate preprocessing techniques aligned with the research objectives. For example, at the moment of carrying out a research work related to the exposed topic, it is recommended to analyze in the dataset the null values, distribution of variables, standardization and the need to perform data balancing, which are the characteristics of the datasets most frequently addressed in the present research. As a solution, techniques such as data elimination, standardization and data balancing are used.

In the section on implementation techniques, the SVM, LR, RF and NB algorithms are the ones that showed the best performance. It should be noted that these algorithms displayed a lower performance than usual in few works due to dataset characteristics such as its dimensions and the preprocessing techniques used. Even so, these techniques can be a useful tool in future research works considering the size of the dataset and the objective of the work to be developed.

5. CONCLUSIONS

This study aimed to carry out a systematic compilation of articles related to stroke and related diseases. It was found that the main risk factors for stroke are age, sex, hypertension, blood pressure, smoking, alcohol consumption, family history and hypercholesterolemia. In addition, the research showed that the main preprocessing techniques are SMOTE, standardization and value elimination/imputation. These techniques can be developed with different tools. Also, it introduced the most commonly used identification techniques: SVM, RF, LR, NB, KNN and DT. These findings can serve as a guide for future empirical research to identify the risk of CVA.

REFERENCES

- Ahammad, T. (2022). Risk factors identification for stroke prognosis using machine-learning algorithms. *Jordanian Journal of Computers and Information Technology*, 8(3), 282-296. <https://doi.org/10.5455/jjcit.71-1652725746>

- Alaa, A. M., Bolton, T., Di Angelantonio, E., Rudd, J. H., & Van Der Schaar, M. (2019). Cardiovascular disease risk prediction using automated machine learning: A prospective study of 423 604 UK Biobank participants. *PLOS ONE*, 14(5), e0213653. <https://doi.org/10.1371/journal.pone.0213653>
- Bernabé-Ortíz, A., & Carrillo-Larco, R. M. (2021). Tasa de incidencia del accidente cerebrovascular en el Perú. *Revista Peruana de Medicina Experimental y Salud Pública*, 38(3), 399-405. <https://dx.doi.org/10.17843/rpmesp.2021.383.7804>
- Castañeda-Guarderas, A., Beltrán-Ale, G., Casma-Bustamante, R., Ruiz-Grosso, P., & Málaga, G. (2011). Registro de pacientes con accidente cerebro vascular en un hospital público del Perú, 2000-2009. *Revista Peruana de Medicina Experimental y Salud Pública*, 28(4), 623-627. http://www.scielo.org.pe/scielo.php?script=sci_arttext&xpid=S1726-46342011000400008
- Centers for Disease Control and Prevention (2022). Stroke signs and symptoms. https://www.cdc.gov/stroke/signs_symptoms.htm.
- Chantamit-o-pas, P., & Goyal, M. (2017). Prediction of stroke using deep learning model. In D. Liu, S. Xie, Y. Li, D. Zhao, & E. S. El-Alfy (Eds), *Neural Information Processing* (pp. 774-781). Springer. https://doi.org/10.1007/978-3-319-70139-4_78
- Chen, S. D., You, J., Yang, X. M., Gu, H. Q., Huang, X. Y., Liu, H., ... & Wang, Y. J. (2022). Machine learning is an effective method to predict the 90-day prognosis of patients with transient ischemic attack and minor stroke. *BMC Medical Research Methodology*, 22(1), 1-11. DOI: 10.1186/s12874-022-01672-z
- Dinesh, K., Arumugaraj, K., Santhosh, K. D., & Mareeswari, V. (2018). Prediction of cardiovascular disease using machine learning algorithms. *2018 International Conference on Current Trends Towards Converging Technologies (ICCTCT)*. <https://doi.org/10.1109/icctct.2018.8550857>
- Dritsas E, Trigka M. (2022) Stroke risk prediction with machine learning techniques. *Sensors*, 22(13), 4670. doi: 10.3390/s22134670
- Hippisley-Cox, J., Coupland, C., & Brindle, P. (2017). Development and validation of QRISK3 risk prediction algorithms to estimate future risk of cardiovascular disease: Prospective cohort study. *BMJ*, 357: j2099. <https://doi.org/10.1136/bmj.j2099>
- Jabal, M. S., Joly, O., Kallmes, D., Harston, G., Rabinstein, A., Huynh, T., & Brinjikji, W. (2022). Interpretable machine learning modeling for ischemic stroke outcome prediction. *Frontiers in Neurology*, 13, 884693. <https://doi.org/10.3389/fneur.2022.884693>
- Khdair, H., & Dasari, N. M. (2021). Exploring machine learning techniques for coronary heart disease prediction. *International Journal of Advanced Computer Science and Applications*, 12(5), 28-36. <http://dx.doi.org/10.14569/IJACSA.2021.0120505>

- King, D., Wittenberg, R., Patel, A., Quayyum, Z., Berdunov, V., & Knapp, M. (2020). The future incidence, prevalence and costs of stroke in the UK. *Age and ageing*, 49(2), 277-282. <https://doi.org/10.1093/ageing/afz163>
- Langhorne, P., Stott, D. J., Robertson, L., MacDonald, J., Jones, L., McAlpine, C., Dick, F., Taylor, G. S., & Murray, G. (2000). Medical complications after stroke: A multicenter study. *Stroke*, 31(6), 1223-1229. <https://doi.org/10.1161/01.str.31.6.1223>
- Lin, C. H., Hsu, K. C., Johnson, K. R., Fann, Y. C., Tsai, C. H., Sun, Y., Lien, L. M., Chang, W. I., Chen, P. L., Lin, C. L., Hsu, C. Y., & Taiwan Stroke Registry Investigators (2020). Evaluation of machine learning methods to stroke outcome prediction using a nationwide disease registry. *Computer Methods and Programs in Biomedicine*, 190, 105381. <https://doi.org/10.1016/j.cmpb.2020.105381>
- Linn, L., Eberwine, D., & Oliel, S. (2014, May 15). La OPS/OMS insta a las personas en las Américas a chequear su presión arterial para prevenir infartos y accidentes cerebrovasculares. Organización Panamericana de la Salud. <https://www.paho.org/es/enlace/hipertension>
- Liu, J., Sun, Y., Ma, J., Tu, J., Deng, Y., He, P., Li, R., Hu, F., Huang, H., Zhou, X., & Xu, S. (2021). Analysis of main risk factors causing stroke in Shanxi province based on machine learning models. *Informatics in Medicine Unlocked*, 26, 100712 <https://doi.org/10.1016/j.imu.2021.100712>
- Ministerio de Salud del Perú (2020). Agenda digital del sector salud 2020-2025. <http://bvs.minsa.gob.pe/local/MINSA/5165.pdf>
- Mohan, S., Thirumalai, C., & Srivastava, G. (2019). Effective heart disease prediction using hybrid machine learning techniques. *IEEE Access*, 7, 81542-81554. <https://doi.org/10.1109/access.2019.2923707>
- Nikam, A., Bhandari, S., Mhaske, A., & Mantri, S. (2020). Cardiovascular disease prediction using machine learning models. *2020 IEEE Pune Section International Conference (PuneCon)*, 22-27. <https://doi.org/10.1109/punecon50868.2020.9362367>
- Nusinovici, S., Tham, Y. C., Yan, M. Y. C., Ting, D. S. W., Li, J., Sabanayagam, C., Wong, T. Y., & Cheng, C. (2020). Logistic regression was as good as machine learning for predicting major chronic diseases. *Journal of Clinical Epidemiology*, 122, 56-69. <https://doi.org/10.1016/j.jclinepi.2020.03.002>
- Qin, Q., Zhou, X., & Jiang, Y. (2021). Prognosis prediction of stroke based on machine learning and explanation model. *International Journal of Computers, Communications & Control*, 16(2), artículo 4108. <https://doi.org/10.15837/ijccc.2021.2.4108>
- Qu, Y., Zhuo, Y., Lee, J., Huang, X., Yang, Z., Yu, H., Zhang, J., Yuan, W., Wu, J., Owens, D., & Zee, B. (2022). Ischemic and haemorrhagic stroke risk estimation using a machine-learning-based retinal image analysis. *Frontiers in Neurology*, 13: 916966. <https://doi.org/10.3389/fneur.2022.916966>

- Sailasya, G., & Kumari, G. L. A. (2021). Analyzing the performance of stroke prediction using ML classification algorithms. *International Journal of Advanced Computer Science and Applications*, 12(6), 539-545. <https://doi.org/10.14569/ijacsa.2021.0120662>
- Sarfo, F. S., Ovbiagele, B., Akpa, O., Akpalu, A., Wahab, K., Obiako, R., Komolafe, M., Owolabi, L., Ogbole, G., Calys-Tagoe, B., Fakunle, A., Sanni, T., Mulugeta, G., Abdul, S., Akintunde, A. A., Olowookere, S., Uvere, E. O., Ibainiye, P., Akinyemi, J., ..., & SIREN. (2022). Risk factor characterization of ischemic stroke subtypes among West Africans. *Stroke*, 53(1), 134-144. <https://doi.org/10.1161/STROKEAHA.120.032072>
- Shoily, T. I., Islam, T., Jannat, S., Tanna, S. A., Alif, T. M., & Ema, R. R. (2019, July). Detection of stroke disease using machine learning algorithms. *2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, 1-6. <https://doi.org/10.1109/icccnt45670.2019.8944689>
- Tazin, T., Alam, M. N., Dola, N. N., Bari, M. S., Bourouis, S., & Khan, M. M. (2021). Stroke disease detection and prediction using robust learning approaches. *Journal of Healthcare Engineering*, 2021, 1-12. <https://doi.org/10.1155/2021/7633381>
- The GBD 2016 Lifetime Risk of Stroke Collaborators (2018, December 19). Global, regional, and country-specific lifetime risks of stroke, 1990 and 2016. *The New England Journal of Medicine*, 379(25), 2429-2437. <https://doi.org/10.1056/nejmoa1804492>
- Torres-Aguila, N. P., Carrera, C., Muiño, E., Cullell, N., Cárcel-Márquez, J., Gallego-Fabrega, C., González-Sánchez, J., Bustamante, A., Delgado, P., Ibanez, L., Heitsch, L., Krupinski, J., Montaner, J., Martí-Fàbregas, J., Cruchaga, C., Lee, J-M., Fernández-Cadenas, I., & Acute Endophenotypes Group of the International Stroke Genetics Consortium (ISGC) (2019). Clinical variables and genetic risk factors associated with the acute outcome of ischemic stroke: A systematic review. *Journal of Stroke*, 21(3), 276-289. <https://doi.org/10.5853/jos.2019.01522>
- World Health Organization (2021, June 11). *Cardiovascular diseases (CVDs)*. [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- World Health Organization Regional Office for the Eastern Mediterranean (n.d.). *Stroke, cerebrovascular accident*. <https://www.emro.who.int/health-topics/stroke-cerebrovascular-accident/index.html>
- Zhang, L., Niu, M., Zhang, H., Wang, Y., Zhang, H., Mao, Z., Zhang, X., He, M., Wu, T., Wang, Z., & Wang, C. (2022). Nonlaboratory-based risk assessment model for coronary heart disease screening: Model development and validation. *International Journal of Medical Informatics*, 162, 104746. <https://doi.org/10.1016/j.ijmedinf.2022.104746>
- Zhang, S., Zhang, W., & Zhou, G. (2019). Extended risk factors for stroke prevention. *Journal of the National Medical Association*, 111(4), 447-456. <https://doi.org/10.1016/j.jnma.2019.02.004>

Predicción de la estabilidad de voltaje en redes eléctricas inteligentes

Victor Gil-Vera

victor.gilve@amigo.edu.co

<https://orcid.org/0000-0003-3895-4822>

Universidad Católica Luis Amigó, Colombia

Recibido: 29/05/2023 / Aceptado: 02/09/2023

doi: <https://doi.org/10.26439/ciis2023.7082>

RESUMEN. Las redes eléctricas inteligentes son un sistema de transporte de electricidad eficiente que no afecta al medio ambiente. Una red inteligente se considera estable cuando puede mantener un funcionamiento confiable y consistente mientras gestiona de manera efectiva diversos factores que pueden provocar interrupciones o desequilibrios en ella. La estabilidad es importante, ya que todo el proceso de transmisión depende del tiempo. En este trabajo se emplea el *deep learning* para predecir la estabilidad en este tipo de redes. Se utilizó una base de datos balanceada y libre de 60 000 observaciones con información de consumidores y productores obtenida a partir de simulaciones. Se concluye que esta técnica obtuvo un alto desempeño (*accuracy* = 97,98 %), lo que permite afirmar que el *deep learning* se puede considerar con seguridad para esta tarea. La cantidad de épocas influyó significativamente en el desempeño de las redes neuronales artificiales (RNA): las que tenían arquitecturas más complejas presentaron un mejor *accuracy*.

PALABRAS CLAVE: análisis / inteligencia artificial / control / aprendizaje automático / red inteligente / estabilidad

PREDICTION OF VOLTAGE STABILITY IN SMART POWER GRIDS

ABSTRACT. Smart grids are a system of electricity transmission networks that enable efficient use of electricity without affecting the environment. A smart grid is considered stable when it can maintain reliable and consistent operation while effectively managing various factors that can cause outages or imbalances within the power grid, stability is important since the entire transmission process is time-dependent. In this work, Deep Learning is employed to predict stability in this type of network. A balanced and free database of 60,000 observations with consumer and producer information obtained from simulations was used. This work concludes that this technique obtained a high performance (Accuracy = 97.98 %), which allows us to affirm that Deep Learning can be safely considered for this task. The number of epochs significantly influenced the performance of the ANNs, those with more complex architectures presented a better Accuracy.

KEYWORDS: analysis / control / artificial intelligence / machine learning / stability / smart grid

1. INTRODUCCIÓN

Las redes inteligentes suministran electricidad de forma controlada y ofrecen una serie de ventajas, entre ellas un mayor crecimiento y una gestión eficaz de las fuentes de energía renovables (Lamnatou et al., 2022). Garantizan la transferencia de información y electricidad entre centrales eléctricas y dispositivos y se utilizan principalmente para resolver problemas relacionados con el suministro de energía (Sai Pandraju et al., 2022). También gestionan la demanda, preservan la red de distribución, reducen costos y ahorran energía (Stright et al., 2022). Una red inteligente es esencialmente un sistema que utiliza tecnología de punta, incluyendo tecnologías de la información y comunicación (TIC), líneas de transmisión, tecnologías de medición, control de generación, subestaciones, medidores y alimentadores, además de tecnologías en las instalaciones (Judge et al., 2022). Los objetivos de las redes inteligentes son: generar un rápido rendimiento en beneficio del consumidor final, reducir los cortes de energía, aumentar la seguridad y la eficiencia energética, reducir la contaminación, regular el consumo de energía y realizar cambios en la ruta de transmisión eléctrica, reducir la vulnerabilidad de las redes de transmisión ante ataques o fallos y facilitar su rápida localización en zonas urbanas y rurales (Panda & Das, 2021).

Garantizar la estabilidad de las redes inteligentes es crucial para mantener una distribución de energía confiable y eficiente (Omitaomu & Niu, 2021); para ello se debe evaluar la funcionalidad del diseño de la red para prever su estabilidad (Singh et al., 2014), lo que permite mitigar la inestabilidad causada por el aumento de las construcciones domésticas y comerciales conectadas a la red o la incorporación de energía verde en ella. Sin embargo, pronosticar la estabilidad del voltaje de las redes eléctricas inteligentes en diferentes condiciones es una tarea de gran complejidad.

Como se mencionó anteriormente, las redes inteligentes integran tecnologías avanzadas y sistemas de comunicación para mejorar la gestión y el control de la generación, distribución y consumo de electricidad. Entre los métodos actuales para garantizar la estabilidad de las redes eléctricas inteligentes frente a escenarios energéticos cambiantes y demandas crecientes, se encuentra el monitoreo y control en tiempo real. Es decir, la implementación de sensores, medidores e infraestructura de comunicación avanzados para monitorear continuamente las condiciones de la red. Estos datos permiten a los operadores identificar problemas y tomar decisiones informadas para evitar la inestabilidad (Ghafouri et al., 2020). Otra solución es el uso del *machine learning* (ML) para anticipar posibles interrupciones o desequilibrios en la red, pues —al analizar datos y patrones históricos— la red inteligente puede abordar los problemas de manera proactiva antes de que se agraven (Azad et al., 2019). Otra es la gestión de recursos energéticos distribuidos (DER, siglas en inglés de *distributed energy resources*), es decir, la incorporación de recursos como paneles solares, turbinas eólicas y sistemas de almacenamiento de energía. La gestión eficaz de estos recursos puede ayudar a equilibrar la oferta y la demanda, reduciendo la tensión en la red durante las horas pico (Massaoudi et al., 2021).

Otra solución es la implementación de programas de respuesta a la demanda que alienten a los consumidores a ajustar su consumo de energía durante períodos de alta demanda. Esto ayuda a prevenir sobrecargas de la red y minimiza la necesidad de medidas de emergencia (Shi et al., 2020). Una medida adicional es la creación de microrredes que puedan funcionar independientemente de la red principal durante emergencias o cortes. Las microrredes pueden garantizar el suministro de energía localizada y reducir el impacto de las perturbaciones en la red más grande (Yoldaş et al., 2017). Finalmente, también sería importante brindar capacitación a los operadores y al personal de mantenimiento para administrar y solucionar problemas de manera efectiva. La mano de obra calificada es esencial para mantener la estabilidad de este tipo de redes (Tufail et al., 2021).

Si bien las estrategias mencionadas anteriormente pueden mejorar la estabilidad de las redes inteligentes, también conllevan ciertas limitaciones y desafíos que deben abordarse, como por ejemplo los altos costos que requiere su implementación. Muchas de las tecnologías y actualizaciones de infraestructura necesarias para las redes inteligentes implican costos iniciales significativos, lo que puede representar un desafío para los gobiernos y las empresas de servicios públicos, especialmente en regiones con recursos financieros limitados (Ma et al., 2013). Garantizar la interoperabilidad entre varios dispositivos, sistemas y protocolos de comunicación es complejo y la falta de tecnologías estandarizadas puede generar problemas de compatibilidad y dificultar la integración perfecta de los componentes. Las redes inteligentes dependen en gran medida de las redes de comunicación para el intercambio de datos en tiempo real. Las fallas o interrupciones de la red pueden afectar su capacidad para operar sin problemas. Finalmente, la transición de redes tradicionales a redes inteligentes puede generar resistencia al cambio por parte de las partes interesadas que están acostumbradas a los sistemas y procesos existentes (Ayadi et al., 2019).

Reemplazar las redes eléctricas tradicionales por redes inteligentes ofrece varios beneficios importantes que pueden conducir a una distribución de electricidad más eficiente, confiable y sostenible. Entre estos beneficios se encuentran el mejoramiento de la eficiencia y la fiabilidad energética, la integración con energías renovables, beneficios económicos, generación de energía descentralizada y sostenibilidad ambiental. La adopción de redes inteligentes representa un cambio transformador de sistemas de energía tradicionales y centralizados a redes dinámicas e interconectadas que son capaces de satisfacer las demandas de un panorama energético que cambia rápidamente (Neffati et al., 2021).

En este trabajo se hace uso del *deep learning* para predecir la estabilidad de las redes inteligentes. Se utilizó una base de datos libre de 60 000 observaciones con información de consumidores y productores sobre doce características predictivas (tiempos de reacción, balances de potencia y coeficientes de elasticidad gama-precio) y una variable independiente (estable/inyestable). En la siguiente sección de este documento se presenta el marco teórico; en la tercera, generalidades sobre el *machine learning*; en la cuarta la metodología; en la quinta los

resultados y en la sexta, se discuten estos últimos y se los compara con experiencias similares. Por último, el documento ofrece algunas conclusiones.

2. MARCO TEÓRICO

Según Dileep (2020), el término *redes inteligentes* se refiere comúnmente a las alteraciones tecnológicas y comerciales de los sistemas eléctricos modernos y engloba todo lo que está integrado con ellas, lo que utiliza los servicios de la red y lo que interactúa con ella. Por otro lado, Muthamizh Selvam et al. (2016), las definen como un complejo sistema de subsistemas tecnológicos de comercialización de electricidad y de servicios articulados con los sectores empresarial, legislativo, político y social. En el aspecto técnico, las redes inteligentes incluyen las redes de transmisión y distribución, las instalaciones de producción, consumo y almacenamiento, así como los sistemas relacionados de toma de decisiones operativas y de inversión. También tienen fuertes conexiones con otras fuentes de energía, dominios a través del acoplamiento de sectores y la electrificación de dominios energéticos como la calefacción y refrigeración de edificios, el transporte y los procesos industriales (Yapa et al., 2021). Las redes inteligentes permiten la integración de tecnologías de generación de energía renovable a la red de transmisión, lo que posibilita un acceso eficiente y fiable a la energía con la integración de tecnologías informáticas y de comunicación digital (Mollah et al., 2021). La implantación de redes inteligentes viene motivada por la realidad en la que están inmersas las empresas de servicios públicos, junto con valores intrínsecos como la cultura empresarial, la madurez tecnológica y de procesos, el mercado actual, así como el escenario socioeconómico y medioambiental de su zona de concesión (Liu et al., 2022).

Una de sus principales características es la autocuración; es decir, pueden proporcionar una serie de beneficios que se prestan a un sistema más estable y eficiente. Dado que sus principales funciones incluyen el monitoreo y reacción en tiempo real, permiten que el sistema se ajuste constantemente a un estado óptimo (Fan et al., 2021). De hecho, gracias a la autorreparación, pueden reducir los cortes de energía y minimizar su duración cuando se producen, pueden detectar señales anómalas, realizar reconfiguraciones adaptativas y aislar las perturbaciones, eliminarlas o minimizarlas durante tormentas o catástrofes (Ashrafi et al., 2021).

Por otro lado, estas redes tienen capacidad de anticipación: buscan automáticamente problemas que podrían desencadenar perturbaciones mayores en el sistema y aíslan las partes de la red que experimentan fallos para evitar la propagación de cortes y permitir una restauración más rápida (Shobole & Wadi, 2021). Las redes inteligentes no solo proporcionan energía, sino también servicios que permiten el funcionamiento eficiente y seguro de un sistema eléctrico, mientras que las empresas de red mantienen el equilibrio del sistema, garantizan la estabilidad y la seguridad del suministro, conectan físicamente a productores y consumidores y permiten las transacciones de energía (Emmanuel et al., 2019). Entre los principales objetivos de las redes

inteligentes se encuentran: utilizar la infraestructura de transmisión existente de forma más eficiente, aumentar la capacidad de acogida de fuentes de energía renovables, vehículos eléctricos, bombas de calor y otras tecnologías de ahorro energético, mejorar el funcionamiento de los mercados energéticos y proporcionar una mayor flexibilidad a todas las partes interesadas, incluidos los agentes más pequeños, como los propietarios de recursos energéticos distribuidos (Ullah et al., 2021). La Figura 1 presenta los principales beneficios de las redes inteligentes.

Figura 1

Ventajas de las redes inteligentes

Redes eléctricas inteligentes	<table border="1" style="width: 100%; border-collapse: collapse;"> <tbody> <tr> <td style="padding: 5px;">Interacción</td><td style="padding: 5px;">- Mayor capacidad de interacción con el mercado energético y los usuarios.</td></tr> <tr> <td style="padding: 5px;">Autorreparación</td><td style="padding: 5px;">- Autorreparación y resiliencia ante el fracaso.</td></tr> <tr> <td style="padding: 5px;">Predicción</td><td style="padding: 5px;">- Pronóstico eficiente para un mejor almacenamiento.</td></tr> <tr> <td style="padding: 5px;">Seguridad</td><td style="padding: 5px;">- Mayor seguridad contra los ataques a la red eléctrica.</td></tr> <tr> <td style="padding: 5px;">Optimización</td><td style="padding: 5px;">- Optimización de la disponibilidad de los recursos y equipos.</td></tr> <tr> <td style="padding: 5px;">Coordinación</td><td style="padding: 5px;">- Gestión armoniosa de recursos, equipos y sistemas de información más allá de la distribución geográfica.</td></tr> <tr> <td style="padding: 5px;">Integración</td><td style="padding: 5px;">- Integración total de supervisión, control, protección, mantenimiento y envío.</td></tr> </tbody> </table>	Interacción	- Mayor capacidad de interacción con el mercado energético y los usuarios.	Autorreparación	- Autorreparación y resiliencia ante el fracaso.	Predicción	- Pronóstico eficiente para un mejor almacenamiento.	Seguridad	- Mayor seguridad contra los ataques a la red eléctrica.	Optimización	- Optimización de la disponibilidad de los recursos y equipos.	Coordinación	- Gestión armoniosa de recursos, equipos y sistemas de información más allá de la distribución geográfica.	Integración	- Integración total de supervisión, control, protección, mantenimiento y envío.
Interacción	- Mayor capacidad de interacción con el mercado energético y los usuarios.														
Autorreparación	- Autorreparación y resiliencia ante el fracaso.														
Predicción	- Pronóstico eficiente para un mejor almacenamiento.														
Seguridad	- Mayor seguridad contra los ataques a la red eléctrica.														
Optimización	- Optimización de la disponibilidad de los recursos y equipos.														
Coordinación	- Gestión armoniosa de recursos, equipos y sistemas de información más allá de la distribución geográfica.														
Integración	- Integración total de supervisión, control, protección, mantenimiento y envío.														

En una red inteligente, la información sobre la demanda de los consumidores se recoge, se evalúa de forma centralizada con respecto a las condiciones de suministro y se envía a los clientes una propuesta de precios para que decidan su consumo (Babar et al., 2020). Debido a que todo el proceso depende del tiempo, la estimación dinámica de la estabilidad de la red se convierte no solo en una preocupación, sino en un requisito. Por ello, es importante comprender y anticipar las perturbaciones y fluctuaciones en el consumo y la producción de energía introducidas por los participantes del sistema de forma dinámica, considerando no solo los aspectos técnicos, sino también cómo responden los participantes a los cambios en los precios de la energía (Babar et al., 2020). En la explotación y planificación de los sistemas eléctricos, la evaluación y predicción dinámicas de la seguridad son fundamentales para garantizar el suministro ininterrumpido de electricidad a los consumidores y mejorar la fiabilidad del sistema (Mukherjee & De, 2020). La estabilidad se refiere a la capacidad de las redes inteligentes para mantener el equilibrio a lo largo del tiempo, es decir, evitar apagones, independientemente de la demanda de los consumidores (Tiwari et al., 2022). En todo el mundo, en los sistemas de distribución y generación de energía eléctrica se emplean frecuencias que oscilan entre 50 Hz y 60 Hz. La frecuencia de la señal eléctrica aumenta en épocas de exceso de generación, mientras que disminuye en épocas de subproducción. Por lo tanto, medir la frecuencia de la red en las instalaciones de cada cliente es suficiente para proporcionar al gestor la información necesaria sobre el balance energético actual de la red, para que pueda tarificar su suministro energético e informar a los consumidores (Yapa et al., 2021).

3. MACHINE LEARNING

El *machine learning* (ML), junto con la analítica de datos, son campos de estudio interdependientes e interrelacionados que se centran en la adquisición de conocimiento decisivo (Zhang et al., 2020). Los modelos predictivos se utilizan para aprender patrones a partir de datos, de dos formas: aprendizaje supervisado o no supervisado. El primero parte de un conjunto de datos etiquetados —es decir, se conoce el valor de la variable objetivo—, mientras que en el segundo los datos no están etiquetados; es decir, no se conoce el valor de la variable objetivo (Ibrahim et al., 2020). El ML implica la creación de modelos que se construyen con datos de entrenamiento y se validan con datos de prueba. Actualmente, el ML está siendo ampliamente utilizado en diferentes ramas del conocimiento para realizar predicciones y facilitar la toma de decisiones, gracias a que permite que las máquinas descubran cómo pueden realizar tareas sin estar explícitamente programadas para ello (Lei et al., 2020). Para tareas sencillas, es factible crear algoritmos que indiquen a la máquina cómo ejecutar los pasos necesarios para resolver un problema, pero, para tareas con un mayor grado de complejidad, es más efectivo ayudar a la máquina a desarrollar su propio algoritmo en lugar de especificar cada paso (Kotsopoulos et al., 2021). El ML se puede utilizar para la clasificación y la regresión: en la primera se pretende predecir la pertenencia a una clase o etiqueta, en la segunda se pretende predecir un valor numérico.

El *deep learning* (DL) es un subcampo del ML que se centra en el uso de redes neuronales artificiales (RNA) con múltiples capas (arquitecturas profundas) para aprender automáticamente jerarquías de características a partir de los datos. Los modelos de DL pueden aprender automáticamente patrones y representaciones complejas a partir de datos sin procesar, sin necesidad de una extensa ingeniería de funciones manual. El DL se inspiró en la forma en que funciona el cerebro humano, por lo tanto, al utilizar una malla de capas, cada una toma información diferente que generará resultados que luego servirán para nuevos cálculos (Heidari et al., 2019). En la ecuación (1) se presenta la ecuación general de una RNA.

$$\text{Output} = \sum_{i=1}^n W_i \cdot X_t + \text{bias} \quad (1)$$

En (1), *output* es la salida de la neurona, y la función de activación (ReLU, sigmoide, tanh) incorpora la no linealidad al modelo. La suma de los pesos es el producto de los valores de entrada y los productos de los pesos correspondientes. Además, la suma ponderada incluye un término constante llamado sesgo.

4. METODOLOGÍA

Los datos empleados provienen de los resultados de simulaciones de la estabilidad de una red en estrella de cuatro nodos de referencia, es decir, tres nodos de consumo y un nodo de generación, tal y como se presenta en la Figura 2.

Figura 2

Red inteligente en estrella de cuatro nodos



Para construir los modelos se utilizó una base de datos gratuita de Kaggle¹. El conjunto de datos contiene 60 000 observaciones, doce características predictivas primarias y una variable dependiente (estable/inestable). Los valores de ambas clases estaban balanceados. Como los datos tenían rangos variables, se utilizó la función *standarscaler* de *sklearn* para normalizar los datos. Esta función lleva todas las variables a la escala 0-1 para eliminar los problemas asociados a la escala de los datos; es decir, que los modelos no generen una buena predicción porque existen diferencias muy grandes en los rangos de variación de las variables. Es necesario aclarar que cada observación proviene de una simulación, no hay valores perdidos y todas las características son numéricas. La Tabla 1 presenta las variables consideradas.

Tabla 1
Base de datos

Variable	Descripción
staf	Variable objetivo (inestable=0 / estable=1)
stafb	Parte real máxima de la raíz de la ecuación diferencial característica
tau1	Tiempo de reacción - productor de energía

(Continúa)

1 Accesible desde el siguiente enlace: <https://www.kaggle.com/datasets/pcbreviglieri/smart-grid-stability>

(Continuación)

Variable	Descripción
tau2	Tiempo de reacción - consumidor 1
tau3	Tiempo de reacción - consumidor 2
tau4	Tiempo de reacción - consumidor 3
p1	Balance de energía - productor de energía
p2	Balance de energía – consumidor 1
p3	Balance de energía – consumidor 2
p4	Balance de energía – consumidor 3
g1	Coeficiente de elasticidad de precios (gamma) - productor de energía
g2	Coeficiente de elasticidad de precios (gamma) – consumidor 1
g3	Coeficiente de elasticidad de precios (gamma) – consumidor 2
g4	Coeficiente de elasticidad de precios (gamma) – consumidor 3

El tiempo de reacción se refiere al tiempo de respuesta de los participantes de la red para ajustar el consumo o la producción en respuesta a cambios en el precio. El balance de potencia se refiere a la potencia nominal producida o consumida en cada nodo de la red.

El coeficiente de elasticidad del precio se refiere a la variación porcentual de la demanda de electricidad en respuesta a pequeñas variaciones porcentuales en el precio. Las RNA fueron entrenadas en Python utilizando Google Colab. Esta herramienta proporciona máquinas virtuales gratuitas con tarjetas gráficas para realizar algoritmos de ML y tiene la misma potencia que plataformas como Azure o Amazon Web Services. Estas máquinas virtuales de Google se reinician cada doce horas, permiten ejecutar y programar en Python en un navegador web, no requieren configuración, permiten el acceso gratuito a unidades de procesamiento gráfico (GPU) y permiten compartir contenidos. Puede ser utilizada por estudiantes, científicos de datos o investigadores de inteligencia artificial. En el siguiente enlace se encuentra disponible el cuaderno de Colab donde se realizó la construcción del modelo de *deep learning* y la validación cruzada: https://colab.research.google.com/drive/1tLhnnotuNNnUXYjcQkF_BoTtyyLp86v

Antes de construir el modelo, se verificó la correlación entre cada característica numérica y la variable dependiente (“stabf”), así como la correlación entre las características numéricas que conducen a una posible colinealidad no deseada. La Figura 3 presenta un mapa de calor que ofrece una visión general de la correlación entre la variable dependiente y las doce características numéricas. La correlación entre p1 y sus componentes p2, p3 y p4 está por encima de la media, pero no es tan alta como para justificar su eliminación.

Figura 3
Mapa de calor



La Tabla 2 presenta la arquitectura de la RNA óptima empleada en este trabajo. A pesar de que los datos se comportan bien y se distribuyen uniformemente, se propone un ajuste basado en la validación cruzada KFold con diez conjuntos de validación diferentes. Se empleó la función relu como función de activación para las capas ocultas y la sigmoide para la capa de salida por tratarse de una clasificación binaria (estable/ inestable). Como optimizador adam y como función de pérdida binary_crossentropy. El desempeño se evaluará haciendo uso de la métrica *accuracy*.

Tabla 2*Configuración de la RNA*

Capa	Unidades	Inicializador kernel	Activación
1	24	Uniforme	relu
2	24	Uniforme	relu
3	12	Uniforme	relu
Salida	1	Uniforme	sigmoide

La métrica accuracy(2) puede ser obtenida de la matriz de confusión en la Tabla 3. TN son los valores que fueron negativos en la predicción y también fueron negativos en los valores reales. TP son los valores que fueron positivos en la predicción y también fueron positivos en los valores reales. FN son los valores que fueron negativos en la predicción y no fueron negativos en los valores reales. Y FP son los valores que fueron positivos en la predicción y no fueron positivos en los valores reales.

Tabla 3*Matriz de confusión*

Valores		Valores predichos	
		negativo	positivo
negativo	verdadero-negativo	falso-positivo	
	falso-negativo	verdadero-positivo	

Accuracy: % de predicciones correctas:

$$\text{Accuracy} = \frac{(TP+TN)}{\text{Total}} \quad (2)$$

Los resultados de la métrica *accuracy* en cada conjunto de validación KFold [1-10], se presentan en la Tabla 4.

Tabla 4*Resultados de la validación cruzada*

k-Fold	1	2	3	4	5	6	7	8	9	10
Accuracy	0,963	0,975	0,975	0,982	0,980	0,986	0,985	0,985	0,989	0,986

5. DISCUSIÓN

En esta sección se comparan los resultados con otros estudios encontrados en la literatura. En el trabajo realizado por Alsirhani et al., (2023), se construyó un modelo empleando un perceptrón multicapa-máquina de aprendizaje extremo (MLP-ELM) para predecir la estabilidad de redes eléctricas inteligentes; obtuvieron un *accuracy* del 95,8 %, una precisión del 90 %, una recuperación del 88 % y una puntuación F1 del 89 %. Concluyeron que esta técnica supera a las técnicas tradicionales de ML. Alazab et al., (2020) desarrollaron un modelo empleando la técnica de memoria multidireccional a corto y largo plazo (MLSTM, por sus siglas en inglés) para predecir la estabilidad de redes eléctricas inteligentes; obtuvieron un *accuracy* del 99,07 % y concluyeron que esta técnica es mejor que otras empleadas en aprendizaje profundo: por ejemplo, la unidad recurrente cerrada (GRU, por sus siglas en inglés), la red neuronal recurrente (RNN, por sus siglas en inglés) y las redes neuronales de memoria de corto-largo plazo (LSTM, por sus siglas en inglés). Bashir et al. (2021) entrenaron diferentes modelos de ML (máquinas de vectores de soporte, k-vecinos más cercanos K-NN, regresión logística, naïve-Bayes, redes neuronales y árboles de decisión) para predecir la estabilidad de las redes eléctricas inteligentes y resaltan la superioridad del algoritmo de clasificación de árboles de decisión, el cual superó a otros algoritmos de última generación y obtuvo una precisión del 100 %, una recuperación del 99,9 %, una puntuación F1 del 100 % y un *accuracy* del 99,96 %.

Como hipótesis se sugiere que el modelo predictivo construido con *deep learning* funciona mejor que otros tipos de modelos de ML, sobre todo por su capacidad de aprender automáticamente representaciones jerárquicas a partir de datos, lo que puede conducir a un mejor rendimiento en tareas complejas. Se debe señalar que esta técnica no es una solución única para todos y su idoneidad debe evaluarse en función del problema específico, los datos disponibles, los recursos computacionales y otros factores. En definitiva, se logró el objetivo planteado: el modelo construido con *deep learning* permitirá a los operadores de redes inteligentes tomar decisiones posteriores en relación con la estabilidad de las redes eléctricas inteligentes, gestionar de forma proactiva el rendimiento de la red, prevenir eventos de inestabilidad y garantizar un sistema de distribución de energía más confiable y eficiente.

Es importante recordar que el objetivo del modelado predictivo es encontrar tendencias que se generalicen a datos no analizados, en lugar de registrar los datos aprendidos durante el entrenamiento. Las métricas de rendimiento deben calcularse después de realizar la validación cruzada. Como puede haber desequilibrio de clases o problemas de sobrentrenamiento también se deben analizar los modelos que están más alejados del caso aleatorio, además de aquellos que se basan únicamente en altas precisiones.

CONCLUSIONES

En este trabajo se ha empleado el *deep learning* para predecir la estabilidad de voltaje en redes eléctricas inteligentes. Se empleó una validación cruzada KFold (10) y se calculó la métrica de desempeño *accuracy* para cada conjunto de validación. El *deep learning* demostró ser una herramienta de predicción excepcional para esta aplicación concreta. Las arquitecturas RNA más complejas obtuvieron mejores resultados que las más sencillas; sin embargo, no es correcto afirmar que esta técnica es superior a las demás, pues el objetivo del investigador, la cantidad y la calidad de los datos disponibles son también relevantes. Además, aspectos como la no normalización de los datos, la no identificación de los parámetros óptimos y un procesamiento inadecuado pueden afectar considerablemente su rendimiento. Trabajos futuros pueden enfocarse en validar el nivel de precisión obtenido con esta técnica en términos prácticos, con ayuda de operadores.

La implantación de redes inteligentes en zonas urbanas y rurales presenta grandes ventajas, ya que estas fomentan el desarrollo de energías renovables, contribuyen a la reducción de gases contaminantes, reducen el impacto ambiental y los daños al ecosistema causados por la construcción de obras de infraestructura eléctrica. Para evitar fallos y colapsos en el sistema compuesto por tales redes, resulta vital predecir su estabilidad con antelación.

REFERENCIAS

- Alazab, M., Khan, S., Krishnan, S. S. R., Pham, Q. V., Reddy, M. P. K. & Gadekallu, T. R. (2020). A multidirectional LSTM model for predicting the stability of a smart grid. *IEEE Access*, 8, 85454-85463. <https://doi.org/10.1109/ACCESS.2020.2991067>
- Alsirhani, A., Alshahrani, M. M., Abukwaik, A., Taloba, A. I., Abd El-Aziz, R. M. & Salem, M. (2023). A novel approach to predicting the stability of the smart grid utilizing MLP- ELM technique. *Alexandria Engineering Journal*, 74, 495-508. <https://doi.org/10.1016/j.aej.2023.05.063>
- Ashrafi, R., Amirahmadi, M., Tolou-Askari, M. & Ghods, V. (2021). Multi-objective resilience enhancement program in smart grids during extreme weather conditions. *International Journal of Electrical Power & Energy Systems*, 129, 106824. <https://doi.org/https://doi.org/10.1016/j.ijepes.2021.106824>
- Ayadi, F., Colak, I. & Bayindir, R. (2019). Interoperability in smart grid. En *7th International Conference on Smart Grid (icSmartGrid)* (pp. 165-169). Institute of electrical and electronics engineers. <https://doi.org/10.1109/icSmartGrid48354.2019.8990680>
- Azad, S., Sabrina, F. & Wasimi, S. (2019). Transformation of smart grid using machine learning. En *29th Australasian Universities Power Engineering Conference (AUPEC)*,

- pp. 1-6. Institute of electrical and electronics engineers. <https://doi.org/10.1109/AUPEC48547.2019.211809>
- Babar, M., Tariq, M. U. & Jan, M. A. (2020). Secure and resilient demand side management engine using machine learning for IoT-enabled smart grid. *Sustainable Cities and Society*, 62, 102370. [https://doi.org/https://doi.org/10.1016/j.scs.2020.102370](https://doi.org/10.1016/j.scs.2020.102370)
- Bashir, A. K., Khan, S., Prabadevi, B., Deepa, N., Alnumay, W. S., Gadekallu, T. R., & Maddikunta, P. K. R. (2021). Comparative analysis of machine learning algorithms for prediction of smart grid stability. *International Transactions on Electrical Energy Systems*, 31(9). <https://doi.org/10.1002/2050-7038.12706>
- Dileep, G. (2020). A survey on smart grid technologies and applications. *Renewable Energy*, 146, 2589-2625. <https://doi.org/https://doi.org/10.1016/j.renene.2019.08.092>
- Emmanuel, M., Rayudu, R. & Welch, I. (2019). Modelling impacts of utility-scale photovoltaic systems variability using the wavelet variability model for smart grid operations. *Sustainable Energy Technologies and Assessments*, 31, 292-305. <https://doi.org/https://doi.org/10.1016/j.seta.2018.12.011>
- Fan, D., Ren, Y., Feng, Q., Liu, Y., Wang, Z. & Lin, J. (2021). Restoration of smart grids: Current status, challenges, and opportunities. *Renewable and Sustainable Energy Reviews*, 143, 110909. <https://doi.org/https://doi.org/10.1016/j.rser.2021.110909>
- Ghafouri, M., Au, M., Kassouf, M., Debbabi, M., Assi, C., & Yan, J. (2020). Detection and mitigation of cyber-attacks on voltage stability monitoring of smart grids. *IEEE Transactions on Smart Grid*, 11(6), 5227-5238. <https://doi.org/10.1109/TSG.2020.3004303>
- Heidari, A. A., Faris, H., Aljarah, I. & Mirjalili, S. (2019). An efficient hybrid multilayer perceptron neural network with grasshopper optimization. *Soft Computing*, 23(17), 7941-7958. <https://doi.org/10.1007/s00500-018-3424-2>
- Ibrahim, M. S., Dong, W. & Yang, Q. (2020). Machine learning driven smart electric power systems: current trends and new perspectives. *Applied Energy*, 272, 115237. <https://doi.org/https://doi.org/10.1016/j.apenergy.2020.115237>
- Judge, M. A., Khan, A., Manzoor, A. & Khattak, H. A. (2022). Overview of smart grid implementation: frameworks, impact, performance and challenges. *Journal of Energy Storage*, 49, 104056 <https://doi.org/https://doi.org/10.1016/j.est.2022.104056>
- Kotsopoulos, T., Sarigiannidis, P., Ioannidis, D. & Tzovaras, D. (2021). Machine learning and deep learning in smart manufacturing: the smart grid paradigm. *Computer Science Review*, 40, 100341. <https://doi.org/https://doi.org/10.1016/j.cosrev.2020.100341>
- Lamnatou, Chr., Chemisana, D. & Cristofari, C. (2022). Smart grids and smart technologies in relation to photovoltaics, storage systems, buildings and the environment.

- Renewable Energy*, 185, 1376-1391. <https://doi.org/https://doi.org/10.1016/j.renene.2021.11.019>
- Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N. & Nandi, A. K. (2020). Applications of machine learning to machine fault diagnosis: a review and roadmap. *Mechanical Systems and Signal Processing*, 138, 106587. <https://doi.org/https://doi.org/10.1016/j.ymssp.2019.106587>
- Liu, D., Zhang, Q., Chen, H. & Zou, Y. (2022). Dynamic energy scheduling for end-users with storage devices in smart grid. *Electric Power Systems Research*, 208, 107870. <https://doi.org/https://doi.org/10.1016/j.epsr.2022.107870>
- Ma, R., Chen, H. H., Huang, Y. R., & Meng, W. (2013). Smart grid communication: its challenges and opportunities. *IEEE transactions on Smart Grid*, 4(1), 36-46. <https://doi.org/10.1109/TSG.2012.2225851>
- Massaoudi, M., Abu-Rub, H., Refaat, S. S., Chihi, I., & Oueslati, F. S. (2021). Accurate smart grid stability forecasting based on deep learning: point and interval estimation method. En *Kansas Power and Energy Conference (KPEC)* (pp. 1-6). Institute of electrical and electronics engineers. <https://doi.org/10.1109/KPEC51835.2021.9446196>
- Mollah, M. B., Zhao, J., Niyato, D., Lam, K.-Y., Zhang, X., Ghias, A. M. Y. M., Koh, L. H. & Yang, L. (2021). Blockchain for future smart grid: a comprehensive survey. *IEEE Internet of Things Journal*, 8(1), 18-43. <https://doi.org/10.1109/JIOT.2020.2993601>
- Mukherjee, R. & De, A. (2020). Development of an ensemble decision tree-based power system dynamic security state predictor. *IEEE Systems Journal*, 14(3), 3836-3843. <https://doi.org/10.1109/JSYST.2020.2978504>
- Muthamizh Selvam, M., Gnanadass, R. & Padhy, N. P. (2016). Initiatives and technical challenges in smart distribution grid. *Renewable and Sustainable Energy Reviews*, 58, 911-917. <https://doi.org/https://doi.org/10.1016/j.rser.2015.12.257>
- Neffati, O. S., Sengan, S., Thangavelu, K. D., Kumar, S. D., Setiawan, R., Elangovan, M., Mani, D., & Velayutham, P. (2021). Migrating from traditional grid to smart grid in smart cities promoted in developing country. *Sustainable Energy Technologies and Assessments*, 45, 101125. <https://doi.org/10.1016/j.seta.2021.101125>
- Omitaomu, O. A., & Niu, H. (2021). Artificial intelligence techniques in smart grid: a survey. *Smart Cities*, 4(2), 548-568. <https://doi.org/10.3390/smartcities4020029>
- Panda, D. K. & Das, S. (2021). Smart grid architecture model for control, optimization and data analytics of future power networks with more renewable energy. *Journal of Cleaner Production*, 301, 126877. <https://doi.org/10.1016/j.jclepro.2021.126877>
- Sai Pandraju, T. K., Samal, S., Saravanakumar, R., Yaseen, S. M., Nandal, R. & Dhabliya, D. (2022). Advanced metering infrastructure for low voltage distribution system in smart

- grid based monitoring applications. *Sustainable Computing: Informatics and Systems*, 35, 100691. [https://doi.org/https://doi.org/10.1016/j.suscom.2022.100691](https://doi.org/10.1016/j.suscom.2022.100691)
- Singh, A. K., Singh, R., & Pal, B. C. (2014). Stability analysis of networked control in smart grids. *IEEE Transactions on Smart Grid*, 6(1), 381-390. <https://doi.org/10.1109/TSG.2014.2314494>
- Shi, Z., Yao, W., Li, Z., Zeng, L., Zhao, Y., Zhang, R., Tang, Y., & Wen, J. (2020). Artificial intelligence techniques for stability analysis and control in smart grids: Methodologies, applications, challenges and future directions. *Applied Energy*, 278, 115733. <https://doi.org/10.1016/j.apenergy.2020.115733>
- Shobole, A. A. & Wadi, M. (2021). Multiagent systems application for the smart grid protection. *Renewable and Sustainable Energy Reviews*, 149, 111352. [https://doi.org/https://doi.org/10.1016/j.rser.2021.111352](https://doi.org/10.1016/j.rser.2021.111352)
- Stright, J., Cheetham, P. & Konstantinou, C. (2022). Defensive cost-benefit analysis of smart grid digital functionalities. *International Journal of Critical Infrastructure Protection*, 36, 100489. <https://doi.org/https://doi.org/10.1016/j.ijcip.2021.100489>
- Tiwari, S., Jain, A., Ahmed, N. M. O. S., Charu, Alkwai, L. M., Dafhalla, A. K. Y. & Hamad, S. A. S. (2022). Machine learning-based model for prediction of power consumption in smart grid. Smart way towards smart city. *Expert Systems*, 39(5), e12832. <https://doi.org/https://doi.org/10.1111/exsy.12832>
- Tufail, S., Parvez, I., Batool, S., & Sarwat, A. (2021). A survey on cybersecurity challenges, detection, and mitigation techniques for the smart grid. *Energies*, 14(18), 5894. <https://doi.org/10.3390/en14185894>
- Ullah, K., Hafeez, G., Khan, I., Jan, S. & Javaid, N. (2021). A multi-objective energy optimization in smart grid with high penetration of renewable energy sources. *Applied Energy*, 299, 117104. <https://doi.org/https://doi.org/10.1016/j.apenergy.2021.117104>
- Yapa, C., de Alwis, C., Liyanage, M. & Ekanayake, J. (2021). Survey on blockchain for future smart grids: technical aspects, applications, integration challenges and future research. *Energy Reports*, 7, 6530-6564. <https://doi.org/https://doi.org/10.1016/j.egyr.2021.09.112>
- Yoldaş, Y., Önen, A., Muyeen, S. M., Vasilakos, A. V., & Alan, I. (2017). Enhancing smart grid with microgrids: challenges and opportunities. *Renewable and Sustainable Energy Reviews*, 72, 205-214. <https://doi.org/10.1016/j.rser.2017.01.064>
- Zhang, Y., Xin, J., Li, X. & Huang, S. (2020). Overview on routing and resource allocation based machine learning in optical networks. *Optical Fiber Technology*, 60, 102355. <https://doi.org/https://doi.org/10.1016/j.yofte.2020.102355>

Neural Network Energy Control of Combustion Engines for Automotive Software Applications

Marcos Henrique Carvalho Silva
marcoshencarsil@gmail.com
<https://orcid.org/0000-0002-1318-086X>
Universidade de São Paulo, Brazil

André Vinícius Oliveira Maggio
andremaggio@usp.br
<https://orcid.org/0000-0002-9331-5663>
Universidade de São Paulo, Brazil

Armando Antônio Maria Laganá
armandolagana@terra.com.br
<https://orcid.org/0000-0002-0085-1927>
Universidade de São Paulo, Brazil

João Francisco Justo Filho
jjusto@lme.usp.br
<https://orcid.org/0000-0003-1948-7835>
Universidade de São Paulo, Brazil

Bruno Silva Pereira
bruno6_spp@hotmail.com
<https://orcid.org/0009-0000-3943-2132>
Universidade de São Paulo, Brazil

Demerson Moscardini
demersondonoc@hotmail.com
<https://orcid.org/0009-0005-1999-6121>
Universidade de São Paulo, Brazil

Received: July 08, 2023 / Accepted: September 09, 2023
doi: <https://doi.org/10.26439/ciis2023.7083>

ABSTRACT. This article focuses on the application of neural network control for energy generation in an internal combustion engine. A two-layer neural network architecture was developed and tested using laboratory data obtained from a bench dynamometer to accurately identify the network's parameters. The neural network is employed to establish an accurate correlation between the magnitude of actuation signals and the fundamental variables responsible for regulating energy generation within the system. The control system utilizes a gain-scheduling routine to adjust the controller's gain, which attenuates the increment for low error values. An energy generation model is presented to design a virtual engine, enabling accurate control strategies. To ensure the safe operation of the engine, a safety routine is implemented to prevent the control action from assuming values that could negatively impact the vehicle's response to the driver's commands. The developed controller demonstrates a low average absolute error in steady-state conditions and a low average rise and fall time during transient states, ensuring both drivability and good engine performance. To enable the application in software, in structures such as hardware-in-the-loop simulation and engine control units, systems are implemented to ensure real-time operations.

KEYWORDS: neural network control / energy generation / software development

CONTROL ENERGÉTICO DE MOTORES DE COMBUSTIÓN MEDIANTE REDES NEURONALES PARA APLICACIONES DE SOFTWARE DE AUTOMOCIÓN

RESUMEN. Este artículo se enfoca en la aplicación del control mediante redes neuronales para la generación de energía en un motor de combustión interna. Se desarrolló una arquitectura de red neuronal de dos capas y se la probó utilizando datos de laboratorio obtenidos de un dinamómetro de banco para identificar con precisión los parámetros de la red. Esta se utiliza para establecer una correlación precisa entre la magnitud de las señales de actuación y las variables fundamentales responsables de regular la generación de energía dentro del sistema. El sistema de control implementa una rutina de programación de ganancia para ajustar la ganancia del controlador, lo que disminuye el incremento para valores de error bajos. Se presenta un modelo de generación de energía que permite diseñar un motor virtual, lo cual facilita el desarrollo de estrategias de control precisas. Para garantizar el funcionamiento seguro del motor, se implementa una rutina de seguridad que previene que la acción de control adquiera valores que podrían tener un impacto negativo en la respuesta del vehículo a las instrucciones del conductor. El controlador desarrollado demuestra un bajo error absoluto promedio en condiciones de estado estable y un bajo tiempo promedio de subida y caída durante estados transitorios, asegurando la capacidad de conducción y el buen rendimiento del motor. Para habilitar la aplicación en software, en estructuras como el hardware-in-the-loop y la unidad de control del motor, se implementan sistemas para garantizar la operación en tiempo real.

PALABRAS CLAVE: control mediante redes neuronales, generación de energía, desarrollo de software.

1. INTRODUCTION

The relentless pursuit of improvements in engine performance is one of the main objectives of the automotive industry (Pandey et al., 2021). As drivers become increasingly demanding with regard to vehicle drivability, it is essential to apply advancements in the field of control to meet these demands. Technological advancements have driven significant improvements in automotive engine performance. Through the development of more efficient controls, it is possible to optimize engine performance and ensure a more satisfying driving experience for drivers. One key factor in this context is precise engine control, which positively impacts its performance. Advanced controls enable accurate tracking of the desired reference, resulting in improved drivability. When the engine responds promptly and accurately to driver commands, the driving experience becomes smoother and safer (Wang et al., 2020).

The use of neural networks in control has proven to be of great importance in and impact on various fields of application. Neural networks, which are computational models inspired by the functioning of the human brain, have the ability to learn and adapt from input data. When applied to control, neural networks can learn complex and nonlinear patterns, allowing for more precise actions (Shahbaz & Amin, 2023). This is especially relevant in nonlinear systems. By utilizing neural networks in control, it is possible to achieve a higher level of efficiency, precision and adaptability, which contributes to optimizing processes, reducing errors and promoting significant technological advancements (Ineza Havugimana et al., 2023).

There are notable research studies in the field of control with neural networks for internal combustion engines. Moriyasu et al. (2019) controlled the engine's air system using a neural network-based controller and an unscented Kalman filter. Zhao et al. (2020) controlled the engine speed using a radial basis function-based proportional integral derivative (PID) controller based on neural network theory. Wong et al. (2020) developed an extreme learning machine (ELM)-based adaptive neural control algorithm to control the idle speed of the engine. Gordon et al. (2022), aiming to control combustion for improved pollutant emission levels, used a deep neural network (DNN) to develop a predictive controller. Vignesh & Ashok (2021) used a DNN to create a predictive model in order to develop optimal injection control for emission reduction.

2. METHODOLOGY

A mean-value model is used for energy generation. In order to estimate the effective torque value T_e , it is considered that the effective torque can be obtained by subtracting the pumping losses T_{pump} and friction losses T_{fric} from the indicated torque T_i , as described by equation (1).

$$T_e = T_i - T_{pump} - T_{fric}. \quad (1)$$

The estimation of the indicated torque depends on several factors, such as the engine speed, intake manifold pressure, air-fuel ratio, admitted fuel flow and ignition timing. In equation (2), the effects of the air-fuel ratio, ignition timing and load are separated into three factors, respectively $e\lambda$, $e\xi$ and $e\alpha$ (Guzzella & Onder, 2010). These factors relate the indicated torque T_i to the torque T_f that would be produced if the thermal efficiency of the engine were unity. The optimum indicated efficiency is achieved with the optimal ignition timing and air-fuel ratio values. Under these conditions, the indicated efficiency is represented by the factor $e\alpha$ itself.

$$T_i = e\alpha \cdot e\lambda \cdot e\xi \cdot T_f \quad (2)$$

The relationship between the indicated torque and the ignition timing is parabolic (Moskwa, 1988). When the ignition angle ξ is set to the maximum brake torque (MBT) angle ξ_0 , it is considered that there are no losses in efficiency due to the timing of ignition. The maximum brake torque angle is the angular position of the spark discharge that provides the highest indicated efficiency. The opening of the parabola is directly related to the coefficient $k\xi$, as shown in equation (3). The factor that accounts for the efficiency losses due to the air-fuel ratio values can be approximated by equation (4) (Eriksson & Nielsen, 2014). The factor $e\alpha$ is mapped based on the engine speed and intake pressure.

$$e\xi = 1 - k\xi \cdot (\xi - \xi_0)^2 \quad (3)$$

$$\lambda \text{ for rich mixtures} \quad (4)$$

$$e\lambda = \begin{cases} 1 & \text{for poor mixtures} \end{cases}$$

A multivariable neural network controller is employed to control the useful energy generation of the engine through the following actuators: throttle valve, fuel injector and ignition coil. The neural network is trained using data obtained in the laboratory. During training, values such as throttle opening, ignition angle, injection timing, oil temperature, engine speed, intake pressure, air-fuel ratio and effective torque are provided to design a neural network controller that provides appropriate values for throttle opening, ignition angle and injection timing for a desired effective torque. Current and delayed values of intake pressure and air-fuel ratio signals are used, aiming to enhance the predictive capability of the neural network. There is a set of phenomena that occur, such that changes in air intake or fuel injection gradually impact on the air-fuel ratio.

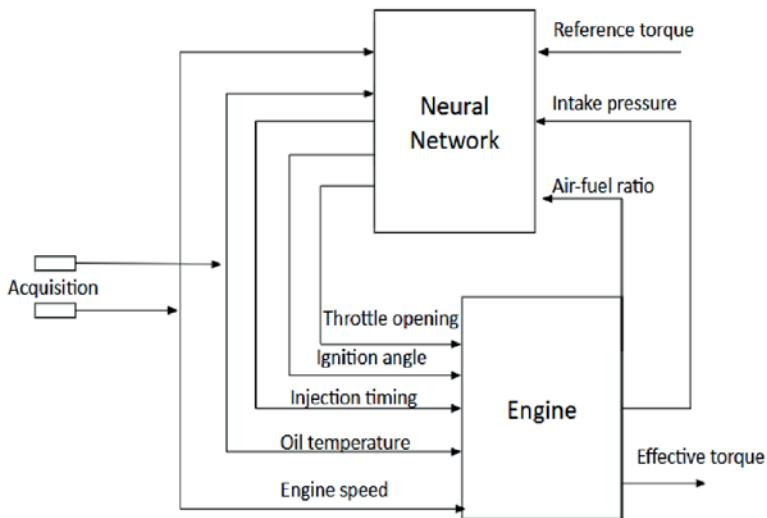
The neural network controller operates in parallel with a gain-schedule routine, which adjusts the controller's gain increment by attenuating it when the error magnitude between the reference and effective torque is small. The developed controller is validated in a simulation with the modeled engine, as shown in Figure 1. The virtual engine is connected to a gain-scheduling routine, a neural network control system and a safety interface. The safety

interface ensures that the control signals received by the actuators do not have values that could compromise the drivability and safety of the engine.

For applicability in automotive software, all systems must exert low processing demand in order to enable their real-time implementation. In this way, systems can be programmed in a hardware-in-the-loop environment or in the electronic control unit due to their capability to operate in real-time (Schäuffele & Zurawka, 2016).

Figure 1

Simplified diagram of the control system with the engine model



3. EXPERIMENTAL SETUP

In order to acquire experimental data for the purpose of engine modeling, a laboratory environment equipped with a bench dynamometer and an external cooling system, as depicted in Figure 2, was employed. The engine under study was the EA-111 VHT 1.6 l, which possesses several features, including indirect port injection, fuel compatibility with both gasoline and ethanol, absence of gas recirculation, spark ignition, eight valves, naturally aspirated configuration and a compression ratio of 12.1.

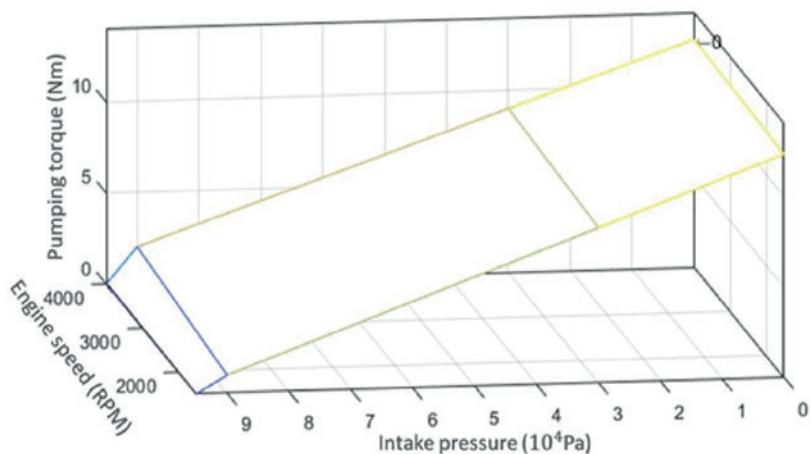
Figure 2
EA-111 VHT 1.6 l engine coupled to the dynamometer



4. RESULTS AND DISCUSSION

Initially, data acquisition is performed to determine multiple engine parameters. Gas pumping losses correspond to the reduction in torque resulting from the energy expended in transferring gas from a low-pressure location (intake manifold) to a high-pressure location (exhaust manifold). These losses can be quantified and computed based on the engine speed and intake pressure. By calculating the pumping loss at various operating points, the map illustrated in Figure 3 is generated. For specific insights into this calculation methodology, refer to Guzzella and Onder (2010).

Figure 3
Pumping torque map



There are various methods to estimate torque losses due to friction. In this research, an active bench dynamometer capable of rotating the engine while it is off was used. The force necessary to rotate the engine can be regarded as the force required to overcome friction. Consequently, the torque measured by the active dynamometer in this scenario, known as motored torque, provides an approximation of the friction values T_{fric} . Motored torque values were obtained at different oil temperatures and engine speeds, as shown in Figure 4.

In order to construct the torque estimator, the optimal ignition angle and the optimal indicated efficiency were identified for various operating conditions. Figure 5 presents the results of the identification of the optimal ignition angle ξ_0 , while Figure 6 displays the results of the optimal indicated efficiency $e\alpha$.

Figure 4

Motored torque map

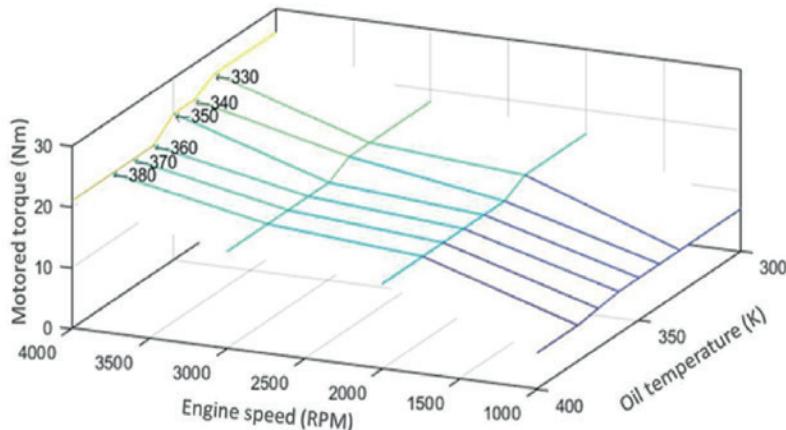
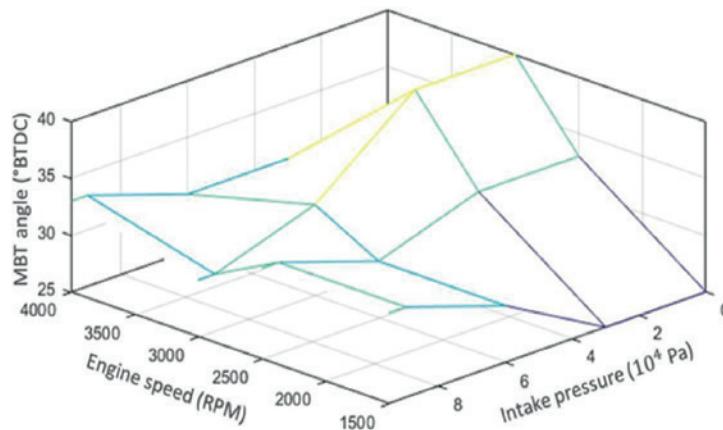


Figure 5

MBT angle map



The comprehensive system diagram is depicted in Figure 7. The engine model encompasses various subsystems including the air intake system, the air-fuel mixture formation system and the energy generation system. To maintain drivability and driver safety, a safety module is incorporated to restrict control signals from assuming values that may compromise these aspects. The neural network control module comprises a two-layer neural network architecture as illustrated in Figure 8. Additionally, the gain-scheduling module generates signals to increment the control signals. However, this increment is attenuated for low absolute error values, considering the error as the discrepancy between the torque reference and the actual torque.

Figure 6
Indicated efficiency for optimal conditions

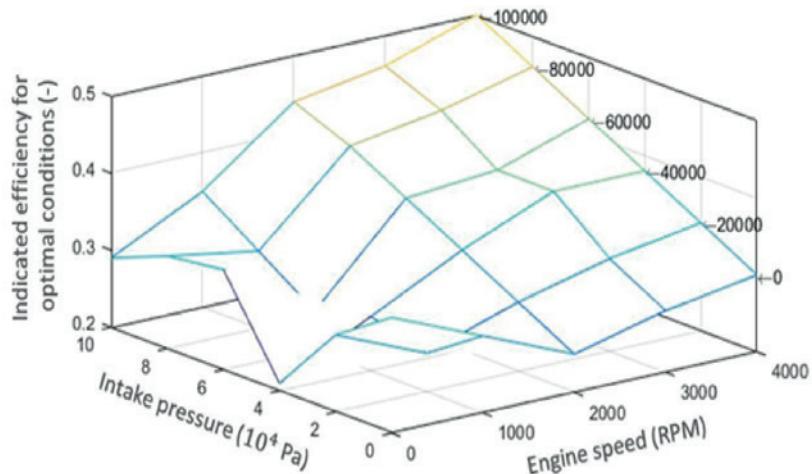


Figure 7

Simulink diagram of the control system with the engine model and the safety routine

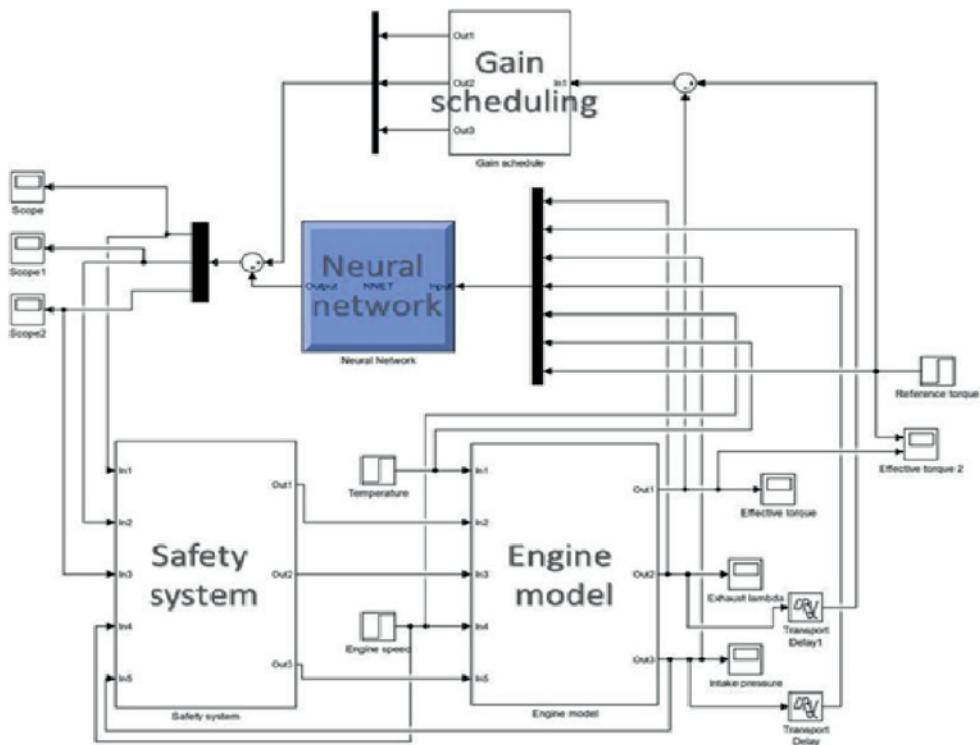
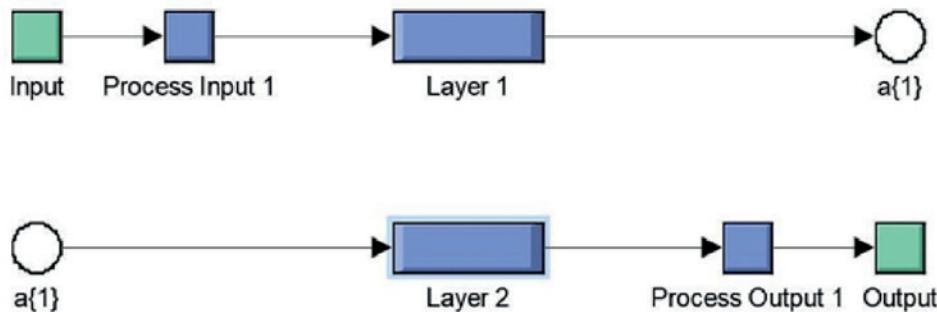


Figure 8

Two-layer neural network control



To validate the control design, simulations were conducted across a range of engine speeds. The simulation results for the engine operating at 2 000 RPM are presented in Figure 9, while Figure 10 showcases the outcomes for the engine at 3 000 RPM. Figure 11, additionally, displays the results obtained for the engine running at 4 000 RPM. In these figures, a comparison is made between the reference signal and the corresponding torque signal. To evaluate the control performance in both steady-state and transient regimes, step changes are applied to the reference signal.

Figure 9a

Torque reference (red signal) contrasting with torque signal (blue signal) in the simulink environment for 2000 RPM with negative step in the reference

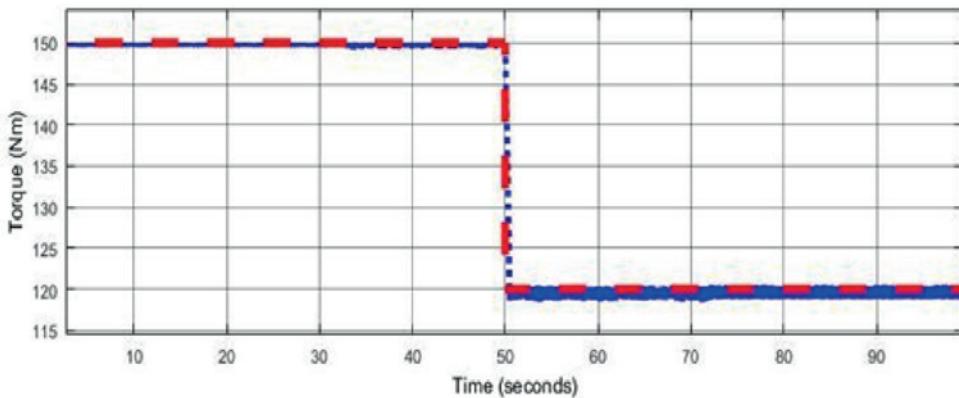


Figure 9b

Torque reference (red signal) contrasting with torque signal (blue signal) in the simulink environment for 2000 RPM with positive step in the reference

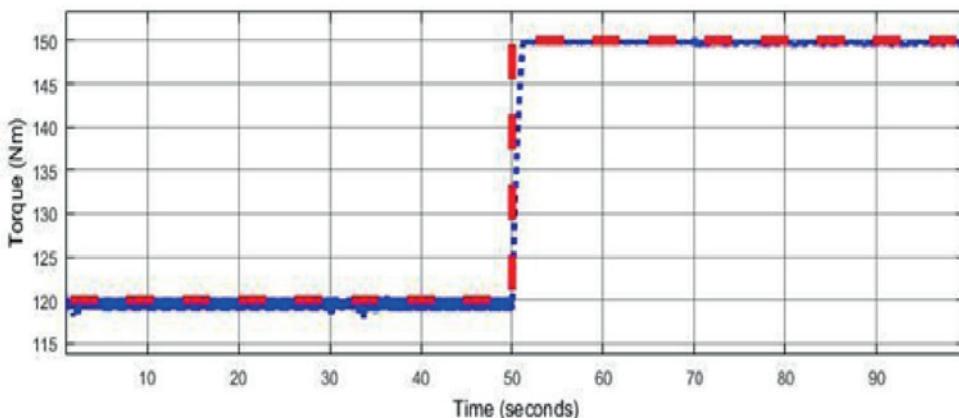


Figure 10a

Torque reference (red signal) contrasting with torque signal (blue signal) in the simulink environment for 3000 RPM with positive step in the reference

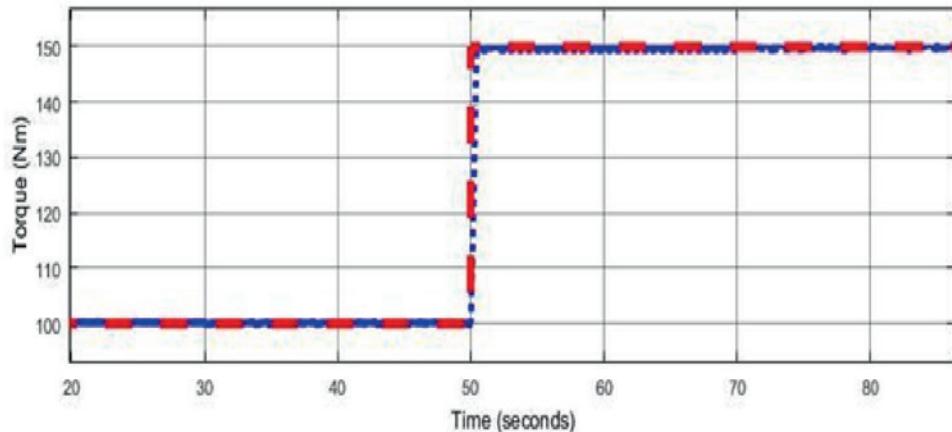


Figure 10b

Torque reference (red signal) contrasting with torque signal (blue signal) in the simulink environment for 3000 RPM with negative step in the reference

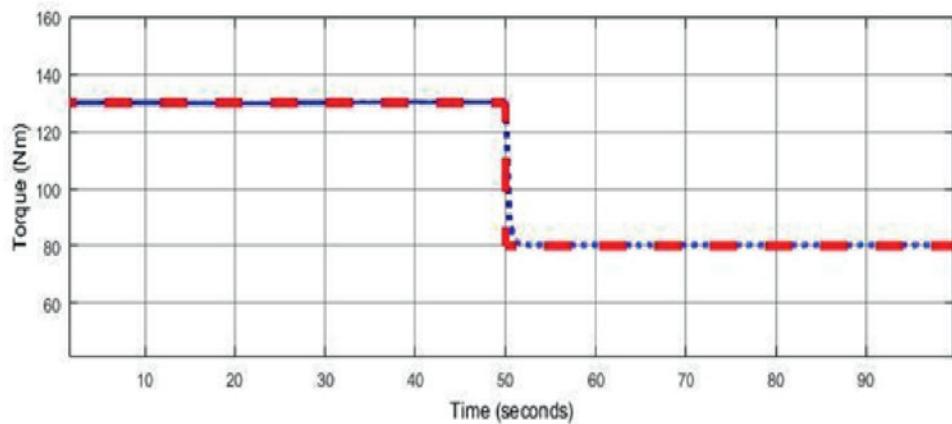


Figure 11a

Torque reference (red signal) contrasting with torque signal (blue signal) in the simulink environment for 4000 RPM with positive step in the reference

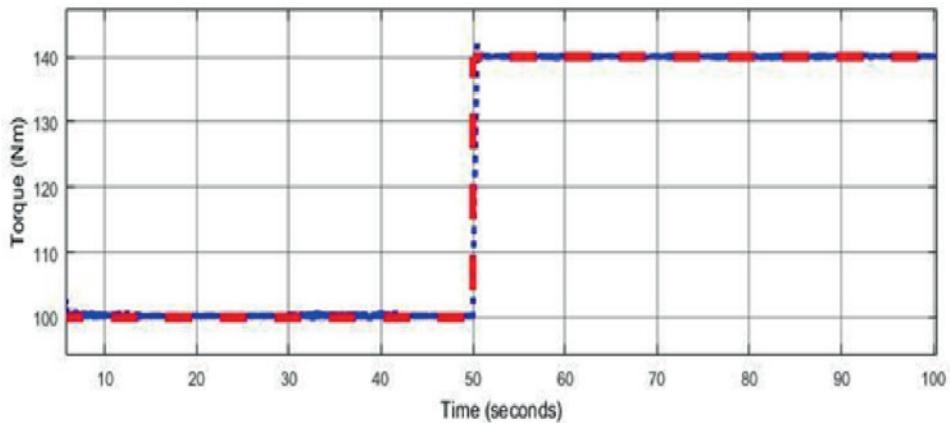
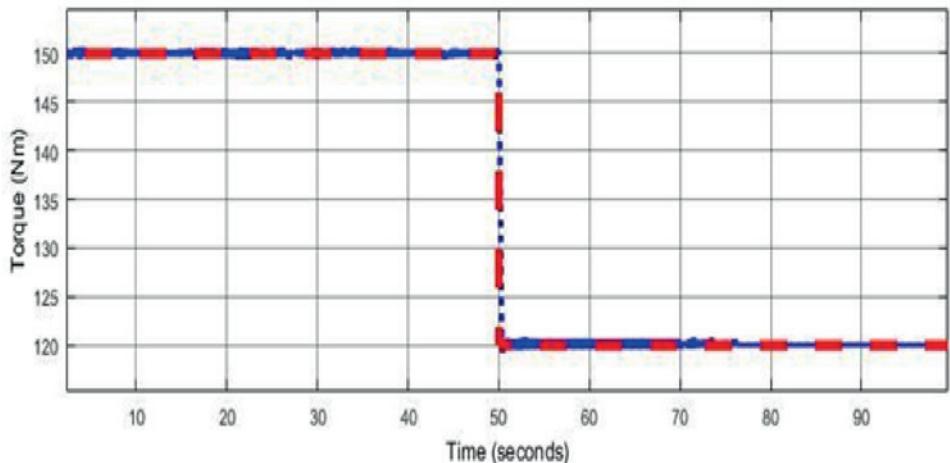


Figure 11b

Torque reference (red signal) contrasting with torque signal (blue signal) in the simulink environment for 4000 RPM with negative step in the reference



For a clearer understanding of the signal behavior in the transient regime, highlights of the simulation with the engine at 3 000 RPM are illustrated in Figure 12. The controller exhibited low values for both the rise and fall times in the transient regime and the mean absolute error in the steady-state regime across all engine speeds. For all engine speeds, the average absolute error values were less than 1 Newton meter, and the average rise and fall time values were less than 2 seconds. These results indicate that the developed controller demonstrates proper reference tracking, implying good drivability and safety for the driver. In order to assess the

control effort, the control signals are depicted in Figure 13. The examination reveals that the control signal values are appropriate for each actuator, as they are within the range of executable values.

A comprehensive system simulation, encompassing a timeframe of 10 000 seconds, completed its execution within a mere 70 seconds on a standard computing device. This significant result validates the system's viability for diverse automotive software applications, as it demonstrates real-time responsiveness, meeting the stringent requirements of such domains.

Figure 12a

Transient regime details in the application of a positive step in torque reference with the engine at 3000 RPM

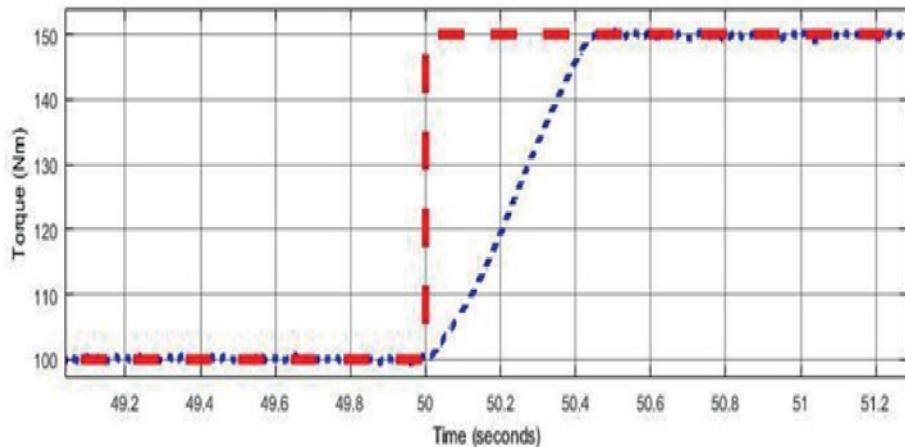


Figure 12b

Transient regime details in the application of a negative step in torque reference with the engine at 3000 RPM

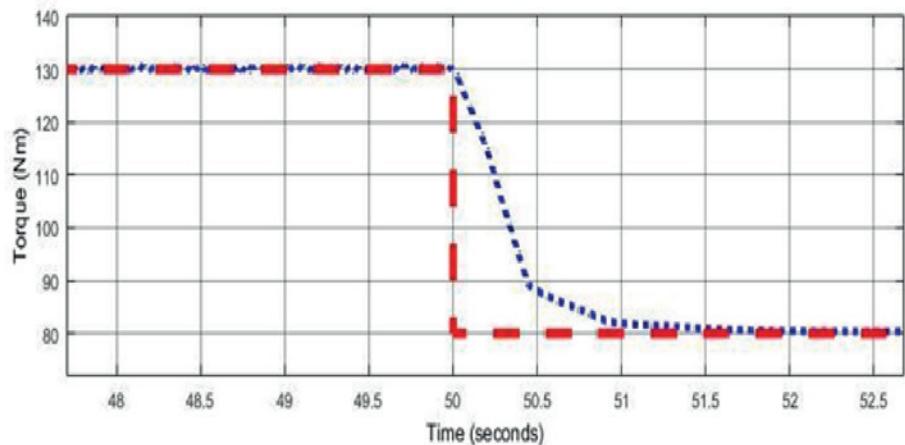


Figure 13a

Ignition angle control signal, in degrees before top dead center ($^{\circ}$ BTDC), for the engine at 3000 RPM

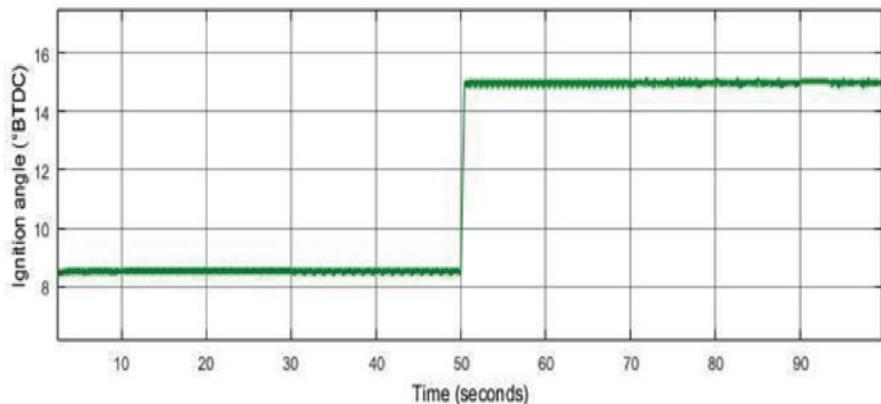


Figure 13b

Injection timing control signal, in milliseconds, for the engine at 3000 RPM

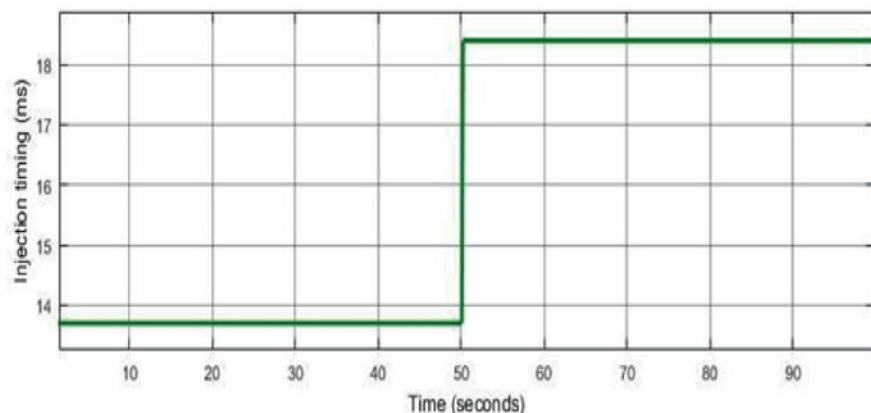
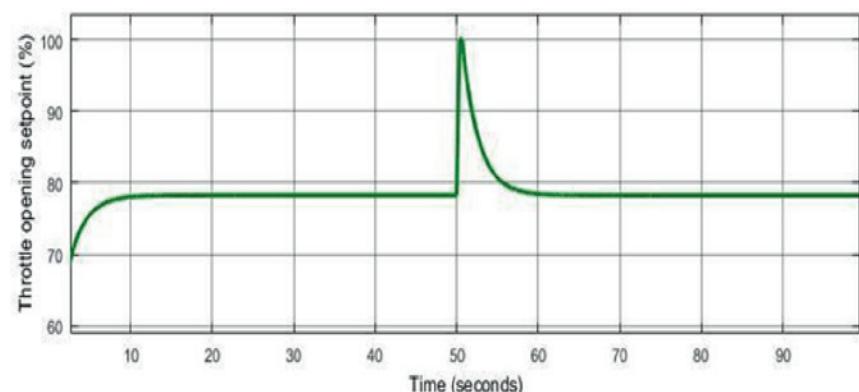


Figure 13c

Throttle opening setpoint control signal, in opening percentage, for the engine at 3000 RPM



5. CONCLUSIONS

This article presented the application of a two-layer neural network for controlling energy generation in an internal combustion engine. The identification of the neural network parameters was performed using laboratory data obtained with a bench dynamometer, establishing a relationship between the main variables responsible for energy generation. Additionally, a gain-scheduling routine was implemented to adjust the controller gain, attenuating the control action increment for low error values.

To ensure the safety and proper response of the vehicle to driver commands, a safety routine was developed to prevent the control action from reaching undesired values. The experimental results obtained with the developed controller demonstrated a low value of mean absolute error in steady-state regime and a reduced average value of rise and fall time in transient regime. These results confirm the drivability and satisfactory performance of the engine, reinforcing the effectiveness of using neural networks in controlling energy generation in internal combustion engines.

The developed project has proven to be suitable for application in automotive software, primarily due to its real-time responsiveness. A comprehensive system simulation spanning a duration of 10 000 seconds can be executed within 70 seconds on a conventional computing device, thereby showcasing efficiency and agility in computational performance. Furthermore, it is possible to convert the project into .c or .a2l files, enabling its integration with widely used solutions in the automotive industry, such as hardware-in-the-loop and electronic control unit. These specialized solutions possess significantly faster data processing capabilities compared to regular computers, further enhancing the advantages of the system proposed in this article for automotive software applications.

As a suggestion for future work, the presented control project can be implemented in a hardware-in-the-loop environment and in the engine with a bench dynamometer to perform the necessary calibration of the adjustable gain routine parameters. Once the calibration to be used is obtained, the entire hybrid control structure, which consists of the collaborative work of an adjustable gain routine with a neural network, can be converted into a single neural network. Similarly, this neural network can be programmed into the engine control unit (ECU) for validation in test rooms.

Acknowledgements

We thank the FIPT (Fundação de Apoio ao Instituto de Pesquisas Tecnológicas) and CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) for funding this research.

REFERENCES

- Eriksson, L., & Nielsen, L. (2014). *Modeling and control of engines and drivelines* (1st ed.). John Wiley & Sons.
- Gordon, D. C., Norouzi, A., Winkler, A., McNally, J., Nuss, E., Abel, D., Shahbakhti, M., Andert, J., & Koch, C. R. (2022). End-to-end deep neural network based nonlinear model predictive control: Experimental implementation on diesel engine emission control. *Energies*, 15(24), 9335. <https://doi.org/10.3390/en15249335>
- Guzzella L., & Onder, C. (2010). *Introduction to modeling and control of internal combustion engine systems* (2nd ed.). Springer Science & Business Media.
- Ineza Havugimana, L. F., Liu, B., Liu, F., Zhang, J., Li, B., & Wan, P. (2023). Review of artificial intelligent algorithms for engine performance, control, and diagnosis. *Energies*, 16, 1206. <https://doi.org/10.3390/en16031206>
- Moriyasu, R., Nojirie S., Matsunaga, A., Nakamura, T., & Jimbo, T. (2019). Diesel engine air path control based on neural approximation of nonlinear MPC. *Control Engineering Practice*, 91, 104114 <https://doi.org/10.1016/j.conengprac.2019.104114>
- Moskwa, J. J. (1988). *Automotive engine modeling for real time control* [Doctoral dissertation, Massachusetts Institute of Technology]. <http://hdl.handle.net/1721.1/14617>
- Pandey, V., van Dooren, S., Ritzmann, J., Pla, B., & Onder, C. (2021). Variable smoothing of optimal diesel engine calibration for improved performance and drivability during transient operation. *International Journal of Engine Research*, 22(6), 1888-1895. <https://doi.org/10.1177/1468087420918801>
- Schäuffele, J., & Zurawka, T. (2016). *Automotive software engineering: Principles, processes, methods, and tools* (2nd ed.). SAE International.
- Shahbaz, M. H., & Amin, A. A. (2023). Design of hybrid fault-tolerant control system for air-fuel ratio control of internal combustion engines using artificial neural network and sliding mode control against sensor faults. *Advances in Mechanical Engineering*, 15(3). <https://doi.org/10.1177/16878132231160729>
- Vignesh, R., & Ashok, B. (2021). Deep neural network model-based global calibration scheme for split injection control map to enhance the characteristics of biofuel powered engine. *Energy Conversion and Management*, 249, 114875. <https://doi.org/10.1016/j.enconman.2021.114875>
- Wang, J., Hou, X., Du, C., Xu, H., & Zhou, Q. (2020). A moment-of-inertia-driven engine start-up method based on adaptive model predictive control for hybrid electric vehicles with drivability optimization. *IEEE Access*, 8, pp. 133063-133075. <https://doi.org/10.1109/ACCESS.2020.3010528>

Wong, P. K., Huang, W., Vong, C. M., & Yang, Z. (2020) Adaptive neural tracking control for automotive engine idle speed regulation using extreme learning machine. *Neural Computing and Applications*, 32, 14399-14409. <https://doi.org/10.1007/s00521-019-04482-5>

Zhao, G., Long, Y., Ding, S., Yang, L., Song, E., & Ma, X. (2020). Study of advanced control based on the RBF neural network theory in diesel engine speed control. *SAE International Journal of Engines*, 13(1), 63-75. <https://doi.org/10.4271/03-13-01-0005>

Diseño de un aplicativo (AI-Pills) que reconoce medicamentos mediante el uso de la inteligencia artificial

Carolina Aliaga

Universidad Nacional de Ingeniería, Perú

Jesús Dominguez

Universidad Nacional de Ingeniería, Perú

Iris Liña

Universidad Nacional de Ingeniería, Perú

Javier Acuña

Universidad Nacional de Ingeniería, Perú

Recibido: 25/07/2023 / Aceptado: 25/08/2023

doi: <https://doi.org/10.26439/ciis2023.7084>

RESUMEN. En el presente trabajo se realizará una propuesta para el desarrollo de un aplicativo móvil innovador capaz de satisfacer las necesidades de algunas personas, pues puede reconocer una pastilla indicada en tiempo real, tan solo escaneándola con la cámara del celular. Para esto, partimos de una necesidad muy común en personas de tercera edad y de otras con discapacidad o dificultades visuales, a quienes se les complica encontrar el nombre del medicamento debido a que las letras son muy pequeñas. La aplicación utiliza tecnología avanzada de reconocimiento de imágenes y una base de datos integral de medicamentos para proporcionar información confiable sobre los fármacos prescritos.

PALABRAS CLAVE: Reconocimiento de imágenes, pastillas, aplicativo móvil, inteligencia artificial.

DESIGN OF AN APPLICATION THAT RECOGNIZES MEDICINES THROUGH A CAMERA BY MEANS OF ARTIFICIAL INTELLIGENCE “AI-PILLS”

ABSTRACT. In this project, we will make a proposal for an innovative mobile application capable of satisfying multiple needs of some people. The need to recognize the right pill in real time, just by scanning it with their camera. For this, we start from a very common need in old people and people with poor vision, which makes it difficult for them to find the name of the pill because of the size of the letters. AI-Pills is a revolutionary solution designed to help users, especially the ones with vision problems, to accurately identify their medications. The application uses advanced image recognition technology and a comprehensive drug database to provide reliable information about prescribed drugs.

KEYWORDS: Image recognition, pills, mobile application, artificial intelligence.

1. INTRODUCCIÓN

La inteligencia artificial ha ganado un enorme reconocimiento y popularidad en los últimos años debido a su capacidad para facilitar tareas, optimizar procesos y generar innovaciones tecnológicas. Según Rouhiainen (2018), “las tecnologías basadas en la IA ya están siendo utilizadas para ayudar a los humanos a beneficiarse de mejoras significativas y disfrutar de una mayor eficiencia en casi todos los ámbitos de la vida” (p. 17).

Una de las aplicaciones de la IA es la identificación de pastillas, una tarea compleja que puede ser especialmente beneficiosa para personas con dificultades de visión. Este proyecto se centra en desarrollar un aplicativo basado en inteligencia artificial capaz de reconocer pastillas en imágenes capturadas, para brindar así una solución práctica y accesible a las personas que necesitan identificar sus medicamentos de manera rápida.

No obstante, es relevante mencionar que este proyecto no está exento de desafíos. La principal limitación que se enfrenta es alcanzar un alto nivel de precisión en la identificación de pastillas con solo tomar una captura. La diversidad de formas, colores y tamaños de las pastillas representa un obstáculo importante que requerirá un esfuerzo considerable en el desarrollo y entrenamiento del aplicativo. Además, aspectos éticos y de seguridad de datos deben ser abordados para garantizar la privacidad de los usuarios y para evitar el riesgo de automedicación.

El artículo inicia con el detalle de la metodología empleada para el proyecto, continúa con la definición del plan del proyecto, los *sprints* por realizar y, por último, se muestran los resultados obtenidos.

2. METODOLOGÍA

El proyecto es realizado en base a dos marcos de trabajo clave: la Guía PMBOK en su sexta edición (Project Management Institute, 2017) y el marco de trabajo SCRUM. Además, se realizó el modelo Canvas del proyecto de inversión planteado, el cual se muestra en la Figura 1.

Figura 1
Modelo Canvas de AI-Pills



Como puede verse en el modelo, nuestra principal propuesta de valor consiste en la identificación de pastillas escaneadas con el dispositivo móvil y lectura de los detalles de la pastilla, y está dirigida a un público objetivo ubicado en el segmento de personas con problemas de visión o personas de la tercera edad. Para ello planteamos como socios clave a los proveedores de servicios en la nube, para garantizar la estabilidad y rendimiento de la aplicación, pues al ser una aplicación tipo *start-up*, esa sería la infraestructura que más se le adapte.

Para asegurar la rentabilidad del aplicativo, se propone un modelo de ingresos por suscripción. Ello no significa que no pueda usarse sin suscripción, pero con la versión de pago (*premium*) se estima que el aplicativo garantice un mejor porcentaje de precisión que en la versión gratuita, además de brindar algunas funcionalidades adicionales, como el seguimiento de recetas y recordatorios.

Al inicio del proyecto, se llevó a cabo la formulación y evaluación del proyecto de inversión, en la que se definieron los objetivos y se realizó un análisis financiero para determinar los costos de inversión, así como las ganancias proyectadas durante los próximos diez años tras la implementación del proyecto.

2.1 Plan del proyecto

El plan del proyecto está compuesto por los planes de gestión de alcance, cronograma, costos, calidad, recursos, comunicaciones, riesgo, adquisiciones y el involucramiento de los interesados.

De todos estos documentos, es particularmente importante tener en cuenta la descripción del alcance del producto, porque presenta un resumen conciso y claro de los límites y objetivos del proyecto.

Tabla 1

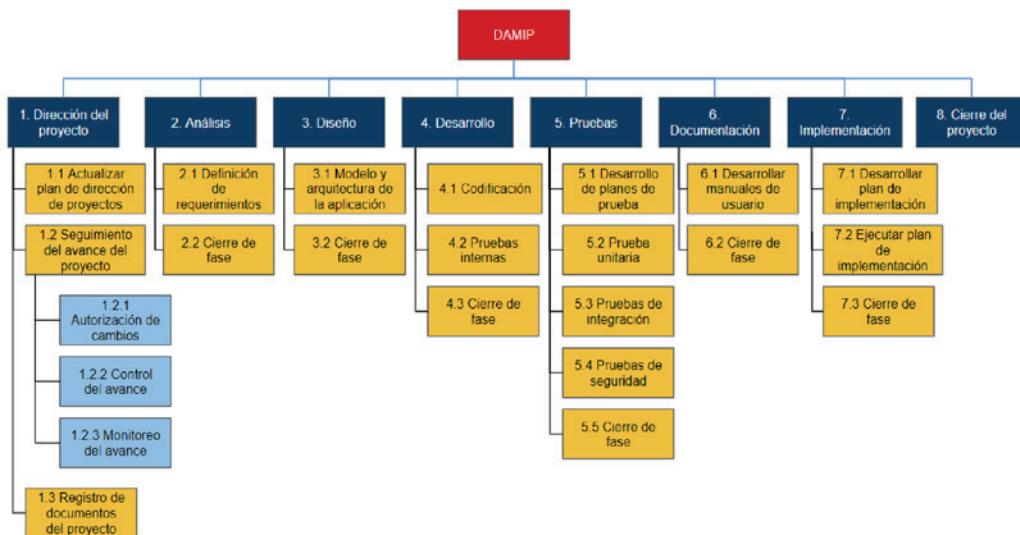
Descripción del alcance

Descripción del alcance del producto	
Concepto	Objetivos
Desarrollar una aplicación intuitiva en la que el usuario pueda navegar fácilmente.	Proporcionar el diseño de una aplicación intuitiva y fácil de usar
Identificar, por medio del reconocimiento de imágenes que el usuario escaneará por el aplicativo, los medicamentos, para poder brindarle sus detalles.	Identificar los detalles de los medicamentos mediante el reconocimiento de imágenes

La estructura de desglose de trabajo (EDT) también es imprescindible, debido a que desgrega el trabajo necesario para completar un proyecto. Esta EDT se muestra en la Figura 2.

Figura 2

Estructura de desglose de trabajo (EDT) de AI-Pills



Se definieron ocho niveles en la EDT. El primero es la dirección del proyecto, que se desglosa en la actualización del plan de dirección del proyecto, el seguimiento del avance y el registro de documentos del proyecto, considerando que el plan ya está realizado. Los demás niveles se elaboraron en base a las fases que se requieren para el desarrollo de un aplicativo: análisis, diseño, desarrollo, pruebas, documentación e implementación. Como último nivel se tiene el cierre del proyecto, para asegurar la culminación de todas las actividades y el cumplimiento del alcance definido.

De acuerdo a la gestión del cronograma, se estima que el proyecto tome un total de tres meses y medio, con ocho personas que se encargarán del desarrollo del aplicativo y un director de proyectos, que garantizará el uso de las mejores prácticas para obtener los resultados esperados.

Para el diseño del prototipo, como se mencionó anteriormente, se optó por emplear el marco de trabajo SCRUM, en el que se definieron los *sprints* del proyecto. Estos se detallan a continuación.

2.2 *Sprint* del proyecto

En el marco de trabajo SCRUM se definen los *sprint* del proyecto, que son trabajos que el equipo tiene que realizar en períodos cortos de tiempo. Dentro de las tareas de los *sprint* se aplicó la metodología *Atomic Design* (Busquets, s/f). Los *sprint* están establecidos en cuatro niveles para el desarrollo del aplicativo:

- 1) Nivel 1. Se realizan los átomos: paleta cromática, botones, tipografía, encabezados, entre otros.
- 2) Nivel 2. Se realizan las moléculas, que son las uniones de los átomos establecidos en el nivel 1.
- 3) Nivel 3. Se realizan los organismos: uniones de moléculas realizadas en el nivel 2. En este punto se obtienen la interfaz de inicio de sesión, la de registro, la de perfil del usuario, la interfaz principal del aplicativo, la de escaneo y la interfaz de los detalles de la identificación de pastillas.
- 4) Nivel 4. Se realizan las *templates* finales del aplicativo y las relaciones para las interfaces con los botones, que se centran principalmente en el funcionamiento del aplicativo: cada vez que el cliente toque un botón del aplicativo, se debe redirigir a la interfaz conectada con el botón.

Los *sprint* definidos para el proyecto se verán a continuación.

2.2.1 Sprint 1

El objetivo del *sprint 1* es elaborar los átomos y moléculas basados en la metodología del *atomic design*. Estos átomos y moléculas contienen la tipografía, encabezados, íconos, botones, logos, etcétera. Los átomos son las pequeñas unidades definidas para el aplicativo, y las moléculas vienen a ser las uniones de estos átomos, con lo cual el aplicativo se construye como un rompecabezas. En la Tabla 2 podemos apreciar las historias de usuarios realizadas para este *sprint*.

Tabla 2

Sprint 1

HU	Actividad
HU01	Elaborar Nivel 1 de Atomic Design: tipografía, encabezados e íconos
HU02	Elaborar Nivel 1 de Atomic Design: paleta cromática, botones y otros
HU03	Elaborar Nivel 2 de Atomic Design: moléculas (contenedores principales)
HU04	Elaborar Nivel 2 de Atomic Design: moléculas (contenedores secundarios y botones)

2.2.2 Sprint 2

El objetivo del *sprint 2* es realizar las plantillas y pantallas del aplicativo móvil, esbozando su diseño y las funcionalidades que tendrán. Esta tarea se realizará siguiendo los niveles 3 y 4 de la metodología de *Atomic Design*. En la Tabla 3 podemos apreciar las historias de usuarios realizadas para este *sprint*.

Tabla 3

Sprint 2

HU	Actividad
HU04	Elaborar Nivel 3 de Atomic Design: pantalla principal, escaneo e identificación de pastillas.
HU05	Elaborar Nivel 3 de Atomic Design: página de inicio de sesión, registro y perfil.
HU06	Elaborar Nivel 4 de Atomic Design: templates

2.2.3 Sprint 3

El objetivo del *sprint 3* es realizar las modificaciones del prototipo y añadir funcionalidades nuevas al aplicativo. Esto se logró gracias a que, luego de entregar el prototipo como producto mínimo viable (*minimum viable product - MVP*) a los *stakeholders*, nos brindaron *feedback* para crear una mejor versión. En la Tabla 4 podemos apreciar las historias de usuarios realizadas para este *sprint*.

Tabla 4

Sprint 3

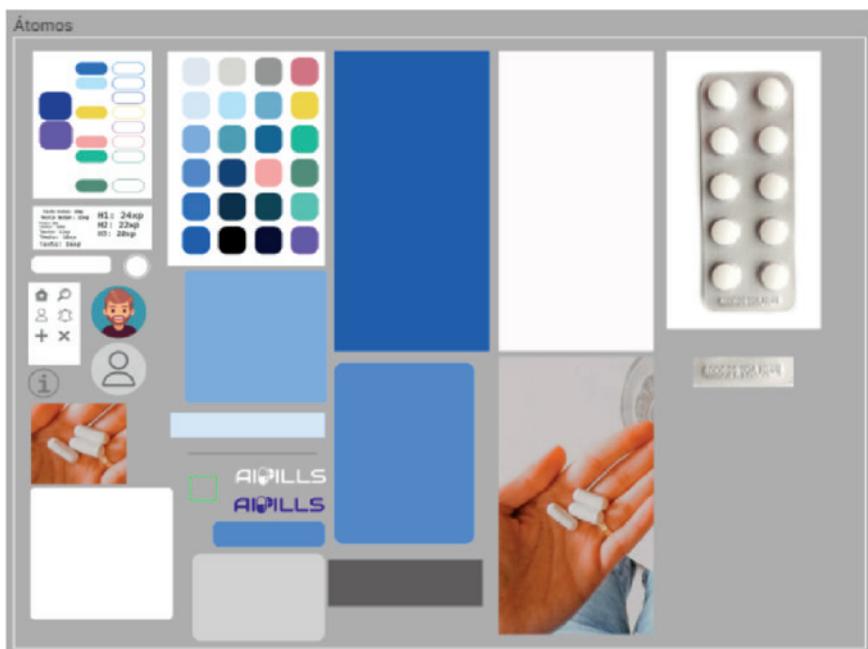
HU	Actividad
HU07	Modificar componentes del prototipo en base al feedback
HU08	Añadir funcionalidad respecto al reconocimiento de fecha de vencimiento

3. RESULTADOS

Con los *sprints* desarrollamos todos los niveles del *Atomic Design*, lo cual facilitó el diseño del prototipo, al ya tener una guía de estilos definida y los componentes necesarios listos para usar. En la Figura 3 podemos apreciar el resultado logrado a nivel del prototipo con el primer *sprint*.

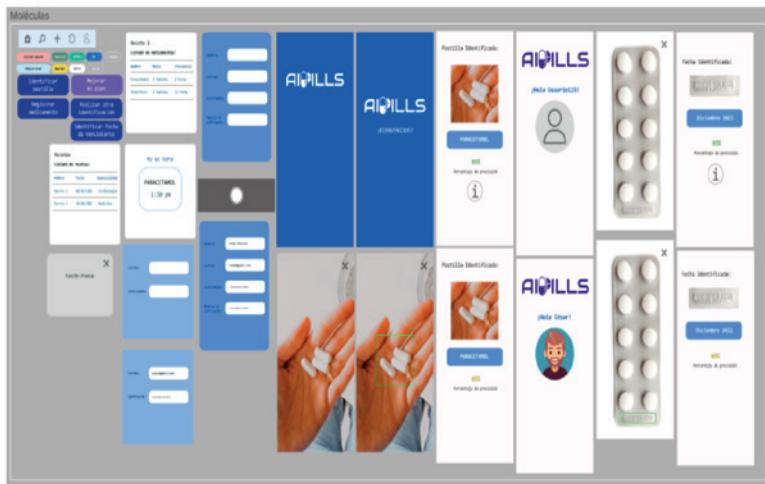
Figura 3

Nivel 1 del prototipo



En la Figura 4 podemos apreciar el resultado logrado a nivel del prototipo con el segundo *sprint*.

Figura 4
Nivel 2 del prototipo



En la Figura 5 puede apreciarse el resultado logrado a nivel del prototipo con el tercer *sprint*.

Figura 5
Nivel 3 del prototipo



Con los componentes listos, se procedió a relacionar todos los componentes para tener un MVP funcional, que permita apreciar el funcionamiento esperado de la aplicación propuesta. Las figuras 6 y 7 nos muestran una simulación de la aplicación de nuestro proyecto.

Figura 6
Prototipo – Identificación de pastilla

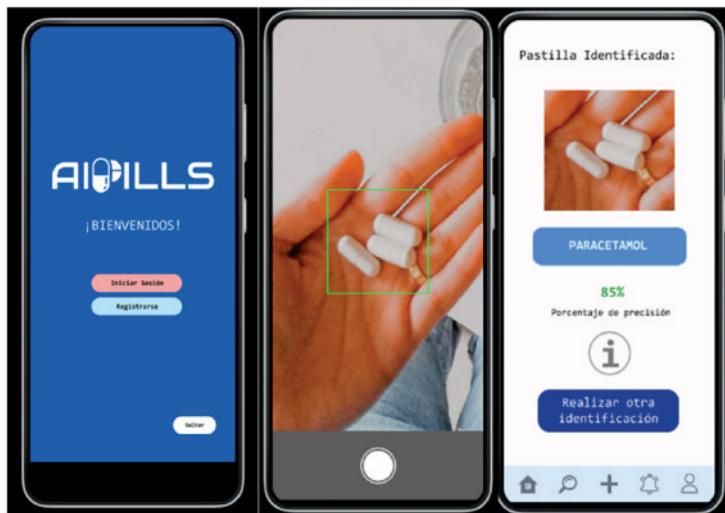


Figura 7
Prototipo – Identificación de fecha de vencimiento



4. DISCUSIÓN

El enfoque integrado de la Guía PMBOK y SCRUM, respaldado por el modelo Canvas, demostró ser una combinación poderosa y eficiente para desarrollar el aplicativo AI-Pills. Además, el uso de la metodología de *atomic design* durante los *sprints* aseguró un avance progresivo, estructurado y coherente en la creación del prototipo. También fue importante la participación activa de los *stakeholders* y su retroalimentación directa, pues permitió realizar mejoras significativas en el aplicativo, para así garantizar su relevancia y efectividad para los usuarios.

Finalmente, los resultados obtenidos respaldan la viabilidad y eficacia del enfoque adoptado, así como la promesa de un aplicativo innovador y altamente funcional en el campo de la salud y el bienestar.

5. CONCLUSIONES

La aplicación AI-Pills representa una solución innovadora para abordar la problemática de identificación de pastillas en adultos mayores y personas con dificultades visuales. Aunque no se llegó a implementar el reconocimiento de imágenes, su enfoque (proporcionar información precisa sobre medicamentos) sigue siendo valioso para mejorar la seguridad y la efectividad del tratamiento médico.

Dado que se trata solo de un prototipo, no se realizó un análisis de base de datos. Sin embargo, en futuras etapas de desarrollo, se considera crucial trabajar en la construcción de una sólida base de datos de imágenes y algoritmos de reconocimiento para garantizar la precisión en la identificación de pastillas.

AI-Pills tiene el potencial de impactar positivamente la vida de las personas con dificultades visuales, brindándoles mayor autonomía y seguridad en la administración de sus medicamentos. Al proporcionar información detallada sobre la dosis recomendada, posibles efectos secundarios y otras advertencias importantes, la aplicación se convierte en una herramienta valiosa para mejorar la adherencia al tratamiento y minimizar riesgos asociados.

El potencial éxito de AI-Pills depende no solo del desarrollo tecnológico, sino también de la colaboración y participación activa de los usuarios y profesionales de la salud, pues la retroalimentación y validación continua por parte de los usuarios han sido esenciales para mejorar la usabilidad y la efectividad de la aplicación, adaptándola a las necesidades reales.

REFERENCIAS

- Busquets, C. (s/f). *Atomic design: qué es y qué ventajas tiene*. uiFromMars. <https://www.uifrommars.com/atomic-design-ventajas/>

Project Management Institute (2017). *Guía de los fundamentos para la dirección de proyectos – Guía del PMBOK* (6ta ed.).

Rouhiainen, L. (2018). *Inteligencia artificial. 101 cosas que debes saber hoy sobre nuestro futuro.* Alienta Editorial.

DATOS DE LOS AUTORES

MUSHTAQ BILAL

Investigador postdoctoral en el Centro Hans Christian Andersen de la Universidad del Sur de Dinamarca. Posee un doctorado en Literatura Comparada de la Universidad de Binghamton en Nueva York. Su trabajo ha sido publicado en revistas académicas y también en periódicos, como The Washington Post y el LA Times. Mushtaq cuenta con una audiencia en línea de 250,000 seguidores en Twitter y LinkedIn, donde escribe sobre simplificar el proceso de redacción académica. Es frecuentemente invitado para dar charlas en las principales universidades en los Estados Unidos, Europa y Asia del Sur.

NELLY CONDORI-FERNÁNDEZ

Trabaja actualmente como profesora asistente en la Universidad de Santiago de Compostela. También es investigadora asociada en la Vrije Universiteit Amsterdam, y realiza investigaciones en ingeniería de *software*, sistemas de información (informática empresarial) e interacción humano-computadora. Sus principales publicaciones están relacionadas con la sostenibilidad del *software*, la ingeniería de requisitos, la experiencia del usuario y cómo potenciar la capacidad de autoadaptación de los servicios de *software* a través de algoritmos de inteligencia artificial. Además, ha participado activamente como revisora y editora en revistas científicas.

PAOLA D. BUDÁN

Doctora en Ciencias de la Computación, investigadora de la Universidad Nacional del Chaco Austral (UNCAUS) y de la Universidad Nacional de Santiago del Estero (UNSE), Argentina. Docente de ambas universidades. Además, es becaria postdoctoral de CONICET

- Universidad Nacional del Sur (UNS), Argentina, en la cual investiga la formalización de patrones de razonamiento y sus implicancias prácticas en las redes sociales.

PATRICIA P. ZACHMAN

Doctora en Ingeniería con mención en ingeniería industrial. Investigadora de la Universidad Nacional del Chaco Austral (UNCAUS), Argentina. Directora de la carrera de Ingeniería en Sistemas de Información y de la Unidad de Vinculación Tecnológica dependiente de Investigación, Ciencia y Técnica de UNCAUS.

RUBÉN E. ANDREU

Licenciado en Matemática. Docente e investigador de la Universidad Nacional del Chaco Austral (UNCAUS), Argentina. Investigador en algoritmos genéticos de UNCAUS. Docente de Ingeniería en Sistemas de Información.

PABLO E. CAMPESTRINI

Ingeniero en Sistemas. Becario en Investigación de la Universidad Nacional del Chaco Austral (UNCAUS), Argentina. Integra el equipo de cátedra de Inteligencia Artificial de la Ingeniería en Sistemas de la UNCAUS. Desarrollador *freelance*.

EMMANUEL I. CHÁVEZ.

Ingeniero en Sistemas de Información. Desarrollador *freelance*.

ANGELO RODRIGO TACO JIMENEZ

Estudiante de Ingeniería de Sistemas en la Universidad de Lima, Perú. Su inclinación principal es hacia la especialización en ingeniería de *software* y su meta tanto a nivel personal como profesional es generar un impacto positivo en la sociedad y en su campo de experiencia.

IZABELLA BARROS LOPES

Graduada en Ingeniería de *Software* por el Centro Universitario Alves Faria (UNIALFA), Brasil. Consultora de soluciones personalizadas, se desempeña como desarrolladora *full-stack* en Capgemini. Trabajó como desarrolladora web y móvil durante su pasantía en SICTEC-Secretaría Municipal de Innovación, Ciencia y Tecnología de la Cámara Municipal de Goiânia, en el estado de Goiás. Posee experiencia en desarrollo de *software*, tecnología, planificación y métodos ágiles.

FILIPE ABNER DE ASSIS SANTOS

Graduado en Ingeniería de *Software* por el Centro Universitario Alves Faria (UNIALFA), Brasil. Cuenta con más de diez años de experiencia en el área de desarrollo de *software* y se destaca por su experiencia en pruebas automatizadas; trabaja en la mayor empresa de recursos humanos de Brasil. Es co-fundador e ingeniero de *software* de Sistema Cotar, plataforma especializada en compras que atiende a las principales empresas constructoras del estado de Goiás. Responsable de garantizar la confiabilidad del sistema y compromiso constante con la calidad y la satisfacción del cliente.

SHARON ROSE CANDINI E SILVA

Graduada en Ingeniería de *Software* por el Centro Universitario Alves Faria (UNIALFA), Brasil. Investigadora en el campo de la inteligencia artificial aplicada. Consultora en gestión de negocios con tecnología.

MARCOS DIAS DE PAULA

Máster en Negocios Internacionales por la Miami University of Science and Technology, MBA en Consultoría de Negocios, Especialista en Gestión Empresarial, Especialista en Metodología de la Educación Superior. Tiene formación en Consultoría por el ITA (Instituto de Tecnología Aeronáutica), formación en Gestión de Marketing Estratégico por la Escuela Superior de Publicidad y Marketing y formación en Gestión de la Innovación en INOVA UNICAMP, Brasil. Es profesor titular de Inteligencia Artificial, coordinador del Área de Tecnologías de la Información, Coordinador del MBA en Ciencia de Datos, Análisis de Datos e Inteligencia de Negocios y MBA en Gestión e Innovación de Ciudades Inteligentes del Centro Universitario Alves Faria (UNIALFA), Brasil.

LELIS RAQUEL ATENCIA MONDRAGON

Estudiante de Ingeniería de Sistemas en la Universidad de Lima, Perú. Interesada en temas relacionados con la ingeniería y el análisis de datos. Su objetivo profesional es desarrollar sus capacidades de programación con el fin de poder impactar de manera positiva en la sociedad.

MELANY CRISTINA HUARCAYA CARBAJAL

Estudiante de Ingeniería de Sistemas en la Universidad de Lima, Perú. Con enfoque en análisis de datos y ciencia de datos. Su objetivo es utilizar la tecnología y los datos para impactar positivamente en el bienestar de la sociedad peruana y construir un futuro más saludable y prometedor para todos.

ROSARIO MARYBEL GUZMÁN JIMÉNEZ

Magíster en Ingeniería de Sistemas de la Universidad de Lima e ingeniera de sistemas por la Universidad Católica Santa María de Arequipa. Actualmente cursa un doctorado en la Universidad Femenina del Sagrado Corazón, con un enfoque en pensamiento computacional en la educación. Es coordinadora de la Oficina de Títulos en la Facultad de Ingeniería de Sistemas de la Universidad de Lima y tiene más de veinte años como profesora investigadora especializada en bases de datos, procesos comerciales y sistemas ERP. Profesora investigadora del Instituto de Investigación Científica de la Universidad de Lima.

VÍCTOR DANIEL GIL VERA

Doctor en Ingeniería de Sistemas de la Universidad Nacional de Colombia. Se desempeña como docente e investigador en la Universidad Católica Luis Amigó en la ciudad de Medellín. Sus principales líneas de investigación son la analítica de datos y la modelación estadística. Ha participado en congresos nacionales e internacionales y cuenta con publicaciones científicas en revistas de alto impacto.

MARCOS HENRIQUE CARVALHO SILVA

Magíster y licenciado en Ingeniería por la Escuela Politécnica de la Universidad de São Paulo. Actualmente, cursa un doctorado en Ingeniería Eléctrica en la misma institución. Como investigador en el Laboratorio de Bioenergía y Eficiencia Energética del Instituto de Investigación Tecnológica de São Paulo, Marcos está involucrado en el proyecto ROTA 2030. Su enfoque se centra en adaptar motores para funcionar con combustibles renovables. Tiene experiencia en el diseño de estrategias de control y arquitectura automotriz y desarrolla soluciones innovadoras para la industria automotriz.

ANDRÉ VINÍCIUS OLIVEIRA MAGGIO

Magíster y licenciado en Ingeniería Eléctrica por la Universidad de São Paulo. Se especializa en sistemas electrónicos y ha centrado su interés en la simulación de hardware en bucle cerrado de un motor de combustión Flex. Fue becario de CAPES y fue supervisado por el profesor João Francisco Justo Filho y por el profesor Armando Antônio Maria Laganá. Actualmente, cursa un doctorado en Ingeniería Eléctrica en la Universidad de São Paulo, también como becario CAPES.

ARMANDO ANTONIO MARIA LAGANÁ

Doctor en Ingeniería Eléctrica por la Escuela Politécnica de la Universidad de São Paulo e ingeniería eléctrica por la Escuela de Ingeniería Mauá. Tiene una amplia experiencia en materiales y procesos de microelectrónica. Actualmente, ocupa el cargo de profesor en el Departamento de

Ingeniería de Sistemas Electrónicos de la Escuela Politécnica de la Universidad de São Paulo. Su trabajo se centra principalmente en el campo de la electrónica automotriz, con un énfasis especial en el control del motor.

JOÃO FRANCISCO JUSTO

Doctor en Ingeniería Nuclear por el Instituto de Tecnología de Massachusetts, magíster en Ciencias con mención en Física y licenciado en Ciencias Físicas por la Universidad de São Paulo. Actualmente es profesor titular en la Escuela Politécnica de la Universidad de São Paulo. Fue profesor asociado visitante en la Universidad de Minnesota (2007-2008). Es miembro de pleno derecho de la Sociedad de Honor Sigma Xi desde 1999. Tiene experiencia en modelado computacional de nanomateriales y electrónica integrada.

BRUNO SILVA PEREIRA

Es candidato a doctorado en Ingeniería Eléctrica en la Universidad de São Paulo, con especialización en unidades de control y sistemas automotrices para el manejo electrónico del motor. Es investigador en el Laboratorio de Bioenergía y Eficiencia Energética en el Instituto de Investigación Tecnológica de São Paulo. Trabajó como desarrollador en LSI-TEC, el Laboratorio de Sistemas Tecnológicos Integrables, donde adquirió experiencia en el desarrollo de soluciones innovadoras.

DEMERSON MOSCARDINI

Tiene formación en tecnología de electrónica automotriz y electrónica. Actualmente, trabaja como investigador asociado en la Universidad de São Paulo. Sus actividades incluyen brindar apoyo práctico en el ensamblaje y mantenimiento de motores y vehículos, asistir en pruebas prácticas para proyectos y artículos de estudiantes, así como ofrecer apoyo en clases prácticas.

CAROLINA ALIAGA:

Bachiller en Ingeniería de Sistemas por la Universidad Nacional de Ingeniería, Perú. Se desempeña en la gestión financiera de la nube, donde aplica analítica para asegurar un uso eficiente de los recursos.

JESÚS DOMINGUEZ:

Estudiante de Ingeniería de Sistemas en la Universidad Nacional de Ingeniería, Perú. Le gusta ser solidario y trabajar en equipo cuando se le es necesario. Tiene intereses en la inteligencia artificial y aplicativos móviles.

IRIS LIÑA

Estudiante de la Universidad Nacional de Ingeniería, Perú, con una pasión por la inteligencia artificial y el reconocimiento de imágenes. Destaca por su enfoque innovador en proyectos de investigación.

JAVIER ACUÑA

Egresado de la Universidad Nacional de Ingeniería, Perú, con un fuerte interés en el desarrollo de aplicativos móviles. Destaca por su creatividad y dedicación para la resolución de problemas.



UNIVERSIDAD
DE LIMA