

CONGRESOS Y CURSOS



Editores:  
JESÚS ENRIQUE SIERRA GARCÍA  
MARIO PEÑACOPA YAGÜE  
PEDRO J. CABRERA SANTANA

# XIX SIMPOSIO CEA DE CONTROL INTELIGENTE LIBRO DE ACTAS



UNIVERSIDAD  
DE BURGOS





**XIX SIMPOSIO CEA DE CONTROL INTELIGENTE.  
LIBRO DE ACTAS**



EDITORES:

JESÚS ENRIQUE SIERRA GARCÍA

MARIO PEÑACOBIA YAGÜE

PEDRO J. CABRERA SANTANA

**XIX SIMPOSIO CEA  
DE CONTROL INTELIGENTE  
LIBRO DE ACTAS**



**UNIVERSIDAD  
DE BURGOS**

2025

(CONGRESOS Y CURSOS, 84)

**XIX Simposio CEA de Control Inteligente**

Reunión anual del grupo de Control Inteligente del comité español de automática (CEA)

Universidad de Burgos, 19-21 de junio de 2024.



Imagen de cubierta: [Stock.adobe.com](https://www.stock.adobe.com). Por Degimages. Generado con IA

© LOS AUTORES

© UNIVERSIDAD DE BURGOS

Edita: Servicio de Publicaciones e Imagen Institucional  
UNIVERSIDAD DE BURGOS  
Edificio de Administración y Servicios  
C/ Don Juan de Austria, 1  
09001 BURGOS - ESPAÑA

ISBN: 978-84-18465-97-0

DOI: <https://doi.org/10.36443/9788418465970>

Esta obra está bajo una licencia de Creative Commons  
[Atribución-NoComercial-SinDerivadas 4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)



## PROGRAMA

---

### Día 1. Miércoles 19 de junio

- **16:30** Recogida de documentación
- **17:00** Sesión de apertura del simposio. **Lugar:** Biblioteca Universitaria
- **17:30** Conferencia plenaria I. Propiedad Industrial en la Industria. Retos y oportunidades en la implantación de la IA y la industria 4.0. (Luis Ignacio Vicente del Olmo, ABB-Pons IP). **Lugar:** Biblioteca Universitaria
- **20:15** Actividad de ocio I. Visita al casco histórico de Burgos. **Punto de encuentro:** Teatro Principal de Burgos.
- **22:00** Cocktail de bienvenida. **Lugar:** Hotel NH Collection Palacio de Burgos

### Día 2. Jueves 20 de junio

- **8:30** Recogida de documentación
- **9:00** Conferencia plenaria II. IA y el Diseño Basado en Modelos: Aprendizaje por Refuerzo. (Miguel Alonso, Mathworks). **Lugar:** Biblioteca Universitaria
- **10:00** Conferencia plenaria III. En Aranda, Michelin fabrica el futuro (Miguel Ruano, Michelin). **Lugar:** Biblioteca Universitaria
- **10:45** Conferencia plenaria IV. Vehículo autónomo y conectado (Jorge Alcalde García, ITCL). **Lugar:** Biblioteca Universitaria
- **11:30** Sesión de Posters/ Café
- **12:00** Conferencia plenaria V. Modelling with Gaussian Processes (Juš Kocijan, Jozef Stefan Institute-University of Nova Gorica). **Lugar:** Biblioteca Universitaria
- **13:30** Visita laboratorios: Laboratorio de robótica y Laboratorio de tecnologías del hidrógeno. **Lugar:** EPS Milanera
- **14:30** Comida de trabajo. **Lugar:** Restaurante Bellavista
- **16:30** Presentaciones doctorandos. **Lugar:** EPS Milanera aula C01-02
- **18:50** Actividad de ocio II. [Visita guiada a las Bodegas Buezo](#). Salidas en Bus: Teatro Principal de Burgos o EPS Milanera
- **21:00** Cena de gala. **Lugar:** Bodegas Buezo (Mahamud)

### Día 3. Viernes 21 de junio

- **10:00** Finalistas Premio IDOM a la mejor Tesis Doctoral (I). **Lugar:** Biblioteca Universitaria
- **10:40** Sesión de Posters / Café
- **11:15** Finalistas Premio IDOM a la mejor Tesis Doctoral (II y III). **Lugar:** Biblioteca Universitaria
- **12:45** Reunión Grupo Temático CEA. **Lugar:** Biblioteca Universitaria
- **13:15** Acto de Clausura
- **14:00** Comida de Trabajo / Despedida





## **COMITÉ ORGANIZADOR**

---

Jesús Enrique Sierra García

Daniel Sarabia Ortiz

Alejandro Merino Gómez

Rubén Ruiz González

Juan Vicente Martín Fraile

Mario Peñacoba Yagüe

Eduardo Quevedo Dueñas

Eduardo Bayona Blanco

## **COMITÉ CIENTÍFICO-TÉCNICO**

---

Jesús Enrique Sierra García

Pedro Jesús Cabrera Santana

Juan Manuel Escaño

Matilde Santos

Eloy Irigoyen Gordo

José Luis Calvo-Rolle

Basil M. Al-Hadithi

Daniel Galán Vicente

Eduardo Martínez Cámara

Javier Sanchis Saez

Emilio Jiménez Macías

José Manuel Andujar Márquez

Vicente Gómez Garay



## ÍNDICE

---

PRÓLOGO .....	13
CONFERENCIAS.....	15
Hacia la optimización de trayectorias de robots colaborativos mediante algoritmos genéticos .....	17
Peñacoba, M.; Sierra-García, J. E.; Santos, M.	
Control predictivo basado en modelo de red neuronal. Aplicación al control de procesos no lineales .....	21
J. Sendra; J. Sanchis; L. Iturbe; M. Larrea; E. Irigoyen	
Selección de la tecnología de visión más adecuada para paletizado .....	27
Moreno-Román, G.; Sierra-García, J.E.	
Fuzzy speed estimator for drives using optical encoders .....	33
Satué, M.G.; Escaño J.M.; Colodro, F.	
Nuevo algoritmo de entrenamiento híbrido para modelos neuronales de sistemas dinámicos .....	39
Iturbe, Lucía; Irigoyen, Eloy; Larrea, Mikel; Sendra, Javier; Sanchis, Javier	
Análisis del rendimiento de un sistema de control avanzado basado en el estándar IEC 61499.....	45
Guzmán González-Mateos, Miguel A. Prada, Antonio Morán, Raúl González-Herbón, José R. Rodríguez-Ossorio, Manuel Domínguez	
Enfoque Centrado en el Humano para el Gemelo Digital de la Colaboración Humano-Máquina/Robot en una Línea Piloto de Industria 5.0.....	51
Alfaro, Diego.; Castaño, Fernando; Cruz, Yarens J.; Villalonga, Alberto; Haber, Rodolfo E.	
La docencia en ingeniería de control frente a la inteligencia artificial generative .....	57
Barragán, A. Javier; Segura, Francisca; Martínez, Miguel A.; Andújar, José M.	
Modelado de un Acumulador de Energía Dinámico Mediante Volante de Inercia en Simulink .....	63
Torres, Juan Carlos; Douairi, Hamza; González, Jaime; Carta, José Antonio; Cabrera, Pedro	
Modelo lineal de pérdidas de un volante de inercia .....	69
Douairi, Hamza; Torres-Bordón, Juan Carlos; Carta, José Antonio; Cabrera, Pedro.	

Modelos de predicción neuro-borrosos para un aerogenerador en una planta de fabricación industrial .....	75
Chicaiza, W.D.; Gómez, J.; Camacho, P.G.; Escaño, J.M.	
Integration of artificial intelligence with automation for predictive maintenance in sustainable hydrogen production plants.....	81
Abiola, A O.; Segura, F M.; Andújar, J M.; Barragán, A. J.	
Hacia la gestión de comunidades energéticas con Aprendizaje por Refuerzo .....	89
Arnay del Arco, R.; Riverón-Miranda, I.; Hamilton-Castro, A.; Torres-Álvarez, S.; González-Cava, J.M.; Castilla, I.; González Díaz, B.; Méndez-Pérez, J.A.	
Ajuste multiobjetivo de PIDs robustos para el control de temperatura de una pila tipo PEM .....	92
Veyna, U.; Blasco, X.; Herrero, J.M.; Pajares, A.; Ramos, C.	

## **PRÓLOGO**

---

Al igual que en las ediciones anteriores, el XIX Simposio CEA de Control Inteligente ha tratado de mantener los objetivos propuestos por el Grupo Temático de CEA y desarrollar unas jornadas de convivencia en las que se han desarrollado actividades científicas de investigación, de formación de doctores, de relaciones con la industria y, por supuesto, actividades culturales y de relaciones sociales de todos los miembros que formamos esta comunidad científica.

Este año, el lugar elegido para la celebración del Simposio ha sido la ciudad de Burgos y le ha correspondido la organización de este al área de Ingeniería de Sistemas y Automática de la Universidad de Burgos. Con 48 asistentes, hemos conseguido generar un ambiente más que propicio para desarrollar distintas discusiones científicas de gran calado. Esto demuestra el interés que suscita nuestra disciplina en estos tiempos. Durante los últimos años el control inteligente está demostrando ser una herramienta esencial para contribuir a solucionar los grandes retos que se nos van a plantear en el futuro. Pero, hasta la fecha no habíamos experimentado, tan de primera mano, los efectos derivados del cambio climático, la falta de recursos energéticos y de materias primas, las pandemias, la falta de recursos hídricos, la ciberseguridad o los incendios. Por ello, más que nunca se antoja necesario reflexionar, reforzar nuestros vínculos o crear nuevas sinergias para contribuir y poner nuestro valioso conocimiento a disposición de nuestra sociedad. En este sentido nos sentimos orgullosos de presentar las contribuciones tan valiosas que recoge este documento. Estas han superado todas nuestras expectativas, lo que da muestras del sentido de responsabilidad que tiene el Grupo Temático CEA de Control Inteligente con su tiempo.

¡MUCHAS GRACIAS A TODOS!

Pedro Cabrera  
Coordinador del Grupo Temático CEA de Control Inteligente



CONFERENCIAS

---





## Hacia la optimización de trayectorias de robots colaborativos mediante algoritmos genéticos

Peñacoba, M.<sup>a</sup>, Sierra-García, J. E.<sup>a</sup>, Santos, M.<sup>b</sup>

<sup>a</sup> Escuela Politécnica Superior, Universidad de Burgos, Avda. Cantabria, s/n, 09006 Burgos, España.

<sup>b</sup> Instituto de Tecnología del Conocimiento, Universidad Complutense de Madrid, Calle del Prof. José García Santesmases, 9, 28040, Madrid, España

**To cite this article:** Peñacoba, M., Sierra, J., Santos, M. 2024. Towards the Optimization of Cobot Trajectories Using Genetic Algorithms. XIX Simposio CEA de Control Inteligente. 2024.

### Resumen

Este trabajo en curso se enfoca en la optimización de las trayectorias de un robot CRB15000 mediante un algoritmo genético. Para ello, se ha desarrollado un protocolo de comunicación entre el controlador en una computadora y el robot. La trayectoria se ejecutará en un entorno de gemelo digital (RobotStudio), donde se simularán posibles colisiones y se analizará el espacio recorrido por el extremo del robot. La información obtenida será transmitida a la computadora a través del protocolo de comunicación, permitiendo al algoritmo genético optimizar la trayectoria del robot para alcanzar un objeto de manera más eficiente. Esta metodología no solo busca minimizar las colisiones y el recorrido del efector final, sino también mejorar la eficiencia operativa del robot en entornos complejos. Los resultados esperados incluyen una trayectoria optimizada que reduce significativamente el tiempo y los recursos necesarios para completar las tareas asignadas al robot, incrementando así su eficacia y productividad.

*Palabras clave:* Algoritmo genético, optimización, robótica, gemelo digital.

### Towards the Optimization of Cobot Trajectories Using Genetic Algorithms

#### Abstract

This ongoing work focuses on optimizing the trajectories of a CRB15000 robot using a genetic algorithm. To achieve this, a communication protocol has been developed between the controller implemented on a computer and the robot. The trajectory execution will take place in a digital twin environment (RobotStudio), where simulated information on potential collisions and the space traversed by the robot's end effector will be obtained. This information will be transmitted to the computer via the communication protocol, allowing the genetic algorithm to optimize the robot's trajectory to reach an object more efficiently. This methodology aims not only to minimize collisions and the end effector's travel but also to enhance the robot's operational efficiency in complex environments. The expected outcomes include an optimized trajectory that significantly reduces the time and resources required to complete the tasks assigned to the robot, thus increasing its effectiveness and productivity.

*Keywords:* Genetic algorithm, optimization, robotics, digital twin.

### 1. Introducción

La robótica industrial ha sido uno de los sectores más dinámicos y de rápido crecimiento en las últimas décadas, consolidándose como la clave para una industria más eficaz y competitiva. Además, impulsada por la necesidad de incrementar la eficiencia y la productividad en diversos sectores, la robótica ha transformado radicalmente los procesos industriales. En la actualidad, más allá de los eficientes autómatas, la tendencia apunta hacia la robótica colaborativa. Los robots colaborativos, o cobots, han emergido como una solución revolucionaria que permite la interacción segura y eficiente entre humanos y robots. Dentro de este

ámbito, la optimización de trayectorias, ya sea de robots industriales o cobots, es un área de vital importancia (Chen and Wen, 2021). Una trayectoria eficiente no solo minimiza el tiempo y los recursos empleados, sino que también reduce el desgaste del equipo y las probabilidades de colisión. Esto, a su vez, mejora la seguridad operativa y facilita una colaboración más fluida entre humanos y robots, consolidando el papel de los cobots como aliados esenciales en la industria del futuro.

En particular, en este estudio se ha utilizado el robot colaborativo CRB15000, conocido por su versatilidad y precisión, lo que le convierte en un candidato ideal para la implementación de técnicas avanzadas de control en las que se

han empleado técnicas metaheurísticas para optimización de trayectorias.

Una de las metodologías más prometedoras en este ámbito es el uso de algoritmos genéticos (Katic, D et al., 2003). Estos algoritmos, inspirados en los procesos de evolución natural, son capaces de explorar un amplio espacio de soluciones y converger hacia una óptima de manera eficiente. Al aplicar un algoritmo genético para la optimización de las trayectorias del CRB15000 se pretende encontrar rutas que minimicen el riesgo de colisiones y el recorrido del efector final, así como también mejorar la eficiencia operativa en entornos complejos (Manikas, T. W et al., 2007).

Para llevar a cabo este estudio, se ha desarrollado un protocolo de comunicación entre el controlador de la computadora y el robot. La implementación se realizará en un entorno de gemelo digital utilizando RobotStudio para simular las trayectorias del robot. Este entorno permitirá la detección de posibles colisiones y el análisis del espacio recorrido por el extremo del robot. La información obtenida de estas simulaciones será transmitida a la computadora mediante el protocolo de comunicación implementado, permitiendo que el algoritmo genético procese los datos y optimice la trayectoria del robot. Se espera que esta metodología conduzca a la obtención de trayectorias eficientes en términos de tiempo y recursos, incrementando significativamente la productividad y eficacia del robot CRB15000. Además, el método propuesto en este trabajo podrá ser extrapolado a cualquier otro robot, permitiendo implementar los avances conseguidos en cualquier robot industrial o cobot, independientemente de su marca o modelo.

En resumen, este trabajo se centra en la aplicación de un algoritmo genético para la optimización de trayectorias de un robot industrial, utilizando un gemelo digital para simular y analizar las trayectorias. Los pasos clave incluyen el desarrollo de un protocolo de comunicación, la simulación en RobotStudio, la transmisión de datos y la optimización mediante el algoritmo genético. Los resultados esperados incluyen una mejora significativa en la eficiencia operativa y la reducción de colisiones y recursos empleados.

## 2. Metodología

### 2.1 Protocolo de comunicación

El robot CRB15000 está equipado con un módulo denominado EGM (Externally Guided Motion) (Mao, Y et al., 2018), que permite la comunicación externa con el robot. En este estudio, los datos de posición tanto enviados como recibidos al robot se gestionarán utilizando dicho módulo, el cual integra un protocolo de comunicación UDPUC (Obal and Gierlak, 2021). A través de este protocolo, se recibirán coordenadas cartesianas de la herramienta del robot, ángulos de Euler y posibles colisiones detectadas en el gemelo digital. Este proceso será implementado utilizando la dirección de bucle interno 127.0.0.1, donde el protocolo de comunicación creado en Python 3.8.1 gestionará la transferencia de datos de manera eficiente. Dicho protocolo se ejecutará desde la controladora, un Dell Vostro 5410, que a su vez procesará los datos mediante un algoritmo genético utilizando Matlab (2023b) en el mismo dispositivo (Qian and Dong, 2023). Esta

integración asegura una transición fluida entre las simulaciones digitales y las aplicaciones en el entorno real, optimizando las trayectorias del cobot para mejorar su productividad y eficacia. Se muestra un esquema de la comunicación en la Figura 1.

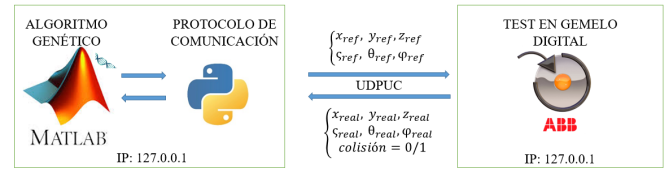


Figura 1: Esquema de comunicación entre el modelo digital del robot y la técnica metaheurística para la optimización de trayectorias.

Inicialmente, el algoritmo genético trabajará con los datos obtenidos del modelo digital en RobotStudio. Este entorno permitirá la simulación y evaluación de las trayectorias del robot, facilitando la identificación de colisiones y el análisis del recorrido del efector final. Una vez que el algoritmo haya determinado la trayectoria más eficiente, esta información se transferirá al robot real para su implementación.

### 2.2 Diagrama de Arquitectura

La arquitectura del sistema se ha implementado como sigue. El algoritmo genético, desarrollado en Matlab, genera trayectorias de referencia  $\{x_{ref}, y_{ref}, z_{ref}, s_{ref}, \theta_{ref}, \phi_{ref}\}$  que se corresponden con las coordenadas cartesianas de la última articulación del robot. Estas son enviadas al módulo de simulación de trayectorias. La simulación, ejecutada en RobotStudio, evalúa estas trayectorias en un entorno de gemelo digital, detectando posibles colisiones y calculando el recorrido del efector final del robot.

Los resultados de dicha simulación se traducen en las coordenadas y ángulos reales, o, en otras palabras, los puntos y ángulos por los que ha pasado el robot  $\{x_{real}, y_{real}, z_{real}, s_{real}, \theta_{real}, \phi_{real}\}$  y las posibles colisiones  $\{colisión\}$  indicadas con un valor binario  $\{0, 1\}$ . Estos datos se transmiten de regreso al algoritmo genético a través de un protocolo de comunicación basado en Python 3.8.1. Este protocolo utiliza la dirección de bucle interno 127.0.0.1 y el protocolo de comunicación UDPUC para garantizar una transferencia de datos eficiente. El diagrama de la arquitectura se muestra en la Figura 2.

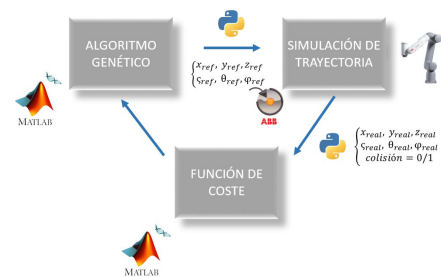


Figura 2: Diagrama de arquitectura

Por último, la función de coste, también implementada en Matlab, evalúa la eficiencia de las trayectorias simuladas en función del tiempo y los recursos empleados, además de la

detección de colisiones. Basándose en esta evaluación, el algoritmo genético ajusta las trayectorias. Este ciclo se repite hasta encontrar la ruta más eficiente. Una vez que se ha determinado la trayectoria óptima en el entorno de simulación, esta se puede transferir al robot real para su implementación, asegurando así una mejora significativa en la productividad y eficacia del robot CRB15000.

### 2.3 Problema de optimización

La optimización de la trayectoria requiere la definición de una función de coste que el algoritmo genético debe minimizar. En este caso, la función de coste estará diseñada para evaluar tres aspectos clave: evitar colisiones, minimizar la distancia de la trayectoria y minimizar el tiempo de operación (Zhang, Y et al., 2023).

Con la comunicación establecida y validada, el siguiente paso en el desarrollo del trabajo es integrar el algoritmo genético. La recopilación y el envío de datos entre los diferentes componentes del sistema ya están implementados con éxito. Ahora, la atención se centrará en la implementación de la optimización metaheurística mediante un algoritmo genético desarrollado en Matlab. Este algoritmo se encargará de procesar los datos obtenidos de las simulaciones en RobotStudio y optimizar las trayectorias del robot en función de una función de coste que evalúa tiempo, recursos empleados y detección de colisiones (Li, Y et al., 2023).

El objetivo del algoritmo de optimización es encontrar una trayectoria que cumpla con los siguientes criterios:

- I. Sin Colisiones: La trayectoria debe evitar cualquier intersección con obstáculos. Este criterio es fundamental para asegurar la seguridad operativa del robot. Si se producen colisiones, el valor de la función de coste será considerablemente alto.
- II. Minimización de la trayectoria recorrida: para obtener una trayectoria optimizada, se debe garantizar un funcionamiento eficaz y, además, un gasto energético mínimo. Esto se traduce en la menor distancia recorrida posible que garantice el correcto funcionamiento de la trayectoria.
- III. Minimización del Tiempo de Operación: La trayectoria debe completarse en el menor tiempo posible, siempre y cuando se cumplan los dos criterios anteriores. Este aspecto está intrínsecamente relacionado con la optimización del espacio y la velocidad operativa del manipulador.

Conociendo estas premisas, se ha definido la función de coste según la ecuación 1. En ella  $D_i$  se corresponde con la distancia entre un punto de paso y el siguiente,  $t_{TOTAL}$  es el tiempo total que tarda en ejecutarse la trayectoria,  $D_{TOTALref}$  es la distancia total que ha recorrido el robot en la trayectoria de referencia a minimizar. Siendo esta una trayectoria que ha ejecutado el operario y se ha utilizado como referencia para que sea mejorada por el algoritmo genético. Por último,  $t_{TOTALref}$  es el tiempo total que ha tardado en ejecutarse dicha trayectoria de referencia.

$$f_c = \begin{cases} 2 + \sum_{i=1}^n D_i + t_{TOTAL} & \text{if collision} \neq 0 \\ \frac{\sum_{i=1}^n D_i}{D_{TOTALref}} + \frac{\sum_{i=1}^n t_{TOTAL}}{\sum_{i=1}^n t_{TOTALref}} & \text{if collision} = 0 \end{cases} \quad (1)$$

La función de coste está definida de tal manera que las trayectorias con colisiones tendrán un valor superior a 2 y las trayectorias sin colisiones un inferior a 2. De esta manera, el algoritmo genético podrá iterar y ajustar las trayectorias hasta encontrar la más eficiente según estos parámetros (Peñacoba, M et al., 2023).

La integración del algoritmo genético permitirá encontrar trayectorias óptimas que eviten colisiones, maximicen la cobertura y minimicen el tiempo de operación, asegurando así una mejora continua en la productividad y eficacia del robot.

### 3. Desarrollo del trabajo

En la fase inicial del proyecto, se ha probado extensivamente la comunicación entre Python y RobotStudio, así como entre Python y el robot real, utilizando el protocolo UDPUC presente en el módulo EGM. Estas pruebas han permitido validar la robustez y la fiabilidad del sistema de comunicación para el intercambio de datos entre el controlador y el robot.

Además, se han realizado pruebas de precisión del robot tanto en modo de control articular como en modo de control cartesiano. Los resultados han mostrado desviaciones menores a 1 mm de precisión en cada eje, lo cual es un indicador positivo de la exactitud y consistencia del sistema en operaciones reales.

Con la comunicación establecida y validada, el siguiente paso en el desarrollo del trabajo es integrar el algoritmo genético. Habiendo sido la recopilación y el envío de datos entre los diferentes componentes del sistema implementados con éxito, ahora, la atención se centrará en la implementación de la optimización metaheurística mediante un algoritmo genético desarrollado en Matlab.

Este algoritmo se encargará de procesar los datos obtenidos de las simulaciones en RobotStudio y optimizar las trayectorias del robot en función de una función de coste que evalúa tiempo, recursos empleados y detección de colisiones. Una vez completada esta fase, se espera que el sistema mejore significativamente la eficiencia operativa del robot CRB15000, tanto en entornos de simulación como en aplicaciones reales.

### Referencias

- Chen, S., & Wen, J. T. (2021). Industrial robot trajectory tracking control using multi-layer neural networks trained by iterative learning control. *Robotics*, 10(1), 50.
- Katic, D., Vukobratovic, M., Katic, D., & Vukobratovic, M. (2003). Genetic Algorithms in Robotics. *Intelligent Control of Robotic Systems*, 113-131.
- Manikas, T. W., Ashenayi, K., & Wainwright, R. L. (2007). Genetic algorithms for autonomous robot navigation. *IEEE Instrumentation & Measurement Magazine*, 10(6), 26-31.
- Mao, Y., Lu, Q., & Xu, Q. (2018). Visual servoing control based on EGM interface of an ABB robot. In *2018 Chinese Automation Congress (CAC)* (pp. 3260-3264). IEEE.
- Obal, P., & Gierlak, P. (2021). EGM Toolbox—Interface for Controlling ABB Robots in Simulink. *Sensors*, 21(22), 7463.

- Qian, Y., & Dong, D. (2023). Servo-based High-speed Alignment Software using EGM Interface. In 2023 IEEE International Conference on Robotics and Biomimetics (ROBIO) (pp. 1-6). IEEE.
- Zhang, Y., Ou, B., Xu, Y., & Dai, C. (2023, April). Path planning of mobile robots based on genetic algorithm. In 2023 8th International Conference on Cloud Computing and Big Data Analytics (ICCCBDA) (pp. 501-505). IEEE.
- Li, Y., Zhao, J., Chen, Z., Xiong, G., & Liu, S. (2023). A robot path planning method based on improved genetic algorithm and improved dynamic window approach. *Sustainability*, 15(5), 4656.
- Peñacoba, M., Sierra-García, J. E., Santos, M., & Mariolis, I. (2023). Path Optimization Using Metaheuristic Techniques for a Surveillance Robot. *Applied Sciences*, 13(20), 11182.

## Control predictivo basado en modelo de red neuronal. Aplicación al control de procesos no lineales.

J. Sendra,<sup>a</sup>, J. Sanchis<sup>a</sup>, L. Iturbe<sup>b</sup>, M. Larrea<sup>b</sup>, E. Irigoyen<sup>b</sup>

*a. Instituto Universitario de Automática e Informática Industrial, Universitat Politècnica de Valencia, Valencia, España.*

*b. Universidad del País Vasco UPV-EHU. Escuela Técnica Superior de Ingeniería. Bilbao. España.*

**To cite this article:** J. Sendra, J. Sanchis, L. Iturbe, M. Larrea, E. Irigoyen. Neural Network Model Predictive Control. Application to non-linear processes. XIX Simposio CEA de Control Inteligente.

### Resumen

Este trabajo presenta el control de dos procesos distintos mediante el control predictivo sobre modelo (MPC), tomando como modelo una red neuronal autorregresiva no lineal con entradas exógenas (NARX). Al tratarse de un MPC no lineal, la solución se encontrará mediante el uso de un algoritmo genético multiobjetivo (MOGA), el cual deberá optimizar las funciones básicas de un MPC. Además, se asegurará el seguimiento sin error de la referencia mediante la realimentación del offset a las predicciones de la red. Este control se ha aplicado a dos procesos SISO diferentes. El primero de ellos es una célula Peltier, en el que se controlará la temperatura de la cara fría de esta a través de la tensión de entrada a dicha célula. En este proceso se comparará la eficiencia del control con un control PID. El segundo proceso es un tanque reactor de agitado continuo (CSTR), del cual se controlará la concentración dentro de dicho tanque, a partir del caudal de entrada. Para esta comparativa, se hará uso de un MPC lineal al uso.

*Palabras clave:* Control no lineal, Redes neuronales, Control basado en modelos, SISO.

### Neural network-based model predictive control and its application to nonlinear process control.

#### Abstract

This work presents the control of two different processes through model predictive control (MPC), taking as said model a nonlinear autoregressive with exogenous inputs (NARX) neural network. Since it is a non-linear MPC, the solution will be found using a multi-objective genetic algorithm (MOGA), which must optimize the basic cost functions of an MPC. In addition, reference tracking will be ensured by feeding the offset back to the network predictions. This control has been applied to two different SISO processes. The first of them is a Peltier cell, in which the temperature of the cold side of the cell will be controlled through the input voltage to said cell. In this process the control efficiency will be compared with a PID control. The second process is a continuous stirred tank reactor (CSTR), of which the concentration within said tank will be controlled, based on the inlet flow. For this comparison, a standard linear MPC will be used.

*Keywords:* Nonlinear control, Neural networks, Model based control, SISO.

### 1. Introducción

El control MPC es uno de los diseños más utilizados para el control de procesos de alta complejidad (Darby and Nikolaou, 2012). Se ha convertido en uno de los controles más populares en las últimas décadas por su alta capacidad para controlar procesos altamente no lineales (Allgower et al., 2004) Una de las desventajas de este diseño es la necesidad de un buen modelo, capaz de replicar el proceso con gran similitud, en uno o varios puntos de operación.

En varios casos, un modelo lineal es suficiente para obtener resultados satisfactorios, pero existen también procesos que no pueden ser controlados por un MPC lineal. Para resolver dicho problema, es posible el uso de un MPC no lineal que, pese a requerir mayor capacidad de computación, es capaz de utilizar un modelo más representativo del proceso a controlar.

Sin embargo, los modelos necesarios para el uso de este diseño tienen la desventaja de ser altamente complicados de obtener. Por ello, se va a utilizar un modelo autorregresivo no lineal con entradas exógenas en forma de red neuronal, que, como se ha visto en varias ocasiones (Sjöberg et al., 1994),

(Schäfer and Zimmermann, 2006) (Rehmer and Kroll, 2019) es capaz de identificar un proceso a partir de datos entrada/salida. Gracias a esto se reduce enormemente el tiempo requerido para la identificación de sistemas que previamente necesitaba este tipo de control.

Con el uso de este modelo, se obtendrá un esquema de control predictivo sobre modelo de red neuronal (NNMPC).

Este diseño de control ha sido probado anteriormente (Saint-Donat et al., 2007) (Piche et al., 1999) (Kittisupakorn et al., 2009) y se conoce su capacidad, sobre la cual se implementarán mejoras.

Para comprobar la eficiencia del diseño implementado, se controlarán dos procesos no lineales diferentes y se comparará su eficacia con otros diseños más conocidos y aceptados.

El principal objetivo del trabajo es la obtención de un diseño de MPC basado en un modelo de red neuronal que sea capaz de un control equivalente al de otros controles más arraigados.

La estructura del trabajo será la siguiente. La Sección 2 presentará el esquema de control que se utilizará en ambos procesos, detallando las funciones de coste y el seguimiento de las referencias. En la Sección 3 se presentará el proceso de la célula Peltier, y en sus subapartados se detallará la identificación y el control llevados a cabo, así como la comparativa con el control PID mencionado. En la Sección 4 se hará análogamente con el proceso CSTR. Por último, la Sección 5 tomará los resultados de las anteriores para dar conclusiones acerca del trabajo.

## 2. Control predictivo sobre modelo de red neuronal (NNMPC)

El control NNMPC se caracteriza por utilizar un modelo de predicción de tipo NARX basado en una red neuronal simple. Por otro lado, se plantea un problema de optimización multiobjetivo minimizando simultáneamente dos funciones de coste clásicas del MPC como son el error de seguimiento de la trayectoria y el esfuerzo de control.

### 2.1. Modelo de predicción: Red neuronal NARX




Figura 1: Esquema red neuronal NARX, tomado de [Seel et al., 2021]

La red neuronal de la figura 1 obtiene una predicción a un paso, a partir de los valores anteriores y actuales de entradas y salidas. Para realizar la predicción a p-pasos, para cada instante

futuro se realimenta la predicción anterior, añadiendo una entrada nueva:

$$\begin{aligned} \hat{y}_{k+1} &= f(u_k, \dots, u_{k-m_x}, y_k, \dots, y_{k-m_y}) \\ \hat{y}_{k+2} &= f(u_{k+1}, \dots, u_{k-m_x+1}, \hat{y}_{k+1}, \dots, y_{k-m_y+1}) \\ &\dots \\ \hat{y}_{k+p} &= f(u_{k+p-1}, \dots, u_{k+p-m_x}, \hat{y}_{k+p-1}, \dots, \hat{y}_{k+p-m_y}) \end{aligned}$$

De esta manera, iterando la función implementada por la red neuronal, se pueden obtener tantas predicciones como el horizonte de predicción requiera.

La tipología de red neuronal de una red NARX es de una única capa oculta y una de salida, lo cual la convierte en una red sencilla, cuyos parámetros de estructura son el número de valores anteriores de entrada, la cantidad de realimentaciones de la salida y el número de neuronas que existirán en la capa oculta.

Por ello, es posible generar una función que, a partir de los valores propios de la red (pesos en cada neurona, sesgos, valores de normalización de variables), pueda generar las predicciones de esta con mayor velocidad comparado con, por ejemplo, la función *net()* de Matlab.

Cabe destacar también que las redes NARX implementan por defecto la función *tansig()* como función de activación de la capa oculta, y se ha decidido cambiar esta por *elliosig()*, ya que, aun siendo parecidas, ambas introducen la posibilidad de no-linealidad en la red pero esta última presenta una menor carga computacional, algo esencial para el control en tiempo real.

### 2.2. Optimización multiobjetivo y MPC.

El controlador resuelve en cada periodo de control un problema de optimización multiobjetivo cuyas variables de decisión son los cambios en las acciones de control futuras  $\Delta u$ . Es decir, el propio algoritmo de optimización es el algoritmo de control.

El controlador hará uso de la red neuronal para obtener las predicciones y resolverá el problema siguiente:

$$\min_{\Delta u} (J_1, J_2)$$

donde

$$\begin{aligned} J_1 &= \alpha \sum_{i=1}^p \|r_{k+i} - \hat{y}_{k+i}\|^2 \\ J_2 &= \lambda \sum_{i=0}^{c-1} \|\Delta u_{k+i}\|^2 \end{aligned}$$

Siendo p y c los horizontes de predicción y control respectivamente,  $r_k$  la referencia en el instante k,  $\hat{y}_k$  la predicción en ese mismo instante,  $\Delta u_k = u_k - u_{k-1}$ , el cambio de la acción de control,  $\alpha$  un factor de ponderación del error de seguimiento de la referencia y  $\lambda$  un factor de ponderación del esfuerzo de control.

Además, existen las siguientes restricciones relacionadas con los límites de la variable controlada y manipulada.

$$\begin{aligned} \underline{y} &\leq \hat{y}_{k+i} \leq \bar{y}, \forall i \in [1 \dots p] \\ \underline{u} &\leq u_{k+i} \leq \bar{u}, \forall i \in [0 \dots c - 1] \\ \underline{\Delta u} &\leq \Delta u_{k+i} \leq \bar{\Delta u}, \forall i \in [0 \dots c - 1] \end{aligned}$$

Para resolver el problema de optimización anterior se requiere de un algoritmo de optimización multiobjetivo, como por ejemplo NSGA-II (Deb et al., 2002), SP-MODE (Reynoso-Meza, 2009), etc. En este trabajo se ha utilizado el algoritmo ev-MOGA (Martínez et al., 2009), debido a sus características de distribución de las soluciones y sencillez en la sintonía de sus hiper-parámetros.

La solución encontrada por el algoritmo no será única, sino que resultará en un conjunto de soluciones, todas ellas óptimas, conformando el conocido Frente de Pareto (FP) en el espacio de los objetivos.

Aunque es característico de los problemas de optimización multiobjetivo una fase de análisis de las soluciones que conforman el FP para elegir cuál de ellas será la solución preferida, en este caso el controlador aplicará una técnica sencilla para seleccionar automáticamente el conjunto de acciones de control preferidas utilizando el criterio de mínima distancia euclídea al punto utópico  $J_U$  (formado por los valores mínimos de cada objetivo) esto es:

$$\Delta u = \arg \min(J - J_U)$$

### 2.3. Seguimiento de la referencia sin error (Offset-Free)

Puesto que las predicciones de la red neuronal no serán exactas debido a dinámica no modelada, perturbaciones no medibles, etc. es necesario incorporar en el controlador algún mecanismo que asegure un error en régimen permanente nulo para un correcto seguimiento de la trayectoria de referencia.

En este trabajo, se ha utilizado el método propuesto en (Tatjewski, 2017) para procesos no lineales en el que, a partir de un error de predicción,  $v_k$ , para el instante actual y calculado como:

$$v_k = y_k - \underbrace{f(u_{k-1}, \dots, u_{k-mx-1}, y_{k-1}, \dots, y_{k-my-1})}_{\hat{y}_k}$$

Y asumiendo que dicho error se mantendrá constante en el futuro,

$$v_k = v_{k+1} = \dots = v_{k+p}$$

Se pueden calcular cada una de las  $p$  predicciones como:

$$\hat{y}_{k+i} = f(u_{k+i}, \dots, u_{k-mx}, \hat{y}_{k+i-1}, \dots, \hat{y}_{k+i-my}) + v_k$$

Por lo que, a la hora de la implementación, solo se necesitará el valor del offset  $v_k$  para corregir de forma iterativa las predicciones.

## 3. Casos prácticos de aplicación

### 3.1. Célula Peltier

Una célula Peltier es un dispositivo de refrigeración basado en el enfriamiento termoeléctrico. En este trabajo, se ha utilizado el modelo de célula Peltier descrito [Huilcapi et al., 2017] y se ha implementado en Simulink tal y como muestra la Figura 2.

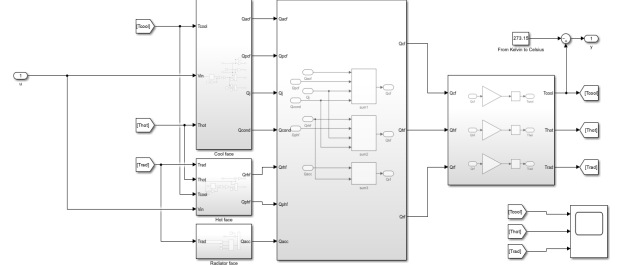


Figura 2: Implementación del sistema Peltier en Simulink.

Se trata de un sistema de una entrada y una salida no lineal, en el que la variable que se controlará es la temperatura de la cara fría ( $T_{cool}$ ), en °C, y la variable manipulada será el porcentaje de actuación respecto a la tensión máxima de entrada al diodo Peltier ( $V_{in}$ ), en %.

El conjunto de datos utilizados para el ajuste y entrenamiento de la red neuronal NARX, que servirá para desarrollar el modelo de predicción, fue obtenido a partir de distintos experimentos realizados con la célula Peltier. Se insertó una entrada cada segundo, dentro del rango total de operación (0% -100%), con cambios aleatorios en la acción de control en intervalos de tiempo también aleatorios.

La red neuronal seleccionada presenta los siguientes parámetros: El número de entradas anteriores para la predicción es de 10, igual que el de realimentaciones de la salida. Esto significa que, para la predicción en el instante  $k+1$ , se requerirán los valores desde  $k$  hasta  $k-10$ . Además, el número de neuronas en la capa oculta es de 10. Estos números se han seleccionado debido a la poca mejora que presenta la red al aumentar cualquiera de ellos. Además, la red se ha entrenado con el método de retropropagación de Levenberg-Marquardt, el cual busca el mínimo del error cuadrático de las predicciones de la red respecto a los valores reales del proceso, a través del método del descenso de gradiente. Los parámetros del entrenamiento son un gradiente mínimo de  $10^{-10}$ , un número máximo de épocas de 2000 y un máximo de épocas de no mejora de 1500. Además, la división del conjunto de datos ha sido del 70% para el entrenamiento, 15% para la validación y el 15% restante para test.

Para la validación final del modelo, se obtuvo otro conjunto de datos diferente al usado en el entrenamiento. En las figuras 3 y 4 puede apreciarse la capacidad de la red neuronal para reproducir el comportamiento de la temperatura.




Figura 3: Validación del modelo de red neuronal para célula Peltier.




Figura 4: Zoom (5000-7000s) validación para célula Peltier.

Con el modelo validado, se implementó el algoritmo NNMPC utilizando los siguientes parámetros mostrados en la Tabla 1.

Tabla 1: Parámetros del control NNMPC en la célula Peltier

Parámetros NNMPC	
p	10
c	5
$\Delta u, \overline{\Delta u}$	-2%, 2%
alfa	1
lambda	8
Parámetros ev-MOGA	
Nº individuos	200
Nº generaciones	200

Para simular el escenario de 700 segundos de la figura 5 se utilizaron 147 segundos de tiempo de cómputo, lo que hace viable su implementación en tiempo real.

El resultado de la simulación del bucle de control arroja unas prestaciones adecuadas comparadas con las alcanzadas por un PID. Tal y como muestran las figuras 5 y 6, el control mediante PID y el realizado con el diseño NNMPC es altamente parecido. En este caso, al tratarse de un sistema con una no linealidad sencilla, el control PID es capaz de controlar el proceso. Sin embargo, los valores de Error cuadrático medio (MSE) y de variación total de la acción de control ( $\sum \Delta u$ ) para el NNMPC son mejores que los obtenidos para el controlador lineal (Tabla 2).

Tabla 2: Prestaciones para ambos controladores en la célula Peltier

Indicador	NNMPC	PID
MSE	12.848	13.038
$\sum \Delta u$	145.382	149.636




Figura 5: Comparativa de control de célula Peltier.

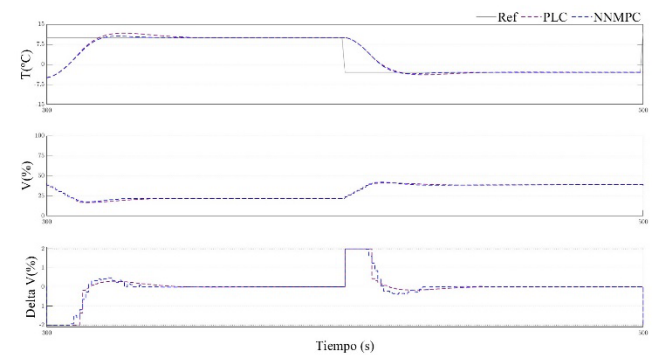


Figura 6: Zoom (300-500 s) comparativa de control de célula Peltier.

### 3.2 Tanque Reactor de Agitado Continuo (CSTR)

El CSTR descrito en (Henson et al, 90) puede considerarse como un “benchmark” de control no lineal para procesos de una entrada y una salida. Este proceso presenta un comportamiento no lineal más pronunciado que el ejemplo anterior. En este apartado se intentará demostrar que el controlador NNMPC es capaz de alcanzar buenas prestaciones de control y de superar a un MPC convencional.

En el CSTR se controla la temperatura y concentración del fluido dentro del tanque, manipulando la temperatura del refrigerante y el caudal de entrada al reactor. Pese a que este sistema se suele tratar como MIMO, en este ejemplo se va a controlar únicamente la concentración a través del caudal de entrada.

El modelo se implementó en Simulink (Figura 7) y, análogamente al ejemplo anterior, se realizaron varios experimentos con el proceso para obtener sendos conjuntos de datos entrada/salida. El primer conjunto de datos se utilizó para entrenar una red neuronal NARX formada por un único retardo en la entrada (para predicción en  $k+1$ , únicamente se requerirá la entrada en el instante  $k$ ), dos realimentaciones de la salida,



y 3 neuronas. Los parámetros de entrenamiento se mantuvieron en este segundo ejemplo, puesto que arrojaron resultados satisfactorios. Con el segundo conjunto de datos se realizó una validación del modelo obtenido (Figura 8 y Figura 9).

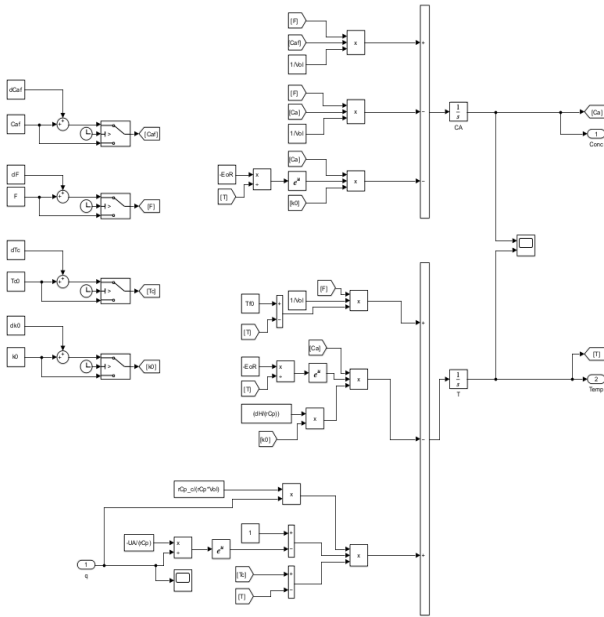


Figura 7: Implementación del sistema CSTR en Simulink.

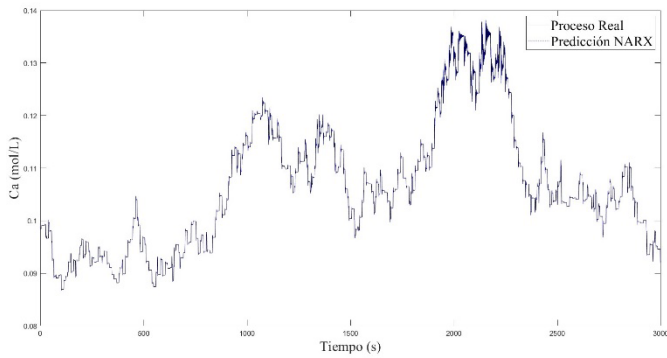


Figura 8: Validación CSTR.

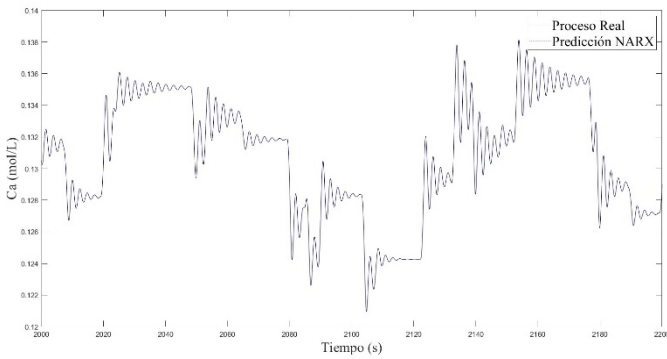


Figura 9: Zoom (2000-2200 s) validación CSTR.

En este caso, el diseño será comparado con un MPC tradicional, ya que se trata de un proceso más complicado de

controlar y el PID no tiene la capacidad controlar correctamente el proceso en todo su rango de operación.

En la simulación del lazo de control con un periodo de control de 5 s., se generaron perturbaciones en los parámetros del proceso, para observar la capacidad del rechazo a perturbaciones de ambos controladores. La primera de ellas se realizó en el instante  $t=125$  min, donde se alteró la concentración del fluido de entrada  $C_{a0}$  en un 2%, así como la constante del ratio de reacción  $k_0$ , en un 2% también. Más adelante, en el instante  $t=270$  min, la temperatura del refrigerante se aumentó en 2 K, afectando al punto de operación del proceso.

Se utilizaron los mismos parámetros para el MPC, tales como el modelo utilizado, horizontes y factores de ponderación, que en (Viviana et al., 2023). En la tabla 3, se detallan los utilizados en el control NNMPC:

Tabla 3: Parámetros del control NNMPC en el CSTR.

Parámetros NNMPC	
p	20
c	5
$\Delta u, \overline{\Delta u}$	-1 L/min, 1 L/min
alfa	50
lambda	0.05
Parámetros ev-MOGA	
Nº individuos	200
Nº generaciones	200

Siendo el resultado de la simulación del lazo cerrado el mostrado en las figuras 10 y 11.

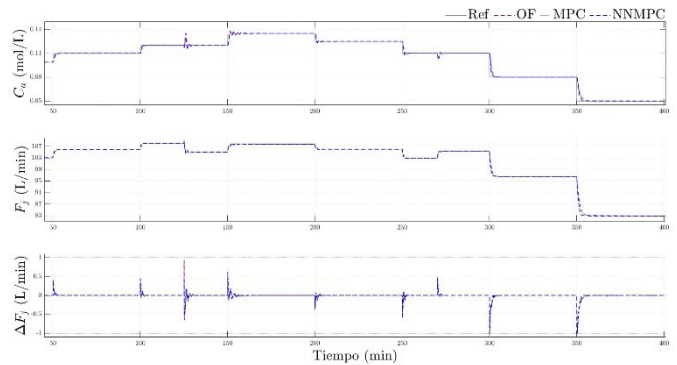


Figura 10: Comparativa del control MPC vs. NNMPC para el CSTR.




Figura 11: Zoom (100-200 s) detalle del control para el CSTR.

Como se puede observar en la Tabla 4, el control del NNMPC es superior al control MPC, realizando una mejor tarea de seguimiento de la referencia, así como de rechazo de las perturbaciones, para una variación similar de la acción de control. Cabe destacar que se seleccionaron los valores de los pesos del NNMPC para que el esfuerzo de control fuera similar en ambos casos.

Para simular un escenario de control de 400 minutos como el que muestra la figura 10, se ha utilizado un tiempo de cómputo de 18 minutos, por lo que se considera un control realizable en tiempo real.

Tabla 4: Prestaciones para ambos controladores en el CSTR.

Indicador	NNMPC	MPC
MSE ( $\cdot 10^{-6}$ )	5.015	6.511
$\sum \Delta u$	48.764	48.354

#### 4. Conclusiones

Tras los resultados obtenidos, se puede concluir lo siguiente:

- Como aproximadores universales de funciones no-lineales, las redes neuronales tipo NARX pueden utilizarse para obtener modelos de caja negra de procesos no lineales y pueden ser utilizadas en algoritmos de control predictivo.
- Los algoritmos evolutivos pueden utilizarse como algoritmos de control en sí mismos, si bien el tiempo de cómputo de la solución puede limitar su aplicación en tiempo real.
- El algoritmo NNMPC es válido para controlar sistemas no lineales de una entrada una salida, teniendo incluso mejor desempeño que un MPC lineal.

El control NNMPC es todavía mejorable y su cuello de botella se encuentra en el tiempo de cómputo de la acción de control, a falta de garantizar la estabilidad de este.

#### 5. Agradecimientos

Este trabajo se ha realizado gracias a la financiación de los proyectos AEI/10.13039/501100011033 [PID2020-120087GB-C21], GVA-CIAICO/ 2021/064.

#### 6. Bibliografía

- Deb, K., Agrawal, S., Pratap, A., and Meyarivan, T., 2002. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Trans. Evol. Comput.* 6, 182–197. DOI: 10.1109/4235.996017
- Iranzo, M.A., Durá, J.M., Sanchís, J., Ferragud, X.B., & García-Nieto, S., 2009. Applied pareto multi-objective optimization by stochastic solvers. *Eng. Appl. Artif. Intell.* 22, 455–465. DOI: 10.1016/j.engappai.2008.10.018
- G. Reynoso-Meza, 2009. Design, coding and implementation of a multiobjective optimization algorithm based on differential evolution with spherical pruning: applications for system identification and controller tuning. Master's thesis, Dep. Ing. Sist. Autom., Univ. Politècnica de València, València, Spain.
- Tatjewski, P., 2017. Offset-free nonlinear Model Predictive Control with state-space process models. *Archives of Control Sciences* 27, 595–615. DOI: 10.1515/acsc-2017-0035
- Seel, K., Grötli, E.I., Moe, S., Gravdahl, J.T., and Pettersen, K.Y., 2021. Neural network-based model predictive control with input-to-state stability. 2021 American Control Conference (ACC), 3556–3563. DOI: 10.23919/ACC50511.2021.9483190
- Rehmer, A., and Kroll, A., 2019. On using gated recurrent units for nonlinear system identification. 2019 18th European Control Conference (ECC), 2504–2509. DOI: 10.23919/ECC.2019.8795631
- Schäfer, A.M., and Zimmermann, H., 2006. Recurrent neural networks are universal approximators. *International journal of neural systems* 17(4), 253–263. DOI: 10.1007/11840817\_66
- Sjöberg, J., Hjalmarsson, H., and Ljung, L., 1994. Neural Networks in System Identification. *IFAC Proceedings Volumes* 27, 359–382. DOI: 10.1016/S1474-6670(17)47737-8
- Kittisupakorn, P., Thitayasook, P., Hussain, M.A., and Daosud, W., 2009. Neural network based model predictive control for a steel pickling process. *Journal of Process Control* 19, 579–590. DOI: 10.1016/j.jprocont.2008.09.003
- Saint-Donat, J., Bhat, N., and McAvoy, T.J., 2007. Neural Net Based Model Predictive Control. *International Journal of Control* 54, 1453–1468. DOI: 10.1080/00207179108934221
- Piche, S., Keeler, J.D., Martin, G., Boe, G., Johnson, D., and Gerules, M., 1999. Neural network based model predictive control. *Neural Information Processing Systems*. Corpus ID: 1525194
- Darby, M.L., and Nikolaou, M., 2012. MPC: Current practice and challenges. *Control Engineering Practice* 20, 328–342. DOI: 10.1016/j.conengprac.2011.12.004
- Allgöwer, F., Findeisen, R., and Nagy, Z.K., 2004. Nonlinear model predictive control: From theory to application. *Journal of the Chinese Institute Of Chemical Engineers* 35, 299–315. DOI: 10.6967/JCICE.200405.0299
- Henson, M.A., and Seborg, D.E., 1990. Input-output linearization of general non-linear processes. *Aiche Journal* 36, 1753–1757. DOI: 10.1002/AIC.690361118
- Martínez Carvajal, B.V., Sanchís Saez, J., García-Nieto Rodríguez, S., and Martínez Iranzo, M., 2023. Modified Active Disturbance Rejection Predictive Control: A fixed-order state-space formulation for SISO systems. *ISA Trans.* 142, 148–163. DOI: 10.1016/j.isatra.2023.08.011

## Selección de la tecnología de visión más adecuada para paletizado

Moreno-Román, G.<sup>a,\*</sup>, Sierra-García, J.E.<sup>a</sup>

<sup>a</sup> *Ingeniería de Sistemas y Automática, Departamento de Digitalización, Escuela Politécnica Superior, Avenida de Cantabria s/n, 09006 - Burgos (Spain), Universidad de Burgos*

**To cite this article:** Moreno-Román, G., Sierra-García, J.E., 2024. Selecting the most suitable vision technology for palletizing. XIX Simposio CEA de Control Inteligente. 2024.

### Resumen

Se analiza un problema existente en un proceso de paletizado en automoción, en el que las piezas a paletizar son totalmente negras, sin zonas de contraste, lo que dificulta enormemente su identificación mediante visión en dos dimensiones. Por ello, se estudian alternativas de adquisición en tres dimensiones, pues si se consigue apreciar diferencias de altura, se podrían identificar las piezas y huecos para ubicarlas. Una vez analizadas las tecnologías de adquisición 3D, se realiza una comparativa entre las tecnologías de adquisición 3D sin contacto más comunes en el ámbito industrial. Por último, se enumeran algunos de los métodos de reconstrucción 3D que se pueden emplear hoy en día. Tras este análisis de tecnologías de adquisición 3D sin contacto y métodos de reconstrucción 3D, se valora con qué tecnologías comerciales se podría resolver el problema propuesto.

*Palabras clave:* Visión artificial, Visión por ordenador, Sistemas de adquisición de imágenes 3D, Técnicas de medición de profundidad, Reconstrucción 3D.

### Selecting the most suitable vision technology for palletizing

#### Abstract

An existing problem in an automotive palletizing process is analyzed, in which the parts to be palletized are totally black, without contrast areas, which makes it very difficult to identify them by means of two-dimensional vision. Thus, three-dimensional acquisition alternatives are analyzed, because if height differences can be appreciated, the parts and gaps to locate them could be identified. Once the 3D acquisition technologies have been analyzed, a comparison is made between the most common non-contact 3D acquisition technologies in the industrial field. Finally, some of the 3D reconstruction methods that can be used today are listed. After this analysis of non-contact 3D acquisition technologies and 3D reconstruction methods, it is evaluated with which commercial technologies the proposed problem could be solved.

*Keywords:* Machine vision, Computer vision, 3D image acquisition systems, Range measurement techniques, 3D reconstruction.

### 1. Introducción

En multitud de procesos de producción industrial se ha extendido el uso de diferentes tecnologías de visión artificial, habiéndose encontrado particularmente útiles los algoritmos de clasificación y reconocimiento de imágenes (Phanomchoeng & Chanchareon, 2017).

Mediante el uso de cámaras digitales y usando procesamiento de imágenes, se puede automatizar la producción y mejorar la calidad de los productos. Las tareas de visión artificial pueden clasificarse en una de las 4 siguientes tareas principales (Nilsson & Murhed, 2015):


1. Posicionamiento: detectar y localizar objetos para, a continuación, informar de la presencia o las coordenadas del objeto.
2. Inspección: verificar la calidad del producto, por ejemplo, comprobar la presencia de todas las piezas de un conjunto o encontrar defectos y desviaciones.
3. Medir: Determinar las dimensiones de los objetos, como la longitud, la anchura, la altura, el área y el volumen.

### 1.1 Resolver aplicaciones usando visión 2D o 3D

En muchas ocasiones una misma tarea de visión se puede resolver de distintas formas. A veces resulta obvia la elección entre visión 2D o 3D, pero en otros casos ambas tecnologías son válidas, pero cada una aporta ciertas ventajas. Conviene comprender dichas ventajas para llegar a una solución fiable (Nilsson & Murhed, 2015):

#### Visión 2D:

Se puede usar para resolver cualquiera de las 4 tareas de visión y es la tecnología de visión más usada. Es particularmente útil cuando hay alto contraste o la clave de la solución está en la textura o color del objeto, *Figura 1*.



*Figura 1 La impresión en la caja será visible utilizando 2D (a), con la visión 3D (b) solamente se comprueba la forma de la caja. Extraído de (Nilsson & Murhed, 2015)*

#### Visión 3D:

Adecuada para analizar el volumen, la forma, la posición en el espacio de un objeto, así como detectar piezas y defectos que tienen bajo contraste, pero con una diferencia de altura detectable.



*Figura 2 En la imagen 2D, debido al bajo contraste, difícilmente se puede reconocer el objeto superior. En la imagen 3D el objeto superior se puede encontrar fácilmente porque está más cerca de la cámara, así que aparece más brillante. Extraído de Nilsson and Murhed (2015)*

## 2. Problema a resolver

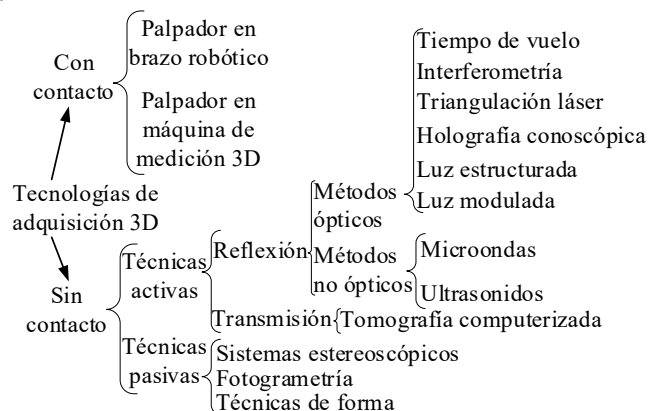
Se trata de guiar a un robot industrial de 6 ejes para paletizar fragmentos de banda de rodadura de neumáticos para vehículos industriales. Son piezas de goma negras sin zona alguna de contraste entre ellas, *Figura 3*. Así, la solución de visión artificial más adecuada sería la visión 3D, pues medir la diferencia de altura entre las piezas negras de la *Figura 3* conducirá a un contraste similar al observado en la imagen en 3D de la *Figura 2*, mientras que en 2D apenas habría contraste. En este caso la visión 3D facilita considerablemente la tarea.



*Figura 3 Piezas a paletizar dentro del contenedor metálico en el que paletizarlas. El sistema de visión ha de ver las piezas a paletizar y el contenedor. Fuente: archivo del autor.*

## 3. Clasificación de las tecnologías de visión 3D

Las tecnologías de adquisición de cotas de posición en tres dimensiones pueden clasificarse como se muestra en la *Figura 4*.



*Figura 4 Clasificación de las tecnologías de adquisición 3D, adaptado de Pilar Valerga Puerta et al. (2020)*

Se analizarán únicamente tecnologías de medición sin contacto, para la mínima interferencia con el proceso industrial. Para hacer una descripción en tres dimensiones de la escena existen varios algoritmos de reconstrucción, que se pueden clasificar en 2 clases (Isgro et al., 2005):

- **Métodos pasivos:** todos aquellos que no utilizan tipo alguno de energía para ayudar a los sensores, por ejemplo, la visión estereoscópica o la obtención de la forma a partir del sombreado (shape from shading). Solamente cuentan con los equipos de adquisición de imágenes.
- **Métodos activos:** proyectan energía, por ejemplo, un patrón de luz, pulsos de sonar (localización por sonido) sobre la escena y detectan su posición para llevar a cabo la medición o aprovechan el efecto de los cambios controlados de algunos parámetros del sensor, por ejemplo, el enfoque.

### 3.1. Métodos pasivos de reconstrucción 3D

Los métodos de reconstrucción pasivos basados en visión no interfieren con el objeto reconstruido. Solamente utilizan sensores ópticos para medir el flujo radiante que refleja o emite la superficie del objeto e infiere su estructura tridimensional a través de la imagen (Zhou et al., 2024).

### 3.1.1. Mapeado de textura

Si la textura de la superficie del objeto es fácilmente distinguible, se puede utilizar dicha información de la superficie del objeto para asignar a cada punto de la imagen bidimensional una cota de profundidad en el modelo 3D.

### 3.1.2. Forma a partir del enfoque

Se utiliza el ajuste de la distancia focal de la cámara para calcular la profundidad observando los cambios en la profundidad focal del objeto. La distancia focal del objeto está determinada por el grado de desenfoque de la imagen del objeto a diferentes distancias focales. Se puede usar una cámara para capturar imágenes de la misma escena a varias distancias focales. En la imagen, cuanto más lejos esté el objeto del plano focal, más borrosa será su imagen. La estimación de la profundidad es otro aspecto importante a tener en cuenta. Utilizando la relación entre el nivel de desenfoque de la imagen y la profundidad, es posible estimar el objeto. El valor de profundidad de cada parte y, finalmente, la reconstrucción 3D, convierten la información de profundidad en coordenadas 3D, obteniendo así el modelo de reconstrucción 3D del objeto.

### 3.1.3. Visión binocular estereoscópica

El principio de visión estereoscópica (triangulación pasiva) se refiere al proceso de determinar los datos 3D y la profundidad de cualquier objeto visible en el espacio midiendo el ángulo desde dos puntos conocidos con una línea de base fija en lugar de determinar la distancia al punto del objeto directamente. El punto objetivo puede considerarse el tercer punto del triángulo (Aboali et al., 2017).

La escena se observa desde dos o más puntos de vista, por varias cámaras al mismo tiempo. A partir de las imágenes recogidas, el sistema debe inferir información sobre la estructura tridimensional de la escena (Se & Pears, 2020).

En la Figura 5 se muestra un sistema estereoscópico binocular.

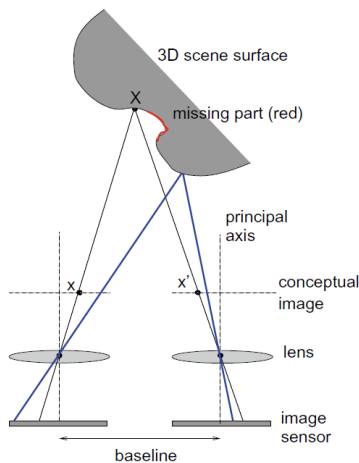


Figura 5 Vista en planta del funcionamiento de un equipo estereoscópico sencillo en el que los ejes ópticos de las dos cámaras son paralelos para formar un equipo rectilíneo. Extraído de Se and Pears (2020).

Si se consigue determinar que los puntos de las imágenes de las cámaras izquierda y derecha corresponden al mismo punto de la escena, se pueden determinar dos direcciones

(rayos 3D) a lo largo de las cuales debe encontrarse el punto 3D. Los parámetros de la cámara necesarios para convertir las posiciones de las imágenes 2D en rayos 3D proceden de un procedimiento de calibración de la cámara (Se & Pears, 2020).

Aunque el sensor de imagen real está detrás de la lente, es práctica común prever y utilizar una posición de imagen conceptual delante de la lente para que la imagen tenga la misma orientación que la escena (no invertida de arriba abajo y de izquierda a derecha), y esto se muestra mediante la línea horizontal discontinua en la Figura 5.

### 3.1.4. Estructura a partir del movimiento

Consiste en recuperar estructuras tridimensionales a partir de múltiples imágenes. Este método se basa en la relación entre el movimiento de la cámara y la estructura de la escena, utilizando el movimiento de la cámara en diferentes momentos o lugares. SFM se divide principalmente en cuatro grupos: incremental, global, híbrido y jerárquico.

### 3.2. Métodos activos de reconstrucción 3D

Los métodos activos de reconstrucción 3D basados en visión usan interferencias mecánicas o radiométricas con el objeto reconstruido para adquirir mapas de profundidad. Estos métodos utilizan principalmente instrumentos ópticos para escanear la superficie de un objeto y reconstruir la estructura tridimensional mediante el análisis de los datos escaneados. Algunos de estos métodos incluyen la luz estructurada, los telémetros láser, el escaneo láser, el escaneo de tomografía computarizada industrial, la tecnología de tiempo de vuelo (TOF), el método de sombras, etc. (Zhou et al., 2024).

#### 3.2.1. Escaneo láser




Figura 6 Principio de medición de distancia por triangulación activa, extraído de Lange (2000).

La triangulación activa, como se ve en la Figura 6, utiliza una fuente de luz para proyectar un punto (en el caso más sencillo) en el objeto, que es observado por un detector sensible a la posición. En lugar de medir ángulos directamente, la triangulación activa se basa en la similitud de triángulos, el triángulo del objeto y el triángulo de la imagen, que está totalmente definido por el eje óptico del dispositivo de formación de imágenes, la distancia focal  $h$  del sistema y la posición de la proyección del punto  $x'$  en el detector. Conociendo el desplazamiento  $x$  de la fuente de luz desde el dispositivo de formación de imágenes, se puede determinar la distancia  $z$  al objeto (Lange, 2000).

### 3.2.2. Luz estructurada

Para el cálculo de correspondencias entre las imágenes izquierda y derecha, los sensores de luz estructurada usan patrones de luz (o códigos). La cámara registra los patrones de la superficie. Si la superficie del objeto escaneado es plana, el patrón adquirido por la cámara será similar al patrón iluminado por el proyector. Sin embargo, si el objeto tiene algunas variaciones en la superficie, el patrón adquirido por la cámara se distorsionará en comparación con el patrón proyectado, por lo que la forma 3D del objeto puede reconstruirse comparando los patrones proyectados y los patrones distorsionados adquiridos por la cámara.

Los patrones se establecen de forma que cada píxel codificado tenga una palabra clave asociada, es decir, se proporciona una correspondencia entre las palabras clave diseñadas y las coordenadas de los píxeles del patrón utilizando los valores de gris o color del patrón. En comparación con la correspondencia estereoscópica, el patrón proyectado ayuda a distinguir los píxeles utilizando una estrategia de codificación local. De esta forma, se pueden establecer fácilmente correspondencias entre el patrón proyectado y el patrón percibido por la cámara. Una vez establecidas las correspondencias, la distancia desde el sensor a cada punto de la superficie del objeto 3D escaneado puede calcularse mediante triangulación.

Los sensores de luz estructurada son rápidos y pueden utilizarse en grandes superficies. También son capaces de reconstruir la geometría y la textura de los objetos tridimensionales, con alta resolución y precisión. Sin embargo, son sensibles a la iluminación ambiental. No son adecuados para escanear superficies reflectantes y transparentes.




Figura 7 Sensor de adquisición 3D de luz estructurada. Extraído de Se and Pears (2020).

### 3.2.3. Tiempo de vuelo, ToF

Se puede medir una distancia si se consigue medir el tiempo que necesita un pulso de luz para viajar desde un objetivo hasta un punto de referencia, el detector. Esta medición indirecta de la distancia es posible porque se conoce la velocidad de la luz con suficiente precisión ( $c = 3 \cdot 10^8$  m/s). En una aplicación práctica se sitúa la fuente de luz activa muy próxima al receptor, facilitando así un montaje compacto y evitando los efectos de sombra. En la Figura 8 se ilustra el principio básico de funcionamiento de la medición de distancia en un sistema de tiempo de vuelo.




Figura 8 Principio básico de un sistema óptico de medición de profundidad, extraído de Lange (2000)

Una fuente emite un pulso luminoso e inicia un cronómetro de alta precisión en el detector. El pulso de luz viaja hasta el objetivo y regresa. Al recibirse el pulso luminoso se detiene la medición de tiempo y el cronómetro muestra el tiempo de vuelo del pulso luminoso. Considerando que el pulso de luz recorre el camino dos veces (ida y vuelta), un tiempo medido de 6,67 ns corresponde a una distancia de 1 m y se requiere una precisión de tiempo mejor que siete picosegundos para una resolución de distancia de 1 mm. Una propiedad esencial de esta configuración es que el emisor y el detector funcionan de forma sincrónica.

### 3.2.4. Fotometría estereoscópica

La fotometría registra los valores de radiancia en un único punto de la imagen. En el caso de la estereoscopía fotométrica, se varía la dirección de la iluminación incidente entre imágenes sucesivas, permaneciendo constante la dirección de visión. De este modo se obtiene información suficiente para determinar la orientación de la superficie en cada punto de la imagen. Al no variar la geometría de la imagen, la correspondencia entre los puntos de la imagen se conoce de antemano (Woodham, 1992). En la Figura 9 se muestra un diagrama explicativo sobre la fotometría estereoscópica.




Figura 9 Diagrama explicativo de la fotometría estereoscópica. Varias imágenes de un objeto bajo diferentes iluminaciones se analizan para producir una dirección normal estimada en cada píxel. Extraído de Holroyd (2015)

### 3.2.5. Interferometría

En la Figura 10 se muestra un montaje esquemático de interferometría con varias longitudes de onda, en el que se

tienen los siguientes elementos: LS: fuente de luz; FC: acoplamiento de fibra; F: fibra; SH: cabeza del sensor; L: distancia a la superficie del objeto; S: superficie; SD: filtrado y distribución espectral; PA: análisis y detección de fase;  $\lambda_1$ ,  $\lambda_2$ : longitudes de onda de detección;  $\Lambda$ : longitud de onda sintética.




Figura 10 Montaje esquemático de interferometría con varias longitudes de onda, extraído de Haus (2010)

Las técnicas de medición de distancias mediante interferometría que utilizan solamente una longitud de onda solamente dan resultados inequívocos para distancias inferiores a la mitad de la longitud de onda. Una forma de evitar esta limitación es emplear más de una longitud de onda, en el esquema de montaje mostrado en la Figura 10,  $\lambda_1$  y  $\lambda_2$ . Si la diferencia entre las dos longitudes de onda es pequeña ( $\lambda_1$  y  $\lambda_2$  en la Figura 10),  $\Lambda$  será comparativamente grande, y esto aumenta el rango de no ambigüedad del interferómetro.

### 3.2.6. Fusión de varios sensores

Para superar las limitaciones de los sensores individuales y crear una percepción más completa del entorno o del objetivo, mejorando así la precisión de la reconstrucción 3D, se puede combinar la información de varios sensores, como pudieran ser radar, LIDAR, cámara, ultrasonido, cámara termográfica de infrarrojos, GPS (Zhou et al., 2024).

## 4. Comparación de las tecnologías de adquisición 3D sin contacto más comunes en el ámbito industrial

Los tres principios más usados en los sistemas comerciales de obtención de imágenes tridimensionales son el tiempo de vuelo (ToF), la interferometría y la triangulación. Puede describirse el tiempo de vuelo como basado en un reloj preciso, la interferometría como aquella que usa longitudes de onda precisas y la triangulación como un método basado en la geometría.

En el problema a resolver en esta aplicación, descrito en el apartado 2 del presente documento, la dimensión mayor del objeto está en torno a 1 metro y sería suficiente alcanzar una precisión de milímetros. Según el fabricante norteamericano e-con Systems™ Inc, si se comparan tres de los sistemas más utilizados para la medición de profundidad sin contacto y que, además, no requieren movimiento (estereovisión, luz

estructurada y tiempo de vuelo), se obtendría la comparativa mostrada en la Figura 12. En esta comparativa se puede apreciar que la solución más económica es la estereovisión, pero es algo más limitada en prestaciones. La tecnología basada en luz estructurada es la más precisa, aunque el rango de medida es más limitado. La tecnología basada en tiempo de vuelo es la más compacta, la programación es algo más simple, pero queda en término medio en cuanto a precio y precisión.

Comparativa tecnologías visión 3D que no requieren movimiento

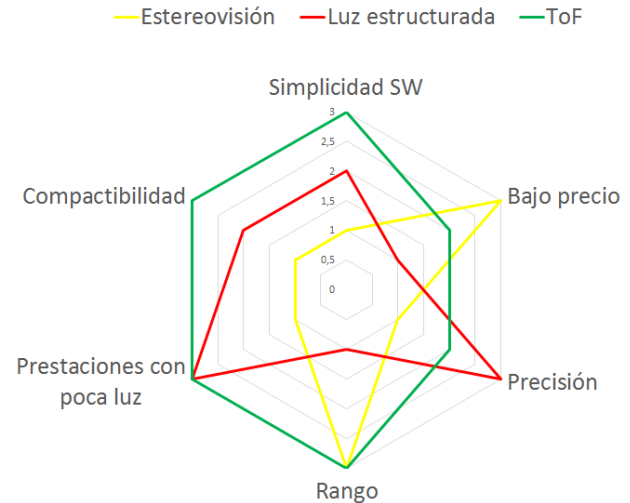


Figura 12 Comparativa de tres tecnologías de visión 3D sin contacto ni movimiento. Elaboración propia a partir de los datos facilitados en e-con Systems™ Inc (2023).

## 5. Métodos de reconstrucción 3D basados en el aprendizaje automático

Los métodos de aprendizaje estadístico pueden utilizarse en la reconstrucción 3D para modelar y aprender la relación de mapeo de datos de entrada (como imágenes y nubes de puntos) a estructuras 3D, aprender formas de escenas y objetos a partir de datos a gran escala y predecir la forma 3D de los objetos mediante modelos de entrenamiento. Este proceso permite la restauración y comprensión de escenas 3D.

Los métodos de predicción de ocupación semántica 3D utilizan tecnología de aprendizaje automático para la segmentación semántica y la comprensión de escenas. Esto permite mejorar la identificación y reconstrucción de la estructura geométrica y la información semántica de varios objetos de la escena (Zhou et al., 2024).

Los métodos de aprendizaje profundo superan a la mayoría de los métodos de aprendizaje automático existentes en varias áreas, entre las que destaca la visión por ordenador. Con el avance de la tecnología de aprendizaje profundo, los métodos de reconstrucción dinámica de escenas 3D basados en redes neuronales han empezado a captar el interés de los investigadores. Las redes neuronales pueden descubrir información de características que los humanos no son capaces de interpretar, y pueden extraer características de alta dimensión (Zhou et al., 2024).

El método implica la extracción de características visuales de imagen de profundidad inicialmente y luego la construcción de un volumen 3D basado en el tronco de la cámara de referencia a través de distorsiones monotónicas diferenciables. Posteriormente, se aplica la convolución 3D para regularizar y estimar por regresión el mapa de profundidad inicial. Por último, la imagen de referencia se utiliza para optimizar y generar el resultado final (Zhou et al., 2024).

Los algoritmos de procesamiento de nubes de puntos 3D basados en el aprendizaje profundo generalmente incluyen algoritmos basados en vóxeles (píxeles volumétricos), algoritmos basados en vistas y algoritmos basados en puntos. El algoritmo basado en puntos utiliza directamente coordenadas de puntos como entrada y puede aprender directamente de los datos originales de una manera integral, simplificando la ingeniería de características y el diseño de reglas en el proceso tradicional. Tiene una gran capacidad de generalización y robustez y es adecuado para escenarios de todo tipo y tamaño.

El método Campo de Radiancia Neural (NeRF) consiste en utilizar campos neuronales de radiación 5D para representar geometría compleja y material en escenas continuas. Se trata de un nuevo paradigma en el campo del aprendizaje profundo y la visión por ordenador, que marca la transición del enfoque convencional del aprendizaje profundo al procesamiento de datos 3D. NeRF utiliza la red Perceptrón Multicapa (MLP) para la parametrización e introduce un método de renderizado diferenciable que mejora las técnicas tradicionales de renderizado de vóxeles (píxeles volumétricos). Las imágenes RGB se obtienen mediante renderizado diferenciable. Cada coordenada 5D se asigna a un espacio de mayor dimensión utilizando el método de codificación de posición, lo que permite optimizar el campo de radiación neural para expresar mejor los detalles de alta frecuencia (Zhou et al., 2024).

## 6. Conclusiones

Para resolver el problema existente, paletizar piezas totalmente negras sin zonas de contraste, la visión 3D es más adecuada porque en este caso es mucho más fiable detectar diferencia de profundidad. Lo más conveniente es tecnología sin contacto, *Figura 4*. Por economía, se evaluará primeramente la validez de métodos comercialmente disponibles en la industria, *Figura 12*. Considerando la triangulación láser o perfilometría láser requiere movimiento,

por lo que habría que embarcar la cámara en el robot para escanear el palé. Además, es un sistema bastante caro, aunque muy preciso. De entre los sistemas que no requieren movimiento, el tiempo de vuelo sería la tecnología más equilibrada por disponer de un campo de visión amplio, apenas se ve afectada por la luz externa y puede alcanzar una precisión del orden de mm (suficiente para la aplicación).

## Referencias

- Aboali, M., Manap, N. A., Darsono, A. M., & Yusof, Z. M. (2017). Review on three dimensional (3-D) acquisition and range imaging techniques [Article]. *International Journal of Applied Engineering Research*, 12(10), 2409-2421. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85020866652&partnerID=40&md5=d3913cce83439f72eeff316fe015dd5a0>
- e-con Systems™ Inc. (2023, January 12th). *Time-of-Flight (ToF) vs Stereo Vision vs Structured light – Detailed look | e-con Systems California (USA)*, e-con Systems™ Inc. <https://www.youtube.com/watch?v=K1j73e3D8qU>
- Haus, J. r. (2010). Optical Sensor Concepts. In *Optical Sensors* (pp. 63-146). <https://doi.org/https://doi.org/10.1002/9783527629435.ch6>
- Holroyd, M. (2015). Photometric stereo. In (Vol. 800 x 600 pixels). [https://upload.wikimedia.org/wikipedia/commons/b/b5/Photometric\\_stereo.png](https://upload.wikimedia.org/wikipedia/commons/b/b5/Photometric_stereo.png): Wikimedia Commons.
- Isgro, F., Odone, F., & Verri, A. (2005, 4-6 July 2005). An open system for 3D data acquisition from multiple sensor. Seventh International Workshop on Computer Architecture for Machine Perception (CAMP'05).
- Koch, M., & Döring, A. (2011). *OCR vs OCV Monitoring of printed product information*. Baumer. [https://www.baumer.com/medias/\\_secure\\_/Baumer\\_VT-OCR-vs-OCV\\_TR\\_EN\\_1105.pdf?mediaPK=8828977348638](https://www.baumer.com/medias/_secure_/Baumer_VT-OCR-vs-OCV_TR_EN_1105.pdf?mediaPK=8828977348638)
- Lange, R. (2000). *3D time-of-flight distance measurement with custom solid-state image sensors in CMOS/CCD-technology*
- Nilsson, F., & Murhed, A. (2015). *Select the best technology for your vision application* (8018982). [https://cdn.sick.com/media/docs/2/22/322/whitepaper\\_sick\\_ag\\_whitepaper\\_select\\_the\\_best\\_technology\\_for\\_your\\_vision\\_application\\_en\\_im0063322.pdf](https://cdn.sick.com/media/docs/2/22/322/whitepaper_sick_ag_whitepaper_select_the_best_technology_for_your_vision_application_en_im0063322.pdf)
- Phanomchoeng, G., & Chanchareon, R. (2017, 1-3 April 2017). Projected pattern on three-dimensional objects for image feature classification and recognition. 2017 2nd International Conference on Control and Robotics Engineering (ICCRE).
- Pilar Valerga Puerta, A., Aletheia Jimenez-Rodriguez, R., Fernandez-Vidal, S., & Raul Fernandez-Vidal, S. (2020). Photogrammetry as an Engineering Design Tool. In *Product Design*. IntechOpen. <https://doi.org/10.5772/INTECHOPEN.92998>
- Se, S., & Pears, N. (2020). Passive 3D Imaging. In Y. Liu, N. Pears, P. L. Rosin, & P. Huber (Eds.), *3D Imaging, Analysis and Applications* (pp. 39-107). Springer International Publishing. [https://doi.org/10.1007/978-3-030-44070-1\\_2](https://doi.org/10.1007/978-3-030-44070-1_2)
- Woodham, R. (1992). Photometric Method for Determining Surface Orientation from Multiple Images. *Optical Engineering*, 19. <https://doi.org/10.1117/12.7972479>
- Zhou, L., Wu, G., Zuo, Y., Chen, X., & Hu, H. (2024). A Comprehensive Review of Vision-Based 3D Reconstruction Methods. *Sensors*, 24(7).



## Fuzzy speed estimator for drives using optical encoders

Satué, M.G.<sup>a,\*</sup>, Escaño J.M.<sup>a</sup>, Colodro, F.<sup>b</sup>

<sup>a</sup>Departamento de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos, s/n, 41092, Sevilla, España.

<sup>b</sup>Departamento de Ingeniería Electrónica, Universidad de Sevilla, Camino de los Descubrimientos, s/n, 41092, Sevilla, España.

**To cite this article:** Satué, M.G., Escaño, J.M., Colodro, F. 2020. Fuzzy Speed Estimator for drives using optical encoders. XIX Simposio CEA de Control Inteligente. 2024.

### Resumen

Después de años de investigación, el Control Indirecto de Campo Orientado (IFOC) y otras técnicas relacionadas son una opción disponible comercialmente. Algunos aspectos derivados de la implementación en Procesadores Digitales de Señal (DSP) de las estructuras de tipo IFOC han recibido menos atención en la literatura. En particular, aquí se considera el proceso de medición de la velocidad mecánica usando codificadores ópticos. Se presenta un modelo del método de medición de la velocidad con sus implicaciones para diseño de controladores. Como resultado del análisis, se presenta un nuevo estimador de la velocidad basado en inferencia borrosa. Los experimentos realizados muestran una mejora en los resultados respecto al modo de proceder común, sin abandonar el método de conteo de pulsos comúnmente utilizado.

*Palabras clave:* Control Borroso, Encóder, Estimación de velocidad, Variadores de velocidad

### Fuzzy speed estimator for drives using optical encoders

#### Abstract

The Indirect Field Oriented Control (IFOC) and related techniques are now a commercially available option after years of research. Some aspects derived from the Digital Signal Processing (DSP) implementation of IFOC-like structures have received less attention in the literature. In particular, the mechanical speed sensing process using optical encoders is considered here. A model of the speed measurement method is presented with its implications for control design. As a result of the analysis, a new speed estimator based on fuzzy inference is presented. The experimental results show improved results with respect to the common practice without abandoning the familiar and commonly used pulse counting method.

*Keywords:* Fuzzy Control, Encoder, Speed estimation, Variable speed drives

## 1. Introduction

Electric drives play an important role in modern society and are the mainstay of many industrial application including transportation (Toral et al., 2010). They are systems based on rotary electrical machines controlled by power electronic converters. Their goal is to provide precise transmission between electrical energy and mechanical motion with fast dynamic responses. A review of recent developments in the field can be found in (Bermúdez et al., 2020).

Sensors are required to monitor the operating state of the electric drive and feed it back as input to the controller. Continuous monitoring and observation are essential for high-quality

controlled systems, which require reliable sensors. The number and type of mechanical and electrical sensors required are variable in electric drives and depend on multiple characteristics of the system (Arahal et al., 2020).

In the case of high-end products, a digital signal processing (DSP) solution is commonly found providing accurate control. This is particularly interesting for multi-level and multi-phase system where intrinsic advantages can be exploited by using advanced control at a higher computational cost (Martín et al., 2016; Martín et al., 2019). Said DSP-based methods often make use of a model to provide some sort of predictive solution (Rodas et al., 2016). However, the basic setup provided by approaches such as Indirect Field Oriented Control (IFOC) is pre-

\*Autor para correspondencia: mgarrido16@us.es

served in many aspects. This is the case of the mechanical speed of the drive, which is often measured using optical devices such as the incremental encoder. In most cases, a simple scheme is used to estimate the speed as a function of the quotient  $\Delta x/T_\omega$ , where  $\Delta x$  is the number of pulses provided by the encoder and  $T_\omega$  is the time spent gathering said pulses. The estimation might then be subjected to some filtering. This basic scheme has been used without much questioning for the past decades.

In many drives applications, speed is the main variable to be controlled (Anuchin et al., 2017; Chen et al., 2019). There are many works concerning speed estimation that need some reviewing. In (Benkhoris and Ait-Ahmed, 1996) sampling frequency is investigated using a Taylor expansion and low order polynomials. The work of (Negrea et al., 2012a) presents a method to change the time base used for the estimation computation. This method is not realizable in some DSP as is reported in (Anuchin et al., 2017). Adjusting the sampling period to make the number of pulses a whole integer is a method proposed in (Negrea et al., 2012b) to reduce ripples in the estimated speed. In (Chen et al., 2019), the quantization noise is considered in the frequency domain. A Notch filter is designed considering the actual speed and the sampling frequency. In (Anuchin et al., 2017) a predictive method with variable-width window is used for the speed estimation. The method is not well suited for low-inertia systems.

With the advent of new DSP at cheap prices, the sampling times used in drives have been steadily reduced (Bermudez et al., 2020), especially with the use of fast MPC methods (Arahal et al., 2023). This, among other things, increases the band-width. However, some basic assumptions for drive-modelling no longer holds, as the speed sensing is not ideal. As the control band-width is increased the frequencies at which the measurement take place are getting closer to those of the controller. This is not good as measurement should be very small fraction of the sampling period (Limon et al., 2007).

This paper presents a model of the speed measurement method used by many DSP for drives and advances the implications for control design. A new fuzzy-based method for speed estimation is then presented and analyzed.

## 2. Speed control in variable speed drives

Indirect Field Oriented Control (IFOC) is, as of today, a popular method for Induction Motor (IM) speed control which is used not only in academia but also in industrial applications under various denominations such as vector control. The method can be adapted to different applications such as permanent magnet machines (Bucciarelli et al., 2024), generators (Duran et al., 2008), etc. The method typically uses PI controllers for the speed loop and the inner current loops, although the inner one is recently replaced by a predictive method (Kowal G et al., 2019). In this case (Satue et al., 2023), the inner loop is replaced by a predictive scheme where the VSI state is directly computed, providing a fast response at the cost of some harmonic content (Arahal et al., 2016). In addition, the method can accommodate with ease different objectives and consider constraints and nonlinearities (Ramirez et al., 2019). It also allows for modulation methods not supported by basic IFOC structure (Satué et al., 2023).

In the indirect field-oriented control scheme, flux and torque are independently regulated. The flux current set point  $i_d^*$  is set to magnetize the motor whereas quadrature current  $i_q^*$  is used to manipulate the produced torque. The PI in the velocity feedback loop is responsible for generating  $i_q^*$  to drive the mechanical speed control error to zero.

$$i_q^* = k_p \cdot e + k_i \int_0^t e(\tau) d\tau \quad (1)$$

where  $e = \omega^* - \omega^e$  is the velocity error or difference between the speed set point ( $\omega^*$ ) and the speed measurement ( $\omega^e$ ).

Once the set-points in  $d - q$  coordinates are known, they are projected to the  $\alpha - \beta$  space using the Park transformation, obtaining a reference for stator current in  $\alpha - \beta$  plane as  $I_{\alpha-\beta}^* = D (i_d^*, i_q^*)^T$ , where matrix  $D$  is given by

$$D = \begin{pmatrix} \cos \theta_a & \sin \theta_a \\ -\sin \theta_a & \cos \theta_a \end{pmatrix} \quad (2)$$

The flux position  $\theta_a$  is estimated as  $\theta_a = \int \omega_e dt$  where  $\omega_e = \omega_{sl} + P\omega$ , being  $P$  the number of pairs of poles of the IM and

$$\omega_{sl} = \frac{i_q^*}{i_d^*} \frac{1}{\hat{\tau}_r} \quad (3)$$

where  $\hat{\tau}_r$  is an estimation of the rotor time constant  $\tau_r = L_r/R_r$ , being  $L_r$  and  $R_r$  the rotor inductance and resistance, respectively. As a result, the set point for stator current tracking  $i^*(k)$  has an amplitude  $I^* = \sqrt{i_d^{*2} + i_q^{*2}}$ . Finally, the  $\alpha - \beta$  references can be expressed as  $i_\alpha^*(t) = I^* \sin \omega_e t$ ,  $i_\beta^*(t) = I^* \cos \omega_e t$ ,  $i_x^*(t) = 0$ ,  $i_y^*(t) = 0$ .

Regarding PI tuning for IFOC, the influential works of the 1990s such as (De Wit et al., 1996) provide tuning methods where global stability is guaranteed. Later on other methods have appeared, where most of the efforts have concentrated on: sensor-less operation, estimation of the rotor time constant, extension of the PI with operating-point based scheduling and/or adaptivity, fault-tolerant capabilities. simple tuning rules are no longer applicable (Díaz et al., 2021), thus researchers have to resort to extensive simulations.

In this context, sensor-less techniques are sometimes used to estimate velocity as in (Chi et al., 2023). However, Quadrature Optical Encoders (QOEs for simplicity), along with micro-controller peripherals, are primarily used for that purpose. Therefore, QOEs can be considered as the basis for position and motion control in electrical systems (Vazquez-Gutierrez et al., 2019). Speed estimation using QOEs is based on the counting of encoder pulses and digital state machines with the ability to detect the direction of rotation. A recent review of these methods can be found in (Anuchin et al., 2019), where it is shown that the algorithms used present precision problems due to their asynchronous operation with the speed controller loop. These problems can be mitigated, but require new dedicated hardware, which increases the cost of speed estimation. For example, the hardware responsible for processing the encoder pulses is expanded in (Anuchin et al., 2019). As a consequence, two capture units of a TMS320F28035 micro-controller are required together with the internal peripheral, the so-called quadrature encoder pulse unit.

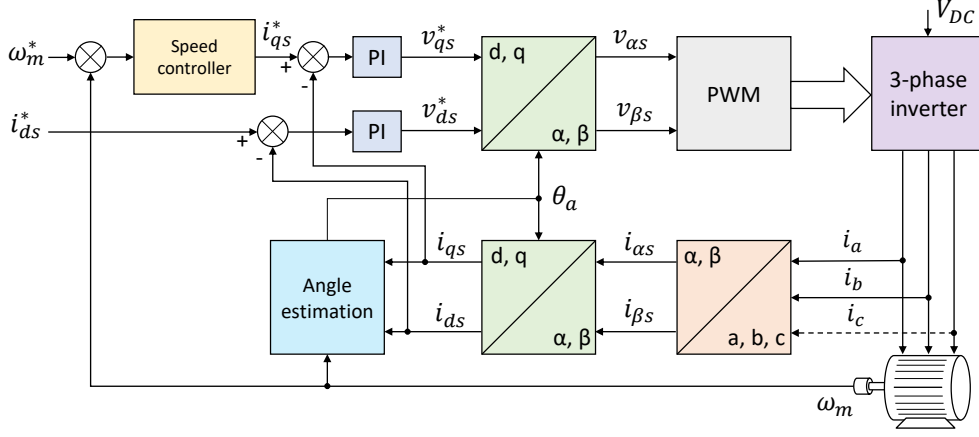


Figure 1: Diagram of IFOC.

In (Colodro et al., 2024), a new speed estimation method is proposed and analyzed using mathematics and simulation. The proposed technique is based on the oversampling of the encoder pulses and on the fact, as will be shown later, that the sequence of pulses is a sigma-delta modulated signal if the angle is sampled at a regular rate. Consequently, the proposed method is simple, does not represent a significant computational load, and achieves an acceptable performance. Furthermore, due to regular sampling, the synchronization of the speed estimation and electrical control units are also simplified.

### 3. Encoder-based speed measurement model

Many DSP are fitted with a module for encoder pulse management. In the case of the TMS320F28335 DSP, an Enhanced Quadrature Encoder Pulse (EQEP) module is provided for this purpose. The EQEP captures encoder pulses and can generate counters to determine position and speed (including its direction). The diagram of Figure 2 presents the various elements of the EQEP module. In particular, the PCCU unit provides with counters of the pulses arriving from the encoder. Similarly, the Unit Timer Base includes a 32 bit chronometer to generate interrupts at certain periods, according to the QUPRD register.

The mechanical speed is typically measured using the EQEP module interfacing with an incremental encoder. Two different first-order approximations can be applied, where the mechanical speed is estimated by counting the number of pulses in a fixed time (the conventional method in normal speed operation) or counting the time to obtain a fixed number of pulses (the approach that can be considered in very low-speed operation) (Soto-Marchena et al., 2023). Considering the first approach, the estimation of mechanical rotor speed is obtained as

$$\hat{\omega} = k_{\omega} \frac{\Delta x}{T_{\omega}} \quad (4)$$

where  $k_{\omega}$  is a parameter depending on the number of pulses per revolution that the encoder can provide (including quadrature).

In the case used for experimentation, a GHM510296R/2500 encoder is used, providing  $10^4$  pulses per revolution (ppr). This is a high-end product, for many applications the encoders used have a lower ppr.

The EQEP peripheral is programmed to schedule a fixed timing interruption event that facilitates the calculation of encoder pulses and the rotor speed between two contiguous events. The time between interrupts corresponds to period  $T_{\omega}$  in (4).

It can be deduced that the quality of the measurement is strongly related to  $T_{\omega}$ . This statement will be made more precise later in this section. For the time being, it is easy to see that longer interruption periods result in better (higher-precision) speed measurements. However, the measurement takes longer to be ready, thus reducing the band-width of the sensor. Typical EQEP interruption periods range between 0.05 ms (milliseconds) and 10 ms, depending on the application.

The estimation provided by (4) has some issues stemming from the quantized nature of the variable  $\Delta x$ . Indeed, if the true speed  $\omega$  is not a multiple of  $k_{\omega}/T_{\omega}$  then the value of  $\Delta x$  will change for different interruption periods even for the same  $\omega$ .

The common practice is to low-pass filter  $\hat{\omega}$  with digital means using the EQEP routines. This takes little computing time and provides a smoother measurement. Please notice that not filtering at all has the effect of letting the oscillations into the electrical part of the control systems, as the measured speed is used for various purposes in the IFOC-like scheme (see Figure 1). This, in turn, produces current and torque ripples that are undesirable in most cases. On the other hand, filtering has the undesirable effect of reducing the phase margin in the direct loop. This makes the speed control either sluggish or overshooting depending on the control tuning.

A model for the speed measurement process can be estimated from (4) considering that the arrival times of pulses is linked to the actual speed. In practice the simple model  $\omega^e(t) = \omega(t - T_{\omega})$  is found to provide a good match. This model neglects steady state deviations of speed measurements and treats the measurement process as a time delay.

### 4. Fuzzy speed estimator based on encoder readings

Figure 3 presents the speed estimated using (4) with no filtering ( $\omega_e$ ) during a step change in speed ( $\omega_r$ ). The oscillations in the measurement can be clearly seen. During steady state, the true speed ( $\omega_r$ ) is the average of the estimated values ( $\omega_e$ ). This prompts for the use of a low-pass filter. However, this introduces a diminution of phase that translates into lower pha-

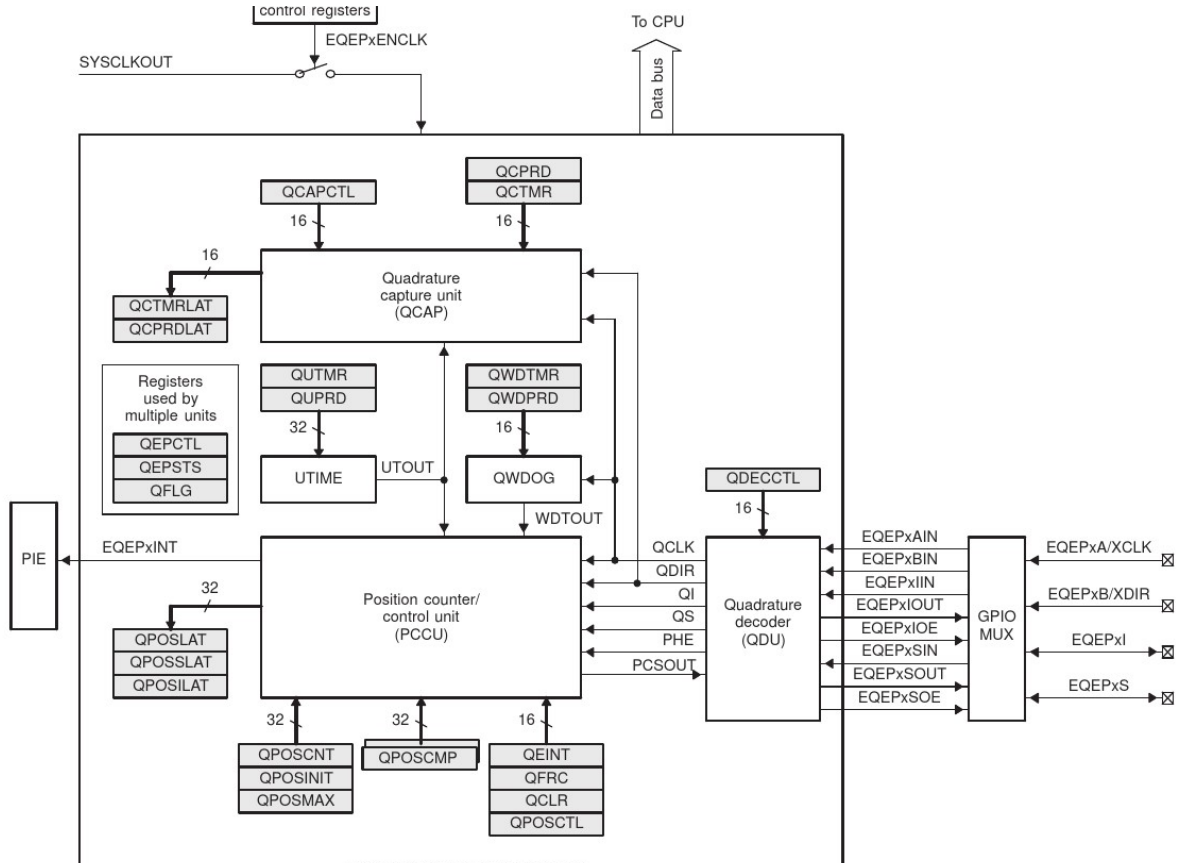


Figura 2: Diagram of the EQEP module.

se margins, negatively affecting the overall control behavior. A smoothing effect can be also obtained by increasing the  $T_\omega$  period.




Figura 3: Speed estimation with standard method with low  $T_\omega$  and no filtering.

Figure 5 presents the speed estimated using (4) with low-pass filtering ( $\omega_f$ ) during a step change in speed ( $\omega_r$ ). In this case the steady state performance is adequate, with virtually no ripples. The transient behavior is characterized by the time constant of the filter.

The proposal uses a fuzzy inference map to determine which situation the speed is in. During steep transients, the inference map indicates the use of the standard method with the lowest possible  $T_\omega$  and no filtering. For medium transients the inference map indicates the use of higher  $T_\omega$  and some filtering. Finally, during steady state (or quasi steady-state) condi-

tions, the inference map indicates the use of a higher  $T_\omega$  and filtering. The inference map uses as independent variables the last two values of the quantity  $\Delta Q(k)$  provided by (5), where  $k$  refers to the EQEP interruption period number that might not be the same as the IFOC sampling number. Two values of  $\Delta Q$  are considered at each EQEP period:  $\Delta Q_1 = \Delta Q(k)$  and  $\Delta Q_2 = \Delta Q(k - 1)$ . The rationale is that, large values of  $\Delta Q$  cannot be obtained from steady state operation since the oscillations in the pulses are constrained. Also, in a state of speed change during a transient, the changes in  $Q$  are not confined to a single EQEP period.

$$\Delta Q(k) = \Delta x(k) - \Delta x(k - 1) \quad (5)$$




Figura 4: Contour map of the fuzzy inference map.

The actual values of the inference map are presented in Figure 4. In this map, a high value indicates the presence of steep changes in speed, whereas a low value indicates no speed changes. In this way, the fuzzy inference allows blending the standard method with different values of  $T_\omega$  and filtering according to the situation.

The results can be seen in Figure 5 marked as  $\omega_p$ . The fast response to changes is combined with a ripple as small as those found with the standard method. This proves that the proposal retains the positive traits of a large  $T_\omega$  while avoiding the sluggish response during transients.




Figura 5: Speed estimations with proposed method and standard method.

## 5. Conclusions

The proposed method makes use of existing and available routines in EQEP modules of DSP. The results greatly enhance those obtained by the standard method. The increase in computational load is negligible for modern DSP hardware. The fuzzy inference map used in this case is of dimension 2, but it can be extrapolated to higher dimensions.

One important aspect is that the DSP setup needed for the proposal is the same as in the commonly found estimation by pulse counting. This makes the proposal easier to deploy replacing the standard scheme.

## Acknowledgments

This research is part of project TED2021-129558B-C22 funded by MCIN/AEI/10.13039/501100011033 and by the “European Union NextGenerationEU/PRTR”, is also part of project PID2022-142069OB-I00, funded by MCIN/AEI/10.13039/501100011033/FEDER, UE.

## Referencias

Anuchin, A., Astakhova, V., Shpak, D., Zharkov, A., Briz, F., 2017. Optimized method for speed estimation using incremental encoder. In: 2017 International Symposium on Power Electronics (Ee). pp. 1–5. DOI: 10.1109/PEE.2017.8171692

Anuchin, A., Dianov, A., Briz, F., 2019. Synchronous constant elapsed time speed estimation using incremental encoders. IEEE/ASME Transactions on Mechatronics 24 (4), 1893–1901.

Arahal, M. R., Barrero, F., Ortega, M. G., Martín, C., 2016. Harmonic analysis of direct digital control of voltage inverters. Mathematics and Computers in Simulation 130, 155–166.

Arahal, M. R., Barrero, F., Satué, M. G., Martín, C., Bermúdez, M., 2023. Evolutionary gaps stator current control of multiphase drives balancing harmonic content. IEEE Transactions on Industrial Electronics.

Arahal, M. R., Martín, C., Kowal, A., Castilla, M., Barrero, F., 2020. Cost function optimization for predictive control of a five-phase im drive. Optimal Control Applications and Methods 41 (1), 84–93.

Benkhoris, M., Ait-Ahmed, M., 1996. Discrete speed estimation from a position encoder for motor drives. In: 1996 Sixth International Conference on Power Electronics and Variable Speed Drives (Conf. Publ. No. 429). pp. 283–287. DOI: 10.1049/cp:19960928

Bermudez, M., Arahal, M. R., Duran, M. J., Gonzalez-Prieto, I., 2020. Model predictive control of six-phase electric drives including arx disturbance estimator. IEEE Transactions on Industrial Electronics 68 (1), 81–91.

Bermúdez, M., Martín, C., González-Prieto, I., Durán, M. J., Arahal, M. R., Barrero, F., 2020. Predictive current control in electrical drives: an illustrated review with case examples using a five-phase induction motor drive with distributed windings. IET Electric Power Applications 14 (8), 1291–1310.

Bucciarelli, A., Duarte, J. D., De Angelo, C., Rey, J. M., Quiroga, O., feb. 2024. Reducción de la eficiencia de un pmsm con control seis-pulsos con respecto al vectorial: Estudio teórico y validación experimental. Revista Iberoamericana de Automática e Informática industrial. DOI: 10.4995/riai.2024.19851

Chen, Y., Yang, M., Xu, D., Blaabjerg, F., 2019. A novel frequency characteristic model and noise shaping method for encoder-based speed measurement in motor drive. In: 2019 10th International Conference on Power Electronics and ECCE Asia (ICPE 2019 - ECCE Asia). pp. 1–6. DOI: 10.23919/ICPE2019-ECCEAsia42246.2019.8796938

Chi, X., Wang, C., Wu, Q., Yang, J., Lin, W., Zeng, P., Li, H., Shao, M., 2023. A ripple suppression of sensorless foc of pmsm electrical drive system based on mras. Results in Engineering 20, 101427.

Colodro, F., Mora, J., Barrero, F., Arahal, M., Martínez-Heredia, J., 2024. Analysis and simulation of a novel speed estimation method based on oversampling and noise shaping techniques. Results in Engineering 21, 101670.

De Wit, P. A., Ortega, R., Mareels, I., 1996. Indirect field-oriented control of induction motors is robustly globally stable. Automatica 32 (10), 1393–1402.

Díaz, J., Costa-Castelló, R., Dormido, S., 2021. An interactive approach to control systems analysis and design by the root locus technique. Revista Iberoamericana de Automática e Informática Industrial 18 (2), 172–188.

Duran, M., Barrero, F., Toral, S., Ruiz Arahal, M., Gregor, R., Marfil, R., 2008. Multi-phase generators viability for offshore wind farms with hvdc transmission. Renewable Energy & Power Quality Journal, 1 (6), 246–251.

Kowal G, A., Arahal, M. R., Martín, C., Barrero, F., 2019. Constraint satisfaction in current control of a five-phase drive with locally tuned predictive controllers. Energies 12 (14), 2715.

Limon, D., Alamo, T., Bravo, J., Camacho, E., Ramirez, D., Muñoz de la Peña, D., Alvarado, I., Arahal, M., 2007. Interval arithmetic in robust nonlinear mpc. Assessment and Future Directions of Nonlinear Model Predictive Control, 317–326.

Martín, C., Arahal, M. R., Barrero, F., Durán, M. J., 2016. Multiphase rotor current observers for current predictive control: A five-phase case study. Control Engineering Practice 49, 101–111.

Martin, C., Barrero, F., Arahal, M. R., Duran, M. J., 2019. Model-based predictive current controllers in multiphase drives dealing with natural reduction of harmonic distortion. Energies 12 (9), 1679.

Negrea, A. C., Imecs, M., Incze, I. I., Pop, A., Szabo, C., 2012a. Error compensation methods in speed identification using incremental encoder. In: 2012 International Conference and Exposition on Electrical and Power Engineering. pp. 441–445. DOI: 10.1109/ICEPE.2012.6463857

Negrea, C. A., Incze, I. I., Imecs, M., Pop, A. V., Szabo, C., 2012b. An improved speed identification method using incremental encoder in electric drives. In: Proceedings of 2012 IEEE International Conference on Automation, Quality and Testing, Robotics. pp. 536–540. DOI: 10.1109/AQTR.2012.6237769

Ramirez, D. R., Martín, C., Kowal G, A., Arahal, M. R., 2019. Min-max predictive control of a five-phase induction machine. Energies 12 (19), 3713.

Rodas, J., Barrero, F., Arahal, M. R., Martín, C., Gregor, R., 2016. Online estimation of rotor variables in predictive current controllers: A case study using five-phase induction machines. IEEE Transactions on Industrial Electronics 63 (9), 5348–5356.

Satué, M. G., Arahal, M. R., Ramirez, D. R., 2023. Estimation of rotor currents in polyphase machines for predictive control. Revista Iberoamericana de Automática e Informática industrial 20 (1), 25–31.

Satué, M. G., Arahal, M. R., Rodríguez Ramírez, D., Barrero, F., abr. 2023.

- Control predictivo polifásico mediante dos constelaciones de vectores virtuales de tensión. *Revista Iberoamericana de Automática e Informática industrial* 20 (4), 347–354.  
DOI: 10.4995/riai.2023.19205
- Soto-Marchena, D., Barrero, F., Colodro, F., Arahal, M. R., Mora, J. L., 2023. On-site calibration of an electric drive: A case study using a multiphase system. *Sensors* 23 (17), 7317.
- Toral, S. L., Torres, M. M., Barrero, F., Arahal, M. R., 2010. Current paradigms in intelligent transportation systems. *IET Intelligent Transport Systems* 4 (3), 201–211.
- Vazquez-Gutierrez, Y., O’Sullivan, D. L., Kavanagh, R. C., 2019. Evaluation of three optical-encoder-based speed estimation methods for motion control. *The Journal of Engineering* 2019 (17), 4069–4073.

## Nuevo algoritmo de entrenamiento híbrido para modelos neuronales de sistemas dinámicos

Iturbe, Lucía.<sup>a,\*</sup>, Irigoyen, Eloy.<sup>a</sup>, Larrea, Mikel.<sup>a</sup>, Sendra, Javier.<sup>b</sup>, Sanchis, Javier.<sup>b</sup>

<sup>a</sup>Dpto. de Ingeniería de Sistemas y Automática, Universidad de País Vasco / Euskal Herriko Unibertsitatea (UPV/EHU).

<sup>b</sup>Dpto. de Ingeniería de Sistemas y Automática, Universitat Politècnica de València (UPV).

**To cite this article:** Iturbe, Lucía., Irigoyen, Eloy., Larrea, Mikel., Sendra, Javier., Sanchis, Javier. 2024. New hybrid training algorithm for neural network models of dynamic systems. XIX Simposio CEA de Control Inteligente. 2024.

### Resumen

Este trabajo presenta una propuesta de algoritmo de entrenamiento para modelos neuronales recurrentes de sistemas dinámicos. Se trata de un método de entrenamiento orientado a producir modelos neuronales capaces de realizar predicciones de varias muestras a futuro, con el objetivo de posteriormente integrar dichos modelos en estrategias de control inteligente. Concretamente, se han entrenado redes NARX para un modelo dinámico SISO con la propuesta de entrenamiento híbrido así como con el clásico entrenamiento en bucle abierto y una estrategia de entrenamiento que combina la configuración en bucle abierto y bucle cerrado. Asimismo, se han realizado validaciones de los modelos obtenidos, en predicciones desde 1 muestra hasta 10 muestras. El objetivo es establecer un análisis comparativo entre los métodos de entrenamiento ya existentes en la literatura y la propuesta de entrenamiento híbrido, la cual lleva a cabo la fase de entrenamiento en una única etapa.

*Palabras clave:* modelo neuronal, sistemas dinámicos complejos, entrenamiento híbrido, entrenamiento en bucle cerrado, SISO.

### New hybrid training algorithm for neural network models of dynamic systems

#### Abstract

This work presents a new training algorithm for recurrent neural network models of dynamic systems. The training method is designed to produce neural models capable of making predictions several steps into the future, with the aim of subsequently integrating these models into intelligent control strategies. Specifically, NARX networks have been trained for a SISO dynamic model using the proposed hybrid training method, as well as the classic open-loop training and a training strategy that combines both open-loop and closed-loop configurations. Additionally, the obtained models have been validated for predictions at both 1-step and 10-step horizons. The objective is to conduct a comparative analysis between the existing training methods in the literature and the proposed hybrid training method, which is performed in a unique training stage.

*Keywords:* neural-network model, complex dynamic systems, hybrid training, closed-loop training, SISO.

### 1. Introducción

El modelado de sistemas dinámicos no-lineales es una tarea compleja. Cada vez es más común el uso de redes neuronales artificiales (RNA) para abordar esta tarea, dado que permiten representar funciones no-lineales complejas. En concreto, en el modelado de sistemas dinámicos está muy extendido el uso de redes neuronales recurrentes (RNN) ((Kang et al., 2023), (Kumar, 2023), (Zabaljauregi et al., 2023)). A diferencia de las re-

des neuronales feedforward convencionales, las RNN tienen conexiones retroalimentadas que les permiten mantener y utilizar información de estados anteriores en la secuencia, lo que las hace ideales para modelar sistemas dinámicos no-lineales. No obstante, son precisamente esas realimentaciones de los estados las que dificultan el entrenamiento de estos modelos neuronales, generando problemas de convergencia y estabilidad.

Asimismo, un aspecto importante a considerar es el uso que se le va a dar al modelo neuronal recurrente. Si el objetivo es in-

\*iturbereylucia@gmail.com

tegrar el modelo en una estrategia de control como la del control predictivo basado en modelo (*Model Predictive Control*, MPC) es esencial que dicho modelo sea capaz de realizar predicciones de varias muestras a futuro sin inestabilizarse o divergir significativamente. Esta capacidad para realizar predicciones de manera adecuada es un aspecto importante a tener en cuenta tanto en el entrenamiento del modelo neuronal como en su posterior validación. Concretamente, este trabajo tiene como objetivo obtener modelos neuronales para integrarlos en la estrategia de control iMO-NMPC (Larrea et al., 2023). Esta estrategia de control aúna técnicas inteligentes como redes neuronales, algoritmos genéticos y lógica difusa, y constituye una línea de trabajo dentro del grupo de investigación de control inteligente (GICI) de la UPV/EHU.

La principal tendencia a la hora de entrenar modelos neuronales recurrentes es la del método en bucle abierto (*open-loop training*) o método serie-paralelo. Consiste en entrenar la red utilizando los datos reales medidos de las salidas/estados de la red sin retroalimentar la predicciones de la propia red. Asimismo, existe también el entrenamiento en bucle cerrado (*closed-loop training*) o entrenamiento paralelo. En el entrenamiento en bucle cerrado, el modelo recibe retroalimentación de sus predicciones anteriores como entrada adicional durante la fase de entrenamiento. Los diagramas de la configuración en bucle abierto y bucle cerrado para una red de tipo NARX pueden apreciarse en las Figuras 1 y 2, donde  $w$  son los pesos,  $b$  los bias y  $R$  los regresores.




Figura 1: NARX bucle abierto.




Figura 2: NARX bucle cerrado.

Existe una serie de aspectos a considerar a la hora de elegir el método de entrenamiento como bien se expone en (Ribeiro and Aguirre, 2018). Por una parte, el método en bucle cerrado precisa de una versión modificada del algoritmo del gradiente descendente, lo que aumenta el coste computacional del entrenamiento, mientras que el método en bucle abierto sí admite el algoritmo clásico del gradiente descendente ((Saggar et al., 2007), (Kelley and Hagan, 2024)). Además, como se menciona en (Tijani et al., 2014), las entradas que se le proporcionan a la red en el entrenamiento en bucle abierto, al ser datos medidos, son más precisas que las predicciones que se proporcionan en bucle cerrado. Sin embargo, hay quien argumenta que el entrenamiento en bucle cerrado genera modelos neuronales con una mejor capacidad de realizar predicciones ((Su et al., 1992)).

En el contexto del entrenamiento de modelos neuronales NARX (*Nonlinear AutoRegressive with eXternal input*), una gran parte de los trabajos se limitan al entrenamiento en bucle abierto ((Du et al., 2020), (Rong et al., 2023), (Habibi et al., 2021), (Tijani et al., 2014)), ya que generalmente es más complicado obtener resultados satisfactorios con el entrenamiento en bucle cerrado (Ghiormez et al., 2017). Asimismo, hay quienes proponen combinar una fase inicial de entrenamiento en bucle abierto con una segunda fase en bucle cerrado ((Phan et al., 2013), (Zhang et al., 2023)).

En este trabajo se hace una propuesta de algoritmo de entrenamiento híbrido para modelos neuronales NARX, ha desarrollar en una única fase de entrenamiento, lo que sería una ventaja computacional y organizativa con respecto a los entrenamientos realizados en dos fases consecutivas. Se trata de un algoritmo orientado a producir modelos que realicen predicciones a futuro, y al igual que el método en bucle abierto, el algoritmo híbrido puede ser implementado con el gradiente descendente.

## 2. Algoritmo de entrenamiento híbrido

El algoritmo de entrenamiento híbrido consiste en una fase inicial de entrenamiento en bucle abierto (entrenamiento a una muestra,  $h=1$ ). Después, se reordenan los datos de entrenamiento con las predicciones a 1 muestra de la propia red como se ilustra en la Figura 3. Así, se prosigue con una segunda fase de entrenamiento a  $h=2$ . Una vez terminada esta fase, se volverían a reordenar los datos de entrenamiento con las predicciones de la red para comenzar con la fase de entrenamiento de  $h=3$ , y así sucesivamente. Se continuará hasta alcanzar el número de muestras deseado. De modo que si deseamos que nuestro modelo neuronal sea capaz de realizar predicciones a 10 muestras, un criterio orientativo sería que el algoritmo contara con 10 fases de entrenamiento.

	INPUT	TARGET	PREDICCIÓN
Entrenamiento $h=1$	$[u(t), u(t-1), \dots, y(t), y(t-1), y(t-2), \dots]$	$[y(t+1)]$	$[\hat{y}(t+1)]$
	$[u(t+1), u(t), \dots, y(t+1), y(t), y(t-1), \dots]$	$[y(t+2)]$	$[\hat{y}(t+2)]$
	$[u(t+2), u(t+1), \dots, y(t+2), y(t+1), y(t), \dots]$	$[y(t+3)]$	$[\hat{y}(t+3)]$
	$[u(t+3), u(t+2), \dots, y(t+3), y(t+2), y(t+1), \dots]$	$[y(t+4)]$	$[\hat{y}(t+4)]$
	...	...	...
Entrenamiento $h=2$	$[u(t), u(t-1), \dots, y(t), y(t-1), y(t-2), \dots]$	$[y(t+1)]$	$[\hat{y}(t+1)]$ ✗
	$[u(t+1), u(t), \dots, \hat{y}(t+1), y(t), y(t-1), \dots]$	$[y(t+2)]$	$[\hat{y}(t+2)]$
	$[u(t+2), u(t+1), \dots, \hat{y}(t+2), y(t+1), y(t), \dots]$	$[y(t+3)]$	$[\hat{y}(t+3)]$
	$[u(t+3), u(t+2), \dots, \hat{y}(t+3), y(t+2), y(t+1), \dots]$	$[y(t+4)]$	$[\hat{y}(t+4)]$
	...	...	...
Entrenamiento $h=3$	$[u(t), u(t-1), \dots, y(t), y(t-1), y(t-2), \dots]$	$[y(t+1)]$	$[\hat{y}(t+1)]$ ✗
	$[u(t+1), u(t), \dots, \hat{y}(t+1), y(t), y(t-1), \dots]$	$[y(t+2)]$	$[\hat{y}(t+2)]$ ✗
	$[u(t+2), u(t+1), \dots, \hat{y}(t+2), \hat{y}(t+1), y(t), \dots]$	$[y(t+3)]$	$[\hat{y}(t+3)]$
	$[u(t+3), u(t+2), \dots, \hat{y}(t+3), \hat{y}(t+2), y(t+1), \dots]$	$[y(t+4)]$	$[\hat{y}(t+4)]$
	...	...	...
Entrenamiento $h=4$	$[u(t), u(t-1), \dots, y(t), y(t-1), y(t-2), \dots]$	$[y(t+1)]$	$[\hat{y}(t+1)]$ ✗
	$[u(t+1), u(t), \dots, \hat{y}(t+1), y(t), y(t-1), \dots]$	$[y(t+2)]$	$[\hat{y}(t+2)]$ ✗
	$[u(t+2), u(t+1), \dots, \hat{y}(t+2), \hat{y}(t+1), y(t), \dots]$	$[y(t+3)]$	$[\hat{y}(t+3)]$ ✗
	$[u(t+3), u(t+2), \dots, \hat{y}(t+3), \hat{y}(t+2), \hat{y}(t+1), \dots]$	$[y(t+4)]$	$[\hat{y}(t+4)]$
	...	...	...

Figura 3: Reordenamiento de los vectores de los datos de entrenamiento para 4 fases de entrenamiento.



Como se puede apreciar en la Figura 3, las predicciones que realice la red al acabar una fase de entrenamiento, se insertarán en los propios datos de entrenamiento para comenzar con la siguiente fase, desplazando a las predicciones ya existentes. Asimismo, como indican las cruces rojas, con cada fase de entrenamiento se descartará el primer vector de datos. Cabe mencionar que mientras se esté entrenando la red, la configuración de la misma será en bucle abierto (ver Figura 1).

### 3. Diseño de los experimentos

Con motivo de comprobar la eficacia del algoritmo híbrido, se ha llevado a cabo una serie de entrenamientos de modelos neuronales. Para este caso particular, se ha optado por modelar una variante del sistema no lineal sintético SISO (Single Input Single Output) propuesto en (Narendra and Parthasarathy, 1990). Se trata de un sistema expresamente diseñado para comprobar la capacidad del modelo neuronal de captar no linealidades, siendo la ecuación matemática que lo describe es la siguiente, donde  $K_1 = 0,3$ ,  $K_2 = 2,4$ ,  $K_3 = 1,1$  y  $K_4 = 0,8$ .

$$y(k + 1) = K_1 u^3(k) + \frac{K_2 y(k) - K_3 y(k - 1)}{1 + K_4 y^2(k)} \quad (1)$$

Con motivo de visualizar las no linealidades del mencionado sistema (ecuación 1), en la Figura 4 se ha representado gráficamente la relación entrada-salida del sistema en régimen estacionario, eligiendo el rango con las dinámicas no lineales más significativas.




Figura 4: Relación entrada-salida del sistema 1 en régimen estacionario.

En cuanto al entrenamiento de las redes NARX, se han seguido las mismas pautas que en el trabajo (Zabaljauregi et al., 2023). En concreto, se han entrenado redes de una única capa oculta con neuronas de un rango de 4 a 20, retardos de la entrada externa de 1 a 4 y retardos de salida real de 1 a 4. Además, para cada una de estas configuraciones se han realizado 10 repeticiones.

Primero, se han realizado los entrenamientos en bucle abierto y después han sido repetidos con el entrenamiento híbrido,

todo ello usando la librería de Keras<sup>1</sup> que ofrece Python<sup>2</sup>. Asimismo, se han realizado entrenamientos en bucle abierto y luego en bucle cerrado usando Matlab<sup>3</sup>. Cabe mencionar que para el caso concreto del sistema de la ecuación 1, no ha sido posible alcanzar entrenamientos satisfactorios directamente en bucle cerrado, dado que el algoritmo de entrenamiento en bucle cerrado que ofrece Matlab no ha sido capaz de converger sin una fase previa de entrenamiento en bucle abierto.

Es importante señalar que el entrenamiento en bucle abierto y el entrenamiento híbrido han sido programados en Python con el algoritmo de optimización de Adam (*Adaptive Moment Estimation*), mientras que el entrenamiento de bucle abierto + bucle cerrado ha sido programado en Matlab con el algoritmo de optimización de Levenberg-Marquardt. Asimismo, según el análisis realizado por los autores, el algoritmo Adam no está disponible en Matlab y el algoritmo Levenberg-Marquardt no está disponible en Python. Ninguno de los algoritmos que tienen en común Matlab y Python, como el del Gradiente Descendente, han sido capaces de converger en Matlab, de modo que, hasta el momento, no ha sido posible emplear el mismo algoritmo en ambas plataformas.

### 4. Resultados

Una vez finalizada la fase de entrenamiento, se ha realizado la validación de todos los modelos neuronales obtenidos. Para ello, se ha empleado el error cuadrático medio (MSE), donde  $N$  es el número de muestras de los datos de validación,  $y_i$  es la salida real y  $\hat{y}_i$  es la salida predicha:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2)$$




Figura 5: MSE de configuraciones para el entrenamiento híbrido, para diferente cantidad de neuronas y diferente cantidad de retardos expresado como (retardos entrada, retardos salida).

<sup>1</sup>Versión 2.10.0 de la librería Keras

<sup>2</sup>Versión 3.10.13 de Python

<sup>3</sup>versión 2023b de Matlab

Por una parte, se ha realizado una validación de predicción a 10 muestras con todos los modelos. En las Figuras 5 y 6 pueden apreciarse los resultados de dichas validaciones para los modelos entrenados con el algoritmo híbrido en Python y los modelos entrenados en bucle abierto y bucle cerrado en Matlab respectivamente, donde se muestra el error en escala logarítmica de la mejor red de las 10 entrenadas para cada configuración.




Figura 6: MSE de configuraciones para el entrenamiento en bucle abierto + bucle cerrado, para diferente cantidad de neuronas y diferente cantidad de retardos expresado como (retardos entrada, retardos salida).

Si analizamos los resultados de las Figuras 5 y 6, se puede apreciar como los entrenamientos de Matlab tienen una mayor variabilidad. Es decir, se obtienen modelos neuronales con errores de una distancia de varios órdenes de magnitud. A diferencia de en Python donde el error es más homogéneo para la mayoría de configuraciones. No obstante, se pueden apreciar mejores modelos con el entrenamiento de bucle abierto + bucle cerrado de Matlab, aunque en el orden de magnitud de los datos por el entrenamiento híbrido, los cuales se han logrado en una única etapa de entrenamiento.




Figura 7: Media del error MSE de todas las configuraciones para el entrenamiento en bucle abierto y el entrenamiento híbrido.

Por otra parte, con motivo de realizar una mejor comparativa entre el entrenamiento en bucle abierto y el entrenamiento

híbrido, se ha realizado una validación en un rango de 1 a 10 muestras estimadas a futuro de todos los modelos neuronales. Después, se ha calculado la media del error de todas las configuraciones para cada uno de los horizontes, para así mostrar su comparativa en la Figura 7. Como era de esperar, para horizontes pequeños, la estrategia en bucle abierto consigue mejores resultados. No obstante, para horizontes más elevados, el algoritmo híbrido parece ser la mejor opción.

### 5. Conclusiones

En el contexto del entrenamiento de modelos neuronales recurrentes, el método de entrenamiento a menudo no recibe mucha atención. Aunque la estrategia en bucle abierto se muestra suficiente en muchos casos, puede no serlo para sistemas no lineales de mayor complejidad. Por ende, este trabajo plantea la relevancia de considerar otras alternativas de entrenamiento para mejorar la capacidad predictiva del modelo, especialmente cuando se busca una predicción futura fiable como es en el caso del MPC. Unido a todo esto, esta propuesta logra llevar a cabo el entrenamiento equivalente al de lazo cerrado, en una sola etapa, frente a las dos de la combinación de lazo-abierto y lazo-cerrado. Si bien estos entrenamientos son realizados fuera de línea (off-line) en la práctica totalidad de los trabajos, sería conveniente en un posterior trabajo analizar y comparar el gasto computacional ocasionado por ambas estrategias de entrenamiento.

Asimismo, se ha visto que para el caso del sistema 1 el algoritmo híbrido y la técnica en bucle abierto consiguen resultados equivalentes, siendo una mejor opción para horizontes bajos el entrenamiento en bucle abierto y para horizontes más elevados el algoritmo híbrido. Además, se ha visto que para el caso de Matlab, los entrenamientos han producido resultados de una gran variabilidad, lo que revela la importancia de diseñar entrenamientos que recorran un rango suficiente de configuraciones de modelos neuronales.

En cualquier caso, es necesario examinar la eficacia del algoritmo híbrido en otro tipo de sistemas, como los sistemas MIMO (Multiple Input Multiple Output) y aquellos con dinámicas más complejas que no sea posible abordar con el entrenamiento en bucle abierto. Además, también es necesario establecer una comparativa equivalente entre el entrenamiento híbrido en Python y los algoritmos de entrenamiento que ofrece Matlab, que por el momento no ha sido posible realizar al no disponer de un mismo algoritmo de optimización en ambas plataformas. Por el momento, el algoritmo híbrido se presenta como una alternativa a métodos de entrenamiento computacionalmente más costosos como aquellos que incluyen entrenamiento en bucle cerrado.

### Agradecimientos

Esta publicación es parte del proyecto de I+D+i PID2020-120087GB-C22, financiado por el Ministerio de Ciencia e Innovación (AEI / <http://dx.doi.org/10.13039/501100011033>).

**Referencias**

Du, L. H., Zhang, Q., Gao, C., Chen, H. L., Yin, Q., Ding, K., Fu, Y. P., Qu, D. X., Guo, F., 2020. Response characteristics prediction of surge protective device based on narx neural network. *IEEE Transactions on Electromagnetic Compatibility* 62, 74–82.  
DOI: 10.1109/TEMC.2018.2881216

Ghiormez, L., Panoiu, M., Panoiu, C., Pop, C., 2017. Electric current prediction for the nonlinear high power loads using narx neural networks. *2017 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*, 128–133.  
DOI: 10.1109/ISSPIT.2017.8388629

Habibi, M. R., Baghaee, H. R., Dragičević, T., Blaabjerg, F., 2021. Detection of false data injection cyber-attacks in dc microgrids based on recurrent neural networks. *IEEE Journal of Emerging and Selected Topics in Power Electronics* 9, 5294–5310.  
DOI: 10.1109/JESTPE.2020.2968243

Kang, T., Peng, H., Xu, W., Sun, Y., Peng, X., 2023. Deep learning-based state-dependent arx modeling and predictive control of nonlinear systems. *IEEE Access* 11, 32579–32594.  
DOI: 10.1109/ACCESS.2023.3263180

Kelley, J., Hagan, M. T., 3 2024. Comparison of neural network narx and nar-max models for multi-step prediction using simulated and experimental data. *Expert Systems with Applications* 237.  
DOI: 10.1016/j.eswa.2023.121437

Kumar, R., 2 2023. Memory recurrent elman neural network-based identification of time-delayed nonlinear dynamical system. *IEEE Transactions on Systems, Man, and Cybernetics: Systems* 53, 753–762.  
DOI: 10.1109/TSMC.2022.3186610

Larrea, M., Irigoyen, E., Artaza, F., Gómez-Garay, V., 2023. Model-based design of the imo-nmpc strategy: Real-time implementation”, booktitle=“18th international conference on soft computing models in industrial and environmental applications (soco 2023). Springer Nature Switzerland, 71–81.  
DOI: [https://doi.org/10.1007/978-3-031-42529-5\\_7](https://doi.org/10.1007/978-3-031-42529-5_7)

Narendra, K., Parthasarathy, K., 1990. Identification and control of dynamical systems using neural networks. *IEEE Transactions on Neural Networks* 1 (1), 4–27.  
DOI: 10.1109/72.80202

Phan, M. C., Beale, M. H., Hagan, M. T., 2013. A procedure for training recurrent networks. *The 2013 International Joint Conference on Neural Networks (IJCNN)*, 1–8.  
DOI: 10.1109/IJCNN.2013.6706994

Ribeiro, A. H., Aguirre, L. A., 11 2018. “parallel training considered harmful?”: Comparing series-parallel and parallel feedforward network training. *Neurocomputing* 316, 222–231.  
DOI: 10.1016/j.neucom.2018.07.071

Rong, Z., Dai, W., Feng, N., Yang, Y., Zhang, L., Wang, Z., Cai, Y., Chan, M., 8 2023. Generic compact modeling of emerging memories with recurrent narx network. *IEEE Electron Device Letters* 44, 1272–1275.  
DOI: 10.1109/LED.2023.3290681

Saggar, M., Mericli, T., Andoni, S., Miiikkulainen, R., 2007. System identification for the hodgkin-huxley model using artificial neural networks. *2007 International Joint Conference on Neural Networks*, 2239–2244.  
DOI: 10.1109/IJCNN.2007.4371306

Su, H. T., McAvoy, T. J., Werbos, P., 4 1992. Long-term predictions of chemical processes using recurrent neural networks: A parallel training approach. *Industrial and Engineering Chemistry Research* 31, 1338–1352.  
DOI: 10.1021/ie00005a014

Tijani, I. B., Akmelawati, R., Legowo, A., Budiyo, A., 2014. Nonlinear identification of a small scale unmanned helicopter using optimized narx network with multiobjective differential evolution. *Engineering Applications of Artificial Intelligence* 33, 99–115.  
DOI: 10.1016/j.engappai.2014.04.003

Zabaljauregi, A., Alonso, A., Larrea, M., Irigoyen, E., Sanchis, J., 2023. Control of mimo systems with imo-nmpc strategy. *17th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2022)*, 474–483.  
DOI: [https://doi.org/10.1007/978-3-031-18050-7\\_46](https://doi.org/10.1007/978-3-031-18050-7_46)

Zhang, X., Zhu, J., Tang, W., Yuan, Z., Wang, Z., 9 2023. Data-driven nonlinear mimo modeling for turbofan aeroengine control system of autonomous aircraft. *Control Engineering Practice* 138.  
DOI: 10.1016/j.conengprac.2023.105568



## Análisis del rendimiento de un sistema de control avanzado basado en el estándar IEC 61499<sup>☆</sup>

Guzmán González-Mateos<sup>a</sup>, Miguel A. Prada<sup>a</sup>, Antonio Morán<sup>a</sup>, Raúl González-Herbón<sup>a</sup>, José R. Rodríguez-Ossorio<sup>a</sup>, Manuel Domínguez<sup>a</sup>

<sup>a</sup>Grupo de Investigación SUPPRESS, Escuela de Ingenierías, Universidad de León, Campus de Vegazana, León, 24007, España  
<https://suppress.unileon.es>, [ggonzm@unileon.es](mailto:ggonzm@unileon.es)

**To cite this article:** González-Mateos, G., Prada, M.A., Morán, A., González-Herbón, R., Rodríguez-Ossorio, J.R., Domínguez, M., 2024. XIX Simposio CEA de Control Inteligente. 2024.

### Resumen

Este trabajo presenta un enfoque para el control PID y la optimización en un sistema distribuido, utilizando el estándar de control IEC 61499. Este estándar permite la comunicación entre diferentes PLC, los cuales se utilizan para desarrollar un control de un lazo SISO basado en eventos y estructurado en tres capas. La capa más baja se encarga de la adquisición cíclica de datos. La segunda capa realiza un control PID basado en eventos. La capa más alta ejecuta un algoritmo de optimización de control, específicamente un ajuste simple basado en Ziegler-Nichols que se utiliza para determinar los parámetros PID para diferentes puntos de operación. El enfoque propuesto se evalúa en un problema de control SISO de nivel de tanque, cuyo comportamiento puede ser modelado como un sistema de primer orden con tiempo muerto en cada punto de operación. El trabajo presentado se ha implementado utilizando dos PLCs físicos y un PLC virtualizado que se ejecuta en un ordenador industrial. Los resultados experimentales en el lazo de control SISO muestran la viabilidad del enfoque propuesto para el control basado en eventos en un sistema distribuido y abren interesantes preguntas de investigación de cara al diseño de controladores y la automatización distribuida.

*Palabras clave:* IEC 61499, PID, Sistemas de control distribuido, Ajuste de PID, Aplicaciones industriales.

### Performance analysis of an advanced control system based on IEC 61499

#### Abstract

This work presents an approach for PID control and optimization in a distributed system, using the IEC 61499 control standard. This standard enables communication among different PLCs, which are used to develop a three-layered event-driven control of a SISO loop. The lowest layer is in charge of cyclical data acquisition. The second layer carries out an event-based PID control. The highest layer runs a control optimization algorithm, specifically a simple tuning approach based on Ziegler-Nichols that is used to determine the PID parameters for different operating points. The proposed approach is assessed in a tank level SISO control problem, whose behavior can be modeled as a first-order plus dead time system in each operating point. For that purpose, it has been implemented using two PLCs and a software PLC running on an industrial computer. The experimental results on the SISO level control loop show the feasibility of the proposed approach for event-driven control in a distributed system and open interesting research questions in the fields of controller design and distributed automation.

*Keywords:* IEC 61499, PID, Distributed Control System, PID Tuning, Industrial application.

<sup>☆</sup> Esta publicación es parte de proyecto PID2020-117890RB-I00, financiado por MCIN/ AEI/10.13039/501100011033/. El trabajo de Guzmán González-Mateos está financiado por el Programa Propio de Ayudas para la realización de estudios de doctorado de la Universidad de León (Convocatoria 2022).

\* Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

## 1. Introducción

En la actualidad, un nuevo paradigma marcado por la digitalización de los procesos productivos ha dado como resultado la llamada cuarta revolución industrial. El aumento en el grado de interconexión digital ha puesto el foco en los sistemas ciberfísicos (CPS), que integran capacidades computacionales y de comunicación con procesos físicos (Lu, 2017). El estándar IEC 61499 surge en este contexto como respuesta a la necesidad de automatizaciones modernas y con un enfoque más modular, escalable y flexible. La idea principal del estándar es lograr una estructura descentralizada en la que el sistema de control esté distribuido a través de una red de comunicaciones. Para lograr esto, el estándar hace uso de un sistema de ejecución basado en eventos (Vyatkin, 2011; Lyu and Brennan, 2021). Así, el control no se basa en una ejecución cíclica tradicional, sino en el desencadenamiento de eventos por parte del sistema en respuesta a cambios en señales, la finalización de una tarea, la ocurrencia de un error o cualquier otra condición predefinida.

Para gestionar los eventos, los autómatas programables (PLCs) que siguen el estándar hacen uso de Bloques de Función, componentes modulares y reutilizables que pueden recibir eventos, procesar datos y generar nuevos eventos o salidas. Estos bloques responden a los eventos ejecutando algoritmos dentro de una máquina de estados que se programa utilizando Texto Estructurado, un lenguaje definido en IEC 61131. Una vez que el bloque termina, desencadena un evento de salida para realizar otra tarea. Los datos manipulados en IEC 61499 residen dentro de los bloques de función pero pueden fluir entre ellos. La encapsulación de datos asegura que cada bloque sea autocontenido, con sus propios datos de entrada y salida. Por su parte, el intercambio de datos ocurre a través de interfaces bien definidas, permitiendo que los bloques compartan información sin exponer su operación interna. La Figura 1 muestra la estructura de un Bloque de Función del estándar IEC 61499.

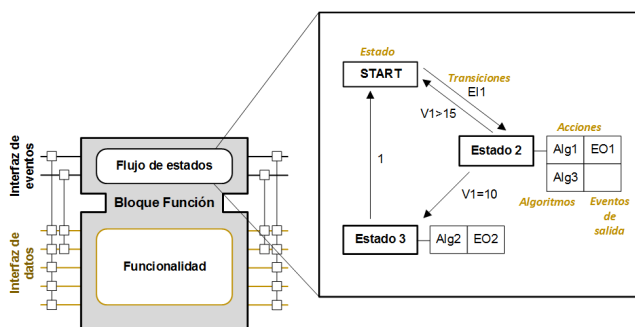


Figura 1: Bloque Función en la IEC 61499

Desde el punto de vista del control de procesos, este estándar abre nuevas oportunidades para el diseño e implementación de controladores en arquitecturas distribuidas. En este sentido, García et al. (2018) presentó un control predictivo basado en modelo de un sistema de oleoductos implementado utilizando bloques de función IEC 61499, mientras que la implementación de un control PID basado en eventos, utilizando el estándar IEC 61499, fue discutida por primera vez en Miguel-Escrib and Romero-Pérez (2018). En este contexto, el uso de técnicas de control basadas en eventos (Dormido et al., 2008)

aparece como una elección natural, puesto que la estrategia de control ahora se ejecuta de forma asíncrona.

Debido a los nuevos desafíos tecnológicos asociados a la digitalización industrial (Muñoz de la Peña et al., 2022), se requiere un importante esfuerzo educativo para hacer frente a la previsible adopción del estándar IEC 61499 por parte de la industria. Por otra parte, desde una perspectiva de investigación, es interesante estudiar las posibilidades del estándar IEC 61499 tanto en el control basado en eventos como en lo relativo a la implementación de técnicas de optimización de controladores en aplicaciones distribuidas. Finalmente, también resulta interesante analizar el cambio de paradigma que supone adoptar estrategias de control distribuidas y basadas en eventos, frente a las arquitecturas monolíticas y de ejecución cíclica tradicionalmente utilizadas en la industria.

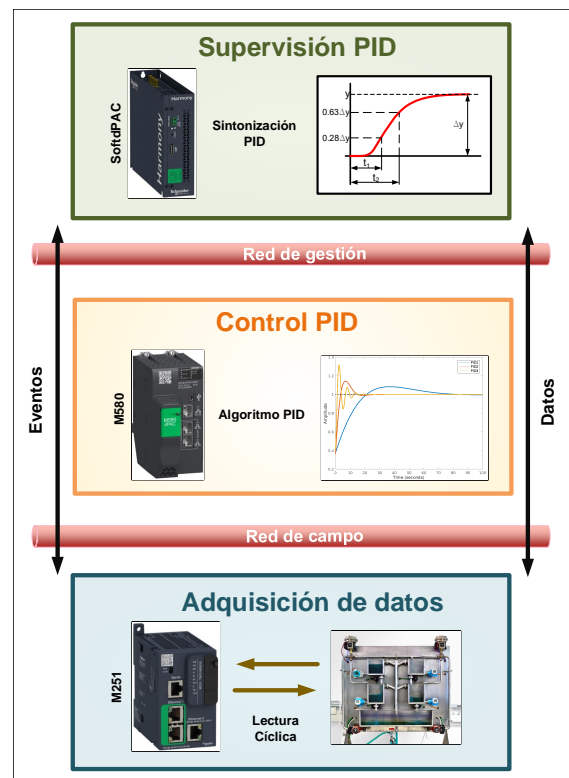


Figura 2: Representación de la arquitectura de control propuesta.

Por estas razones, en este documento se presenta una arquitectura concebida para trabajar en entornos distribuidos y dirigidos por eventos. Dicha arquitectura se divide en tres capas ejecutadas en diferentes dispositivos, para realizar la adquisición de datos, el control PID basado en eventos y la optimización del control. Para ello, el documento sigue la siguiente estructura: La Sección 2 explica el método propuesto para la arquitectura de control, incluyendo la adquisición de datos, el control PID y su parametrización. La Sección 3 presenta el sistema físico que se utilizará para los experimentos, así como las tecnologías específicas de automatización que se utilizan para la implementación del enfoque propuesto. Los experimentos y resultados, que se centran principalmente en evaluar la influencia de los eventos en la arquitectura de control propuesta, se describen en la Sección 4. Finalmente, se presentan las conclusiones en la Sección 5.

## 2. Arquitectura de control

De acuerdo con la modularidad y enfoque distribuido del estándar IEC 61499, se presenta una estructura dividida en tres capas claramente diferenciadas, pero que trabajan de forma conjunta en el control de un sistema determinado. En la Figura 2 se muestra de forma esquemática cada una de las tareas asumidas por las diferentes capas.

### 2.1. Capa 1. Adquisición de datos

La capa de adquisición permite la lectura y escritura de las variables físicas del sistema que se está controlando. El objetivo de esta capa es tanto realizar la lectura cíclica de las variables de interés, como llevar a cabo las operaciones necesarias para acondicionar dichas variables. La arquitectura propuesta hace uso de un dispositivo remoto de entrada/salida para asegurar la compatibilidad con equipos antiguos.

El Bloque de Función de lectura de entradas se ejecuta continuamente en una tarea interna del PLC. Cuando se detecta un cambio significativo en el valor medido, se desencadena un evento para que el valor pueda ser transmitido al bloque que ejecuta el algoritmo del controlador PID, el cual se ejecuta en otro controlador y corresponde a una capa diferente dentro de la arquitectura de la aplicación. El Bloque de Función de escritura solamente se ejecuta cuando la capa de control envía un evento desencadenado por el controlador PID. Las variables asociadas a un evento son transmitidas junto al instante de tiempo en el cual éste se ha producido, de modo que el sistema de control puede conocer el tiempo transcurrido entre las lecturas, escrituras y transmisiones de datos.

### 2.2. Capa 2. Control PID

En esta capa se ejecuta el algoritmo de control basado en eventos. Para ello, se requiere registrar el tiempo transcurrido entre cada evento que desencadena la ejecución del algoritmo, que en este caso son las actualizaciones de los valores leídos por la capa 1. Esto difiere de las implementaciones tradicionales en las que el tiempo transcurrido entre ejecuciones del algoritmo es simplemente el ciclo de ejecución de la tarea del controlador. Sin embargo, como medida de seguridad para garantizar un tiempo máximo entre ejecuciones independientemente de los eventos generados, se ha configurado una tarea de ejecución cíclica que actuará en caso de que no se haya producido ningún evento durante un intervalo de tiempo parametrizado.

La implementación del controlador propuesto utiliza las mejoras al PID basado en eventos de Árzén (Árzén, 1999) propuestas por Durand and Marchand (2009). Por tanto, sigue un enfoque similar al propuesto por Miguel-Escrig and Romero-Pérez (2018), donde también se desarrolló un PID basado en eventos haciendo uso del estándar IEC 61499. La principal diferencia con esta implementación es que su método requería un evento cíclico externo para ejecutar el PID y verificar si había transcurrido el tiempo máximo sin calcular la acción de control, mientras que nuestra propuesta incluye un evento cíclico interno para activar la ejecución del PID cuando ha transcurrido el tiempo máximo, evitando así transmisiones de datos innecesarias. En caso de que el PID sea ejecutado por un evento externo, este contador interno se reinicia.

Una vez calculado una nueva acción de control, se desencadenará un evento hacia la capa 1 para que el valor pueda ser escrito en el sistema físico. Cada vez que el sistema de control determina que hay un cambio en el punto de consigna, se genera un evento hacia la capa 3 para que esta capa calcule nuevos parámetros optimizados para el punto de operación actual. Dado que los datos se transmiten con la marca de tiempo de su adquisición, el retraso entre la emisión del evento desde la capa 1 y su recepción en esta capa puede ser medido. Estas mediciones pueden ser interesantes si se aplican técnicas de control en red (Zhang et al., 2020).

### 2.3. Capa 3. Optimización del controlador

Esta capa es responsable de llevar a cabo las tareas de optimización y ajuste del controlador. Este ajuste se puede realizar con métodos sencillos como Ziegler-Nichols (Ziegler and Nichols, 1942) o mediante algoritmos de optimización más avanzados que no son fáciles de implementar en un PLC, pero que pueden ser implementados en un PC de bajo coste. Estas técnicas avanzadas pueden basarse en métodos de optimización heurísticos con capacidad para parametrizar controladores en línea, como *Tree Physiology Optimization* (TPO) (Halim and Ismail, 2016) o *Particle Swarm Optimization* (PSO) (Vincent and Nersisson, 2017). Como primer paso para evaluar la viabilidad de la arquitectura propuesta y analizar el efecto de los posibles retardos, en este trabajo se utiliza el enfoque de ajuste simple basado en el método de Ziegler-Nichols. Dado que el sistema propuesto puede aproximarse a un modelo de primer orden con retardo, para obtener los parámetros del controlador PID se aplica la variante de Ziegler-Nichols que calcula los parámetros en base al tiempo transcurrido entre 28,3 % y el 63,2 % del valor final ante una entrada de tipo escalón sobre el modelo (Liu et al., 2013).




Figura 3: Proceso de cuatro tanques utilizado durante la experimentación.

La tarea se ejecuta cuando hay un cambio en el punto de consigna, por lo que la capa 2 lanza un evento compartiendo las condiciones del punto de operación que son necesarias para determinar la nueva función de transferencia linealizada. Esta función de transferencia se utiliza para calcular los parámetros  $K_p$ ,  $T_i$  y  $T_d$  usando el procedimiento de ajuste mencionado anteriormente. Una vez que se calculan esos parámetros, se genera

otro evento para devolverlos a la capa 2, donde se actualiza la parametrización del PID a ejecutar.

### 3. Aplicación

#### 3.1. Sistema físico

El sistema propuesto para los experimentos es una planta piloto equipada con instrumentación industrial cuya configuración se basa en el proceso de cuatro tanques de Karl Henrik Johansson (Johansson, 2000). La planta industrial, como se muestra en la Figura 3, fue desarrollada en el Laboratorio Remoto de Control Automático de la Universidad de León (Fuentes et al., 2008).

La configuración de este sistema involucra cuatro tanques de agua organizados en pares, alineados verticalmente para que los tanques superiores alimenten directamente a los inferiores. Para regular el caudal de agua, dos bombas simétricas suministran el caudal requerido desde un tanque de agua inferior, que se distribuye entre los tanques usando dos válvulas de tres vías, de forma cruzada. Es decir, la combinación de bomba y válvula izquierdas controla los tanques inferior izquierdo y superior derecho, mientras que la combinación del lado derecho gestiona los tanques inferior derecho y superior izquierdo. Cada tanque está equipado con un sensor que permite la medición del nivel de líquido. Además, una válvula situada en la base de cada tanque permite la modificación individual del caudal desaguable para introducir intencionalmente perturbaciones que afecten el control del nivel del tanque correspondiente.

sólo un sistema SISO, creando un lazo de control con la bomba 1 y el nivel del tanque 1. Para este escenario, la Válvula 1 y la Válvula 2 siempre están configuradas en 0 y la bomba 2 está apagada. La Figura 4 muestra este lazo de control.

Teniendo esto en cuenta, el modelo del sistema SISO del tanque 1 se puede describir mediante la siguiente ecuación diferencial:

$$\frac{dh_1}{dt} = -\frac{a_1}{A_1} \sqrt{2gh_1} + \frac{k_1}{A_1} v_1 \quad (1)$$

Si esta ecuación diferencial se linealiza alrededor de un punto de operación, se puede obtener una ecuación de transferencia del lazo de control para el tanque 1:

$$G(s) = \frac{(1 - \gamma_1)c_1}{1 + sT_1} \quad (2)$$

donde

$$T_1 = \frac{A_1}{a_1} \sqrt{\frac{2h_1^0}{g}} \quad c_1 = \frac{T_1 k_1 k_c}{A_1} \quad (3)$$

Como se puede observar, el sistema es de primer orden y su ganancia y constante de tiempo dependen del nivel inicial del tanque. Por tanto, dependiendo del punto de operación, la dinámica del sistema cambia. Además, el sistema presenta un retardo en la respuesta debido al tiempo de respuesta de la bomba y la longitud del tubo, resultando en un modelo de primer orden con tiempo muerto (FOPDT):

$$G(s) = e^{-\theta s} \frac{(1 - \gamma_1)c_1}{1 + sT_1} \quad (4)$$

Tabla 1: Variables y constantes del proceso de cuatro tanques

Variable	Unidades	Descripción
$h_i$	cm	nivel tanque i
$h_i^0$	cm	estado estacionario tanque i
$x_i$	cm	desviación del nivel $x_i = h_i - h_i^0$
$q_i$	cm <sup>3</sup> /s	caudal impulsado
$v_j$	0-100	velocidad bombas
$v_j^0$	0-100	estado estacionario bombas
$u_j$	0-100	desviación bombas $u_i = v_i - v_i^0$
$q_{pump,j}$	cm <sup>3</sup> /s	caudal total de las bombas
$\gamma_j$	0-1	ratio de las válvulas
Constante	Unidades	Descripción
$A_i$	cm <sup>2</sup>	sección tanques
$a_i$	cm <sup>2</sup>	sección orificio
$g$	cm <sup>2</sup> /s	gravedad
$k_j$	cm <sup>3</sup> /s	constante bombas
$k_c$	cm	constante sensor nivel

Para mayor claridad, la Figura 4 ofrece una representación esquemática del modelo de Johansson, mientras que la Tabla 1 describe sus principales variables y constantes.

La representación matemática del sistema se puede formular combinando las ecuaciones correspondientes aplicadas a los tanques y bombas: la ley de Bernoulli,  $q_{out} = a_i \sqrt{2gh_i}$ , y los balances de masa,  $A\dot{h} = q_{in} - q_{out}$ . En este documento, dado que el propósito es probar la arquitectura propuesta, se considera




Figura 4: Esquema del proceso de cuatro tanques.

#### 3.2. Implementación de la arquitectura de control

Como resultado de su interés en la educación e investigación sobre Industria 4.0 (Fuentes et al., 2021), el grupo SUP-PRESS en la Universidad de León cuenta con dispositivos industriales basados en el estándar IEC 61499. Estos dispositivos, pertenecientes a la gama dPAC de Schneider Electric, son unos de los primeros PLCs comercialmente disponibles que siguen dicho estándar. Para la implementación de la arquitectura propuesta, se han instalado estos dispositivos en uno de los armarios de control disponibles en el Aula IoT ULE-Schneider Electric (Domínguez et al., 2022).



La capa de adquisición de datos en la arquitectura de control propuesta se implementa con un controlador lógico programable de gama baja, el Schneider Electric dPAC TM251. Para llevar a cabo la comunicación, las variables se leen a través de solicitudes Modbus TCP cíclicamente a intervalos de 100 ms, y se envían a la capa de control solo cuando se desencadena el evento correspondiente.

La capa de control, por otro lado, se implementa en un PLC Schneider Electric dPAC M580, que tiene suficiente potencia de procesamiento para ejecutar todas las rutinas de monitorización y control, incluida la ejecución del PID. Para lograr un comportamiento basado en eventos en el controlador PID, no se puede utilizar la implementación predeterminada del bloque de función PID del M580, que implementa un PID clásico orientado a ejecutarse en una tarea cíclica. Por esta razón, se ha programado un nuevo bloque de función en Texto Estructurado para implementar el algoritmo del controlador PID basado en eventos que se discutió en la sección 2.

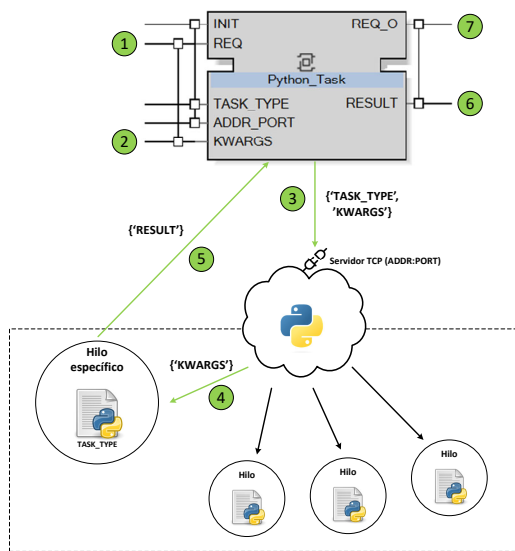


Figura 5: Integración de Bloque Función con los algoritmos programados utilizando el lenguaje Python

La capa de gestión del PID se ejecuta en un PC Industrial (Magelis IoT Box) con sistema operativo Linux. En este sistema se ejecuta un entorno virtualizado conocido como Soft dPAC, para agregar funcionalidad IEC 61499 a un computador tradicional. Esta tecnología hace posible que cualquier tipo de dispositivo se convierta en otro elemento de control dentro de la arquitectura distribuida. Los algoritmos de optimización se implementan utilizando el lenguaje de programación Python y se encapsulan en un Bloque de Función para su integración con el resto del programa, produciéndose una comunicación TCP tradicional entre el Bloque de Función y el programa Python, como se muestra en la Figura 5.

Los dispositivos utilizados están sincronizados mediante NTP, centrándose los experimentos realizados en analizar la influencia en el lazo de control de los eventos generados de forma no determinista. Cabe destacar que no se han realizado modelizaciones de retardos de red, dado que todos los equipos involucrados se comunican a través de una red local, resultado

despreciables los retardos producidos por la comunicación de paquetes de red. Otra ventaja de usar IEC 61499 para el control distribuido es que toda la arquitectura está programada en el mismo entorno, pero luego cada bloque de programa se asigna a su dispositivo correspondiente.

#### 4. Resultados experimentales

Para evaluar el efecto del comportamiento no determinista de los eventos en la arquitectura propuesta, se han llevado a cabo una serie de experimentos en el sistema descrito en la sección anterior. El control del nivel del tanque se realiza con pequeños cambios en el punto de consigna para trabajar con modelos linealizados en diferentes puntos de operación. Se han probado diversos escenarios de ejecución del sistema de control:

- Un PID activado por eventos con una banda muerta de 0.2 unidades, ajustando los parámetros después de cada cambio de punto de consigna. Si el valor controlado no cambia más de 0,2 con respecto al último valor enviado, no se enviará un nuevo evento a la capa de control. Sin embargo, si esta situación se extiende durante más de 200 ms, se realizará una nueva ejecución del PID utilizando el último valor enviado. (PID 0,2 200).
- Mismo PID, pero elevando la banda muerta hasta 1. (PID 1 200).
- Mismo PID con una banda muerta de 1, pero elevando el tiempo máximo de ejecución a 500ms (PID 1 500).
- Un PID activado por eventos con una banda muerta de 0,2 unidades, un tiempo máximo entre ejecuciones de 200ms y un retardo en la tarea de optimización del controlador de 500ms (Retardo en optimización).

El experimento realiza cinco pequeños cambios escalonados en el punto de consigna, comenzando desde un punto de operación inicial (60 %). Para comparar las respuestas resultantes del sistema, se calculan los valores de diferentes índices de rendimiento (Mousakazemi, 2021) para cada configuración del lazo de control, que se muestran en la Tabla 2.

Tabla 2: Comparación entre los índices de desempeño obtenidos

Experimento	IAE	ITAE	IAVU
PID 0,2 200	9,92	3316,91	818,19
PID 1 200	14,2	6000,66	1097,0
PID 1 500	12,81	5342,67	933,88
Retardo en optimización	10,88	3902,66	952,75

Los índices seleccionados son la integral del error absoluto (IAE), la integral del criterio de error absoluto multiplicado por el tiempo (ITAE) y la variación absoluta integral de la señal de control (IAVU).

Se puede observar que la arquitectura de control se ve muy condicionada por una selección adecuada de la banda muerta, causando valores elevados de la misma un incremento tanto del error como del esfuerzo de control. No obstante, este efecto negativo en los índices de desempeño se ve atenuado si además de una banda muerta elevada se selecciona un intervalo mayor

para la ejecución cíclica del PID. Por último, es importante destacar que un retardo en la tarea de optimización del controlador (motivado, por ejemplo, por la sustitución de una técnica de optimización sencilla por otra computacionalmente más costosa), no tiene un efecto significativo en cuanto al error del lazo de control se refiere.

En la Figura 6 se muestra el detalle de un fragmento del experimento, de modo que el rendimiento de los controladores tar




Figura 6: Nivel del tanque y acción de control para los diferentes escenarios

## 5. Conclusiones

Este trabajo presenta una arquitectura para el control PID en un sistema distribuido y su optimización, basada en el reciente estándar de control IEC 61499. La viabilidad de la arquitectura propuesta ha sido evaluada con éxito a través de su implementación en dispositivos industriales disponibles comercialmente y su aplicación al control SISO de un lazo de nivel de un tanque en una planta piloto. Se ha comprobado el efecto que ocasiona la falta de determinismo en la generación de los eventos en el lazo de control, y la influencia de los posibles retardos en la capa de optimización sobre el desempeño del regulador PID en el PLC de control. Los resultados muestran que la implementación de optimizaciones computacionalmente más costosas no implica un impacto significativo en el rendimiento del controlador.

Como línea futura de este trabajo se plantea la implementación de técnicas heurísticas en la capa de optimización, con el fin de mejorar la regulación del sistema, así como el uso de algoritmos de control más avanzados. Por ello, se deberá analizar también la implementación de métodos como el control predictivo basado en modelo. Otra línea futura interesante es la implementación de ideas propias de la teoría de control en red, que podrían ser necesarias para mejorar la respuesta ante potenciales grandes retardos en la transmisión de datos. En este trabajo, dado que todos los dispositivos involucrados se encuentran dentro de una misma red local y los retardos de red resultan despreciables, no se han tenido en cuenta estas consideraciones.

## Referencias

- Domínguez, M., Pérez, D., Morán, A., Alonso, S., Prada, M. A., Fuertes, J. J., 2022. Remote training in cybersecurity for industrial control systems. In: IFAC-PapersOnLine. No. 17. Elsevier B.V., pp. 320–325. DOI: 10.1016/J.IFACOL.2022.09.299
- Dormido, S., Sánchez, J., Kofman, E., ene. 2008. Muestreo, control y comunicación basados en eventos. Revista Iberoamericana de Automática e Informática industrial 5 (1), 5–26. DOI: 10.1016/S1697-7912(08)70120-1
- Durand, S., Marchand, N., 2009. Further results on event-based PID controller. In: 2009 European control conference (ECC). IEEE, pp. 1979–1984.
- Fuertes, J., Prada, M. A., Domínguez, M., Reguera, P., Díaz, I., Díez, A., 2008. Visualization of dynamic parameters of a multivariable system using self-organizing maps. IFAC Proceedings Volumes 41 (2), 11001–11006.
- Fuertes, J. J., Prada, M. A., Rodríguez-Ossorio, J. R., González-Herbón, R., Pérez, D., Domínguez, M., 2021. Environment for education on industry 4.0. IEEE Access, 144395–144405. DOI: 10.1109/ACCESS.2021.3120517
- García, C. A., Castellanos, E. X., Buele, J., Espinoza, J., Lanas, D., Beltran, C., García, M. V., 2018. MPC under IEC-61499 using low-cost devices for oil pipeline system. In: 2018 IEEE 16th International Conference on Industrial Informatics (INDIN). IEEE, pp. 659–664.
- Halim, A. H., Ismail, I., 2016. Online pid controller tuning using tree physiology optimization. In: 2016 6th International Conference on Intelligent and Advanced Systems (ICIAS). pp. 1–5. DOI: 10.1109/ICIAS.2016.7824036
- Johansson, K. H., 2000. The Quadruple-Tank Process: A Multivariable Laboratory Process with an Adjustable Zero. IEEE Transaction on Control Systems Technology 8 (3), 456–465.
- Liu, T., Wang, Q.-G., Huang, H.-P., 2013. A tutorial review on process identification from step or relay feedback test. Journal of Process Control 23 (10), 1597–1623. DOI: 10.1016/j.jprocont.2013.08.003
- Lu, Y., 2017. Industry 4.0: A survey on technologies, applications and open research issues. Journal of Industrial Information Integration 6, 1–10. DOI: https://doi.org/10.1016/j.jii.2017.04.005
- Lyu, G., Brennan, R. W., 2021. Towards IEC 61499-based distributed intelligent automation: A literature review. IEEE Transactions on Industrial Informatics 17 (4), 2295–2306. DOI: 10.1109/TII.2020.3016990
- Miguel-Escrig, O., Romero-Pérez, J.-A., 2018. Implementation and evaluation of event-based PID in the IEC-61499 standard. In: 2018 IEEE 23rd International Conference on Emerging Technologies and Factory Automation (ETFA). Vol. 1. pp. 574–580. DOI: 10.1109/ETFA.2018.8502574
- Mousakazemi, S. M. H., 2021. Comparison of the error-integral performance indexes in a GA-tuned PID controlling system of a PWR-type nuclear reactor point-kinetics model. Progress in Nuclear Energy 132, 103604.
- Muñoz de la Peña, D., Domínguez, M., Gomez-Estern, F., Reinoso, O., Torres, F., Dormido, S., 2022. State of the art of control education. Revista Iberoamericana de Automática e Informática industrial, 117–131. DOI: 10.4995/riai.2022.16989
- Vincent, A. K., Nersisson, R., Nov. 2017. Particle swarm optimization based pid controller tuning for level control of two tank system. IOP Conference Series: Materials Science and Engineering 263, 052001. URL: http://dx.doi.org/10.1088/1757-899x/263/5/052001 DOI: 10.1088/1757-899x/263/5/052001
- Vyatkin, V., 2011. IEC 61499 as enabler of distributed and intelligent automation: State-of-the-art review. IEEE Transactions on Industrial Informatics 7 (4), 768–781. DOI: 10.1109/TII.2011.2166785
- Zhang, X.-M., Han, Q.-L., Ge, X., Ding, D., Ding, L., Yue, D., Peng, C., 2020. Networked control systems: a survey of trends and techniques. IEEE/CAA Journal of Automatica Sinica 7 (1), 1–17. DOI: 10.1109/JAS.2019.1911651
- Ziegler, B. J. G., Nichols, N. B., 1942. Optimum settings for automatic controllers. Journal of Fluids Engineering. DOI: 10.1115/1.2899060
- Årzén, K.-E., 1999. A simple event-based PID controller. IFAC Proceedings Volumes 32 (2), 8687–8692, 14th IFAC World Congress 1999, Beijing. DOI: 10.1016/S1474-6670(17)57482-0

## Enfoque Centrado en el Humano para el Gemelo Digital de la Colaboración Humano-Máquina/Robot en una Línea Piloto de Industria 5.0

Alfaro, Diego.<sup>a,b,\*</sup>, Castaño, Fernando.<sup>a</sup>, Cruz, Yarens J.<sup>a</sup>, Villalonga, Alberto.<sup>a,b</sup>, Haber, Rodolfo E.<sup>a</sup>

<sup>a</sup>Centro de Automática y Robótica, CSIC, Ctra. Campo Real Km. 0,200, 28500, Arganda del Rey, España.

<sup>b</sup>Centro de Automática y Robótica, Universidad Politécnica de Madrid (UPM), C/ José Gutiérrez Abascal, n°2, 28006, Madrid, España.

**To cite this article:** Alfaro, D., Castaño, F., Cruz, Y. J., Villalonga, A., Haber, R. E. 2024. Human-Centric Approach for the Digital Twin of Human-Machine/Robot Collaboration in an Industry 5.0 Pilot Line. XIX Simposio CEA de Control Inteligente. 2024.

### Resumen

Dada la creciente digitalización y automatización en los procesos de fabricación, uno de los mayores retos a los que se enfrenta el sector industrial es el de establecer relaciones seguras y eficientes en la interacción entre humanos y robots. Entre las herramientas de modelado utilizadas, actualmente, encontramos a los gemelos digitales que resultan fundamentales para la optimización y predicción de resultados. Proyectos como Fortis, contextualizados en los conceptos de Industria 5.0, proponen la implementación de líneas de producción colaborativas donde se garantice una interacción segura entre humanos y robots, utilizando modelos y simulaciones de estas interacciones. Para lograr un óptimo rendimiento en una línea de producción, se requiere monitorizar a cada uno de los elementos que la componen, incluyendo a los operadores humanos. En este aspecto, se requiere del reconocimiento y evaluación de parámetros para la generación de modelos de optimización, que permitan predecir el comportamiento de la línea y ayudar en la toma de decisiones. En este trabajo se analiza un caso de estudio en una línea piloto experimental. Con esto se pretende diseñar, desarrollar y evaluar gemelos digitales que permitan modelar el comportamiento de operarios, robots y las interacciones entre estos. Por último, se enunciarán los trabajos futuros y proyecciones correspondientes a este proyecto.

*Palabras clave:* Interacción humano-robot, Gemelo Digital, Centrado en el Ser humano, Inteligencia Artificial.

### Human-Centric Approach for the Digital Twin of Human-Machine/Robot Collaboration in an Industry 5.0 Pilot Line

#### Abstract

The industrial sector faces a major challenge in establishing safe and efficient human-robot interactions due to the growing digitalization and automation in manufacturing processes. Digital twins, among the modeling tools currently used, play a fundamental role in optimizing and predicting results. Projects such as Fortis, framed within the concepts of Industry 5.0, propose the implementation of collaborative production lines where a safe interaction between humans and robots is guaranteed. This is achieved through the use of models and simulations of these interactions. In order to achieve the best performance in a production line, it is necessary to monitor all the components, including human operators. This involves recognizing and assessing parameters to create optimization models. These models can predict the line's behavior and assist in decision-making. In this project, we analyze a case study of an experimental pilot line. The main objective is to design, develop, and evaluate digital twins that can model the behavior of operators, robots, and their interactions. Lastly, we will present future work and projections corresponding to this project.

*Keywords:* Human-Robot Interaction, Digital Twin, Human-centric, Artificial Intelligence.

\*Autor para correspondencia: diego.alfaro@car.upm-csic.es  
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

## 1. Introduction

Industry 5.0 signifies the advancement of industrial manufacturing by advocating for a human-centric approach. The solutions developed for this industry aim to integrate human intelligence and skills with advanced technologies such as artificial intelligence, robots, and automated processes. With an emphasis on ethical and sustainable practices, Industry 5.0 strives to establish more flexible, responsive, and socially responsible manufacturing systems that benefit both businesses and society (Nahavandi, 2019). The concept of a collaborative industry, rather than replacing workers with fully automated processes as in Industry 4.0, aims to enhance people's perception of the rapid technological evolution.

Understanding human behavior in industrial settings is crucial for human-centric automation and collaborative environments. Human-Robot Interaction (HRI) involves designing and analyzing interactions between humans and robots to create safe, efficient, and intuitive collaborations. This multidisciplinary field focuses on integrating robots into human environments by leveraging human cognitive abilities and robotic precision and endurance. Ensuring a synergistic combination of humans and machines supports individual needs and factory requirements (Wang et al., 2024). In robotics literature, concepts such as human-robot interaction, cooperation, collaboration, and co-existence, as well as context-awareness, are explored, contributing to the establishment of guidelines for a collaborative industry (Jahanmahin et al., 2022).

When implementing an automated process involving human interaction with various technologies, there is a risk of inefficient resource allocation. In this context, the digital twin (DT) emerges as a highly effective tool for decision-making and visualization in ongoing research projects (Villalonga et al., 2021). A DT is defined as a virtual model that accurately reflects a physical object, system, or process throughout its entire lifespan. By utilizing real-time data and advanced analytics, it creates a digital counterpart that replicates the current state, behavior, interactions, and environment of its real-world counterpart (Guerra et al., 2019). The physical component provides information to the digital representation for processing, and the digital component responds with data that can modify the behavior of the physical counterpart. This communication enables analysis, monitoring, and optimization, facilitating the prediction of outcomes, enhancement of decision-making, and organization of maintenance processes.

This paper proposes the design and development of a digital twin with a human-centered approach. The goal is to evaluate holistic multi-modal and multi-aspect solutions for human-machine/robot interactions, in order to optimize a manufacturing pilot line within the context of Industry 5.0. In addition, the document provides a review of the current state of Human-Robot Interaction, Digital Twins, optimal resource allocation, and related concepts. It also describes the design of a proposal for a communication protocol and simulation environment.

This document is divided into six sections. Following this introduction, the second section will provide a review of the work related to HRI-DT. Next, the text will explain the communication protocols, simulation environment, and digital tools to be used in the research. Additionally, a case study will be

presented, showcasing the implementation of HRI-DT. Section five will propose the main future applications of this DT. Finally, the conclusion will discuss some of the results from the ongoing implementation and outline the potential directions for HRI-DTs in our research.

Tabla 1: Insights for Digital Twins

Reference	Relevance
Safavi et al. (2024)	<ul style="list-style-type: none"> <li>■ Learning Methods</li> <li>■ Brain computer interfaces</li> <li>■ Emotional Perception</li> <li>■ Metrics</li> </ul>
Tao et al. (2019)	<ul style="list-style-type: none"> <li>■ Design and planning considerations</li> </ul>
Li et al. (2021)	<ul style="list-style-type: none"> <li>■ Implementation of a multi-source model-driven digital twin system</li> <li>■ Interaction (contact) models for robots and manipulated objects</li> <li>■ Geometric 3D space with physics and workflow rules</li> <li>■ Object reconstruction using OpenGL</li> <li>■ Use of UR5 robot, grippers and cameras</li> </ul>
Su et al. (2023)	<ul style="list-style-type: none"> <li>■ Modalities in HRI</li> <li>■ Potential Techniques for interaction and data processing</li> <li>■ Possible input data</li> </ul>
Damjanovic-Behrendt and Behrendt (2019)	<ul style="list-style-type: none"> <li>■ Open source technologies and tools</li> <li>■ Architecture considerations</li> <li>■ Data acquisition and managing considerations</li> </ul>

## 2. Related Work: Human-Robot Interaction Digital Twin

The integration of human-robot interaction with digital twin technologies has become a promising way to improve the efficiency and effectiveness of collaborative environments. This combination takes advantage of digital twins' ability to simula-

te and replicate physical systems in real time, providing a virtual space for testing and optimizing human-robot interactions. By using this synergy, researchers and practitioners aim to create user-friendly interfaces, improve task allocation strategies, and enhance overall system performance.

Different approaches and techniques regarding digital twins, human-robot interaction, and optimal resource allocation have been discussed in the literature. Tables 1 and 2 illustrate several studies that will establish guidelines for the project.

In order to implement digital twins for a pilot line where humans collaborate with robots, we have gathered insights regarding Human Digital Twins. Table 2 presents a compilation of literature concerning the design, architecture, and considerations pertinent to the implementation of Human Digital Twins.

Table 2: Insights for Human Digital Twins

Reference	Relevance
Qu et al. (2024)	<ul style="list-style-type: none"> <li>Human-Machine integration</li> <li>Model planning and design considerations</li> <li>Multiple source data acquisition</li> </ul>
De Oliveira et al. (2023)	<ul style="list-style-type: none"> <li>Human Digital Twins</li> <li>Use of smartwatches</li> </ul>
He et al. (2024)	<ul style="list-style-type: none"> <li>Considerations for the design of Human Digital Twins</li> <li>Frameworks</li> </ul>
Coronado et al. (2024)	<ul style="list-style-type: none"> <li>Architecture for Human - Robot collaboration</li> <li>Use of ROS</li> </ul>

The development of optimization algorithms requires information from a wide range of sources. Digital twin research aims to improve resource allocation, prediction, and other processes by using real-time information. However, the challenge lies in the difficulty of streaming and processing this information. Data acquisition depends on various technologies that may not enable quick communication and data streaming. It is also common to have access to an excess of data from different sources that lacks concrete value. Nevertheless, ongoing research efforts are crucial in uncovering the potential value of such data. With rapid advancements in hardware and processing capabilities, the potential value of processed data is likely to be realized in the near future as hardware continues to evolve.

### 3. Communication protocol and simulation environment

It's important to note that the communication link between the IoT nodes and the machine tools is established using an industrial standard protocol, namely TCP/IP via Ethernet to Kern Evo and the conveyor belt. Additionally, the UR5 and ROSbot XL are connected using ROS 2.

Data for human-related indicators will be collected from wearable devices such as smartwatches. Prominent brands frequently mentioned in the literature include Samsung, Google,

Apple, Huawei, and Garmin. An intermediary Wear OS application is being developed to establish wireless communication between the wearables and IoT nodes. The processed data will be transmitted using MQTT. Physiological indicators from wearable devices will be used to create human digital twins and to extract wellness metrics such as heart rate, blood pressure, and stress levels.

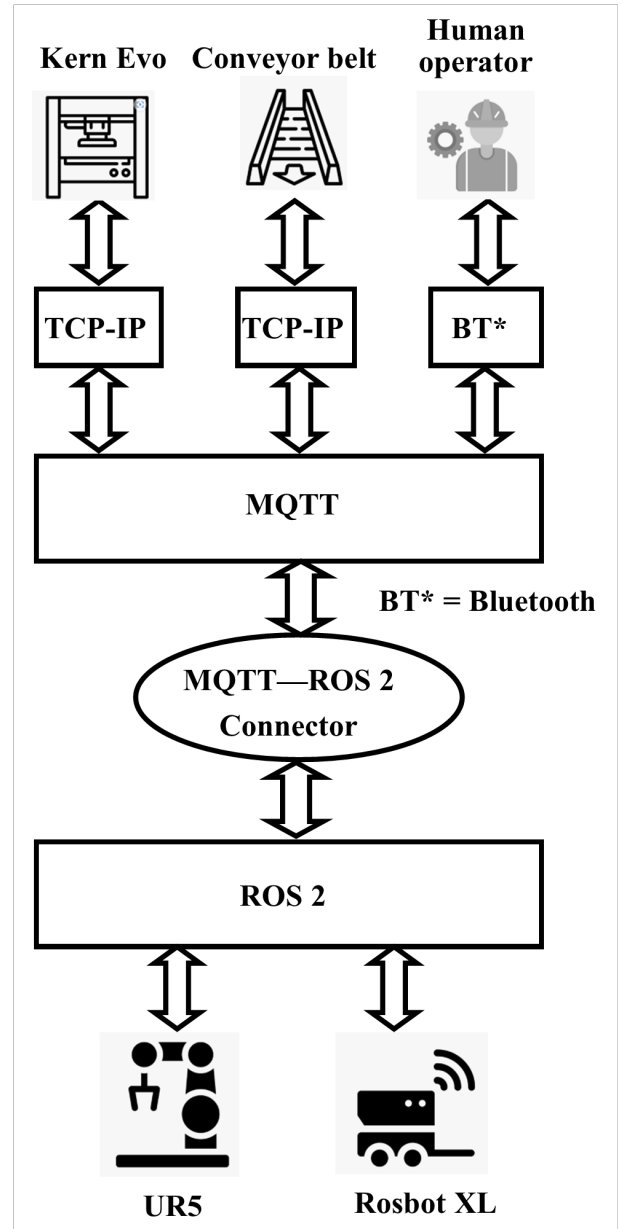


Figura 1: Standardized communication protocol in the HRI-DT

The DC motors of the conveyor belts are controlled by signals transmitted from IoT nodes. These nodes consist of two Raspberry Pi 3B+ and two 4B+ models, along with a PC MSI core i3 with 4GB RAM. These IoT nodes are interconnected at a higher layer through MQTT protocol.

Finally, a connector is created between the IoT and robotic networks to share messages, understanding both ROS 2 and MQTT.

The simulation environment chosen for implementing the HRI-DT is FlexSim which is powerful 3D simulation modeling

and analysis software that allows you to model, analyze, and improve various systems, including manufacturing, healthcare, material handling, supply chain, warehousing, logistics, aerospace, and mining<sup>1</sup>. The main key features of this software are beyond spreadsheets, stunning 3D Visualization and case studies.

In addition to utilizing FlexSim for simulation purposes, Gazebo will be employed for robot interaction and visualization within the ROS2 framework. Alongside RViz for mapping, Gazebo introduces the dimension of physics simulation, enabling the acquisition of data related to force interactions. This integration enhances the realism and accuracy of the simulated environments by incorporating physical dynamics.

#### 4. Case Study: Industry 5.0 Pilot Line Digital Twin

##### 4.1. Pilot line description

The pilot line allows for a wide variety of manufacturing operations for different parts. One practical application involves manufacturing, quality control, and subsequent engraving on the micromilling machine if the piece is correct. The manufacturing process for these covers, which are based on metallic, ceramic, mosaic, or natural stone cladding adhered to extruded polystyrene (XPS) panels, consists of several phases: gluing, pressing, and profiling.

The pilot line selected for this specific application includes a machine tool with sensors, a manipulator robot, two conveyor belts, an autonomous mobile robot serving as a pallet truck for re-manufactured parts, and a human operator. The machine tool is an ultra-precision micromachining center equipped with a Nano NT laser control. Additionally, a Universal Robots UR5e manipulator robot is situated next to the machine to handle the workpieces. Two conveyor belts are responsible for transporting the workpieces. Further along the conveyor belts, the autonomous mobile robot ROSbot XL HUSARION, equipped with a LiDAR RPLIDAR A2 and a stereoscopic camera Intel RealSense, facilitates the transfer of manufactured parts between machines.

One important stage in the pilot line is the quality control system, which consists of the Allied Vision Mako G-192 artificial vision inspection camera. This camera is a GigE camera with an e2v CMOS color sensor and has a resolution of 1.9 megapixels. It is positioned in front of the pick-and-place arm robot UR5. The robot picks up the panel from the conveyor belt and places it in front of the camera for inspection of all sides of the panel.

##### 4.2. Human-robot interaction simulations

To develop the HRI-DT and determine the best way to allocate human and robot resources, it is necessary to gather data from the various sensors in humans and robots/machines. This requires saving data from both simulations and real experiments.

Figures 3 and 4 show simulations of human-robot and robot-robot interactions in pick-and-place operations in Industry 5.0 manufacturing lines.




Figura 3: HRI-DT of interaction between the UR5 robotic arm and the human operator.




Figura 4: HRI-DT of interaction between the UR5 robotic arm and the AGV HUSARION Rosbot XL

#### 5. Future works

##### 5.1. Digital twins with models of machines, devices, robots and humans

Based on the useful information provided by sensors for humans and for cyber-physical systems, as well as the interpretation of the interaction between man and machine through the classification of the actions that both perform based on AI, modeling based on Historical data of interaction behavior based on LSTM and deep learning to detect gestures and intentions through images will allow exploration and research in human digital twins based on human cyberphysical systems. These systems must contain virtual modules of both the robot and the human, as well as the production system. Digital twins will include resources (humans and robots/manufacturing devices) and activity digital twins that represent the physical tasks required by human – robot interaction (HRI).

Distributed systems will benefit from digital twin technologies to plan tasks, configure and install virtual models of machines, robots, manufacturing devices and operators, map the shared workspace, and monitor the activities of the devices/robot and the human being. Additionally, the twins will allow end users to monitor the overall performance of humans and robots on site. Additionally, some effort will be devoted to the integration of robot/device configuration interfaces and human-centric sensing interfaces.

##### 5.2. Fast and agile resource allocation optimizations

The integrated planning and programming of processes of manufacturing entities represents one of the processes with the greatest impact to optimize production systems. In this sense,




Figura 2: Panoramic view of the HRI-DT of the pilot manufacturing line.

this task will provide the tools and services necessary to optimally plan and schedule resource activities in the field. The resource allocation and optimization toolkit must prioritize human benefits and ensure safe and efficient interactions between humans and robots. This decision-making must be flexible and agile to address all possible situations on the ground. Strategies such as machine learning to analyze historical data and make predictions about future resource needs will be explored beyond the state of the art; deep learning to recognize complex patterns in data; reinforcement learning to train devices/robots to make optimal decisions in real time; genetic algorithms for optimization problems, such as optimal resource allocation on a manufacturing line; swarm intelligence to solve optimization problems such as coordinating multiple devices/robots to work together efficiently; fuzzy logic to handle uncertainties in the manufacturing process; and neural networks to find patterns that are too complex or numerous.

## 6. Conclusions

This paper illustrates the significant potential of integrating digital twin technologies with Human-Robot Interaction within the framework of Industry 5.0. Industry 5.0 aims to combine human intelligence with advanced technologies such as AI and robotics, fostering more responsive and socially responsible manufacturing systems through a human-centric approach. The HRI-DT developed to evaluate optimal resource allocation in a manufacturing pilot line exemplifies how digital twins can enhance human-robot collaboration approaches.

The use of FlexSim and Gazebo for simulation demonstrates the software's capability to model and enhance various manufacturing systems, improving decision-making and resource allocation. Effective data integration and communication protocols such as TCP/IP, ROS2, and MQTT facilitate seamless interaction between IoT nodes, machine tools, and wearable devices. Data acquisition from human operators will provide

information to improve human welfare. For this purpose, development using Wear OS is needed. This integration allows physiological data from wearables to be incorporated into human digital twins, providing valuable insights for optimizing human-robot interaction.

The research also outlines future directions, including the development of digital twins for human cyber-physical systems and the application of AI for gesture and intention recognition. By exploring advanced optimization techniques like machine learning and swarm intelligence, this research aims to enhance resource allocation and ensure safe, efficient human-robot interactions, contributing to the advancement of flexible, sustainable manufacturing.

## Acknowledgements

This work has been funded by European Commission through the Horizon Europe project "Multi-Modal and Multi-Aspect Holistic Human-Robot Interaction (FORTIS)", grant ID 101135707.

## Referencias

- Coronado, E., Ueshiba, T., Ramirez-Alpizar, I. G., 2024. A path to industry 5.0 digital twins for human-robot collaboration by bridging nep+ and ros. Robotics 13 (2), cited by: 0; All Open Access, Gold Open Access. DOI: 10.3390/robotics13020028
- Damjanovic-Behrendt, V., Behrendt, W., 2019. An open source approach to the design and implementation of digital twins for smart manufacturing. International Journal of Computer Integrated Manufacturing 32 (4-5), 366 – 384, cited by: 106; All Open Access, Green Open Access. DOI: 10.1080/0951192X.2019.1599436
- De Oliveira, C. D., Khanshan, A., Van Gorp, P., 2023. Exploring the feasibility of data-driven emotion modeling for human digital twins. p. 568 – 573, cited by: 0; All Open Access, Bronze Open Access. DOI: 10.1145/3594806.3596535
- Guerra, R. H., Quiza, R., Villalonga, A., Arenas, J., Castaño, F., 2019. Digital twin-based optimization for ultraprecision motion systems with backlash and friction. IEEE Access 7, 93462–93472. DOI: 10.1109/ACCESS.2019.2928141

- He, Q., Li, L., Li, D., Peng, T., Zhang, X., Cai, Y., Zhang, X., Tang, R., 2024. From digital human modeling to human digital twin: Framework and perspectives in human factors. *Chinese Journal of Mechanical Engineering (English Edition)* 37 (1), cited by: 2; All Open Access, Gold Open Access. DOI: 10.1186/s10033-024-00998-7
- Jahanmahin, R., Masoud, S., Rickli, J., Djuric, A., 2022. Human-robot interactions in manufacturing: A survey of human behavior modeling. *Robotics and Computer-Integrated Manufacturing* 78, cited by: 31. DOI: 10.1016/j.rcim.2022.102404
- Li, X., He, B., Zhou, Y., Li, G., 2021. Multisource model-driven digital twin system of robotic assembly. *IEEE Systems Journal* 15 (1), 114–123. DOI: 10.1109/JSYST.2019.2958874
- Nahavandi, S., 2019. Industry 5.0-a human-centric solution. *Sustainability (Switzerland)* 11 (16), cited by: 645; All Open Access, Gold Open Access. DOI: 10.3390/su11164371
- Qu, Y., Zhao, N., Zhang, H., 2024. Digital twin technology of human-machine integration in cross-belt sorting system. *Chinese Journal of Mechanical Engineering (English Edition)* 37 (1), cited by: 0; All Open Access, Gold Open Access. DOI: 10.1186/s10033-024-01012-w
- Safavi, F., Olikkal, P., Pei, D., Kamal, S., Meyerson, H., Penumalee, V., Vinjamuri, R., 2024. Emerging frontiers in human-robot interaction. *Journal of Intelligent and Robotic Systems: Theory and Applications* 110 (2), cited by: 1; All Open Access, Hybrid Gold Open Access. DOI: 10.1007/s10846-024-02074-7
- Su, H., Qi, W., Chen, J., Yang, C., Sandoval, J., Laribi, M. A., 2023. Recent advancements in multimodal human-robot interaction. *Frontiers in Neuro-robotics* 17. DOI: 10.3389/fnbot.2023.1084000
- Tao, F., Zhang, H., Liu, A., Nee, A. Y. C., 2019. Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics* 15 (4), 2405–2415. DOI: 10.1109/TII.2018.2873186
- Villalonga, A., Negri, E., Biscardo, G., Castano, F., Haber, R. E., Fumagalli, L., Macchi, M., 2021. A decision-making framework for dynamic scheduling of cyber-physical production systems based on digital twins. *Annual Reviews in Control* 51, 357–373. DOI: <https://doi.org/10.1016/j.arcontrol.2021.04.008>
- Wang, T., Zheng, P., Li, S., Wang, L., 2024. Multimodal human-robot interaction for human-centric smart manufacturing: A survey. *Advanced Intelligent Systems* 6 (3), cited by: 4; All Open Access, Gold Open Access. DOI: 10.1002/aisy.202300359



## La docencia en ingeniería de control frente a la inteligencia artificial generativa

Barragán, A. Javier<sup>a,\*</sup>, Segura, Francisca<sup>a</sup>, Martínez, Miguel A.<sup>a</sup>, Andújar, José M.<sup>a</sup>

<sup>a</sup>Centro de Investigación en Tecnología, Energía y Sostenibilidad (CITES), Universidad de Huelva, ctra. Huelva-Palos s/n, 21819, Palos de la Frontera. (Huelva)

**To cite this article:** Barragán, A.J. et al. 2024. Control engineering in the face of artificial intelligence. XIX Simposio CEA de Control Inteligente. (2024)

### Resumen

El auge reciente de las inteligencias artificiales (IAs), y más específicamente de las IAs generativas, está suponiendo la necesidad de un cambio de paradigma en las enseñanzas universitarias. La capacidad de las IAs de crear contenido, elaborar memorias, resúmenes y resolver problemas incluso complejos, debe provocar un cambio en muchos de los sistemas de evaluación que se venían utilizando; o al menos, una toma en consideración de la posibilidad que tiene nuestro alumnado de utilizar estas nuevas herramientas para la realización de sus tareas. En el presente artículo se pretende comprobar la capacidad de las principales IAs disponibles actualmente para la realización de tareas relacionadas con la ingeniería de control, tanto teóricas como prácticas. Los resultados demuestran que las IAs actuales aún no son capaces de resolver problemas de control, y se centran en utilizar recetas típicas no siempre convenientes; sin embargo, sí presentan buenos resultados en lo que respecta a conocimientos teóricos generales.

*Palabras clave:* Análisis, IA, Ingeniería de control, Inteligencia artificial, PID, teoría.

### Teaching in control engineering vs generative artificial intelligence

#### Abstract

The recent rise of generative artificial intelligences (AIs), and more specifically generative AIs, is bringing about the need for a paradigm shift in university education. The capacity of AIs to create content, elaborate memories, summaries and solve even complex problems, should provoke a change in many of the evaluation systems that have been used; or at least, a consideration of the possibility that our students have to use these new tools to carry out their tasks. In this paper, the aim is to test the capability of the main AIs currently available for the performance of tasks related to control engineering, both theoretical and practical. The results show that current AIs are not yet capable of solving control problems, and focus on using typical recipes that are not always convenient; however, they do perform well in terms of general theoretical knowledge.

*Keywords:* Analysis, AI, Artificial intelligence, Control engineering, PID, theory.

### 1. Introducción

Las inteligencias artificiales (IAs) pueden eliminar las limitaciones humanas respecto a la capacidad de adquirir información, retención de conocimientos y los sesgos cognitivos mediante un análisis exhaustivo de los datos y la extracción de patrones (Wang, 2022). La acelerada evolución de las IAs generativas (con capacidad para generar información) está redefiniendo cómo vivimos y trabajamos en una gran variedad de sectores (Wang et al., 2023). Por supuesto, el contexto educativo no es ajeno a estos cambios y se ha visto necesariamente afectado por su utilización (Jiayu, 2023). Las IAs generativa

está transformando el panorama educativo en las universidades, ofreciendo tanto oportunidades como desafíos para la docencia (Yeralan y Lee, 2023) y la investigación (Zhang y Shi, 2021). La adopción de estas tecnologías promete revolucionar la manera en que el estudiantado aprende y cómo las instituciones educativas enseñan y evolucionan (Popenici y Kerr, 2017). En particular, las herramientas de IAs generativas, como las Redes Generativas Antagónicas (GANs) y modelos como GPT, están siendo integradas en el aula para mejorar el proceso de enseñanza-aprendizaje (Ruiz-Rojas et al., 2023; Bethencourt-Aguilar et al., 2023; Walczak y Cellary, 2023). Sin embargo,

\*Autor para correspondencia: antonio.barragan@diesia.uhu.es  
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

hay que ser conscientes de que el uso de las IAs va a plantear retos en los enfoques docentes tradicionales, y exigirá cambios en los planes de estudio, la alfabetización digital y la ética universitaria para poder garantizar una educación adecuada y eficaz en el nuevo contexto (Walczak y Cellary, 2023).

Desde el punto de vista docente, la IA generativa ofrece ventajas significativas para el auto-aprendizaje y la autoevaluación (Rybiński y Kopciuszewska, 2020; Yin, 2021). Estas herramientas pueden proporcionar experiencias educativas personalizadas y enriquecedoras (Jiayu, 2023), adaptando los materiales educativos a las necesidades individuales y preparando al estudiantado para las demandas del también cambiante mercado laboral (Ruiz-Rojas et al., 2023). Las IAs también pueden ayudar a los y las docentes a detectar el comportamiento de su alumnado (Lopez-Carreño et al., 2022), analizar los datos de su aprendizaje para ofrecer resultados de evaluación y comentarios en tiempo real (Jiayu, 2023), o realizar evaluaciones técnicas y creativas de proyectos complejos (Divasón et al., 2023). Además, la IA puede apoyar la creación de modos de enseñanza práctica, integrando el contenido de enseñanza en escenarios específicos y gestionando el proceso de enseñanza de manera inteligente (Yang et al., 2020). En titulaciones STEM (*Science, Technology, Engineering and Mathematics*) estas oportunidades se ven aumentadas por su estrecha relación con la tecnología (Wang et al., 2023). Por ejemplo, Las IAs actuales ya han sido capaces de difuminar la barrera existente entre el profesorado y los asistentes artificiales, lo que les permite mejorar las tutorías del estudiantado de enseñanzas superiores y facilitar su acceso a explicaciones inmediatas y solución de dudas o problemas (Hemachandran et al., 2022).

Sin embargo, la IA generativa también plantea riesgos significativos para la evaluación adecuada de los trabajos del estudiantado, y existe actualmente una gran preocupación por la posibilidad de deshonestidad académica (Yeralan y Lee, 2023). La capacidad de estas tecnologías para generar diálogos interactivos y textos significativos puede llevar a su uso indebido, dificultando la distinción entre el trabajo original y el contenido generado por IA (Yeralan y Lee, 2023). Por ejemplo, algunos estudiantes pueden hacer un uso inapropiado de las IAs utilizándolas como sustituto del pensamiento propio y el esfuerzo de investigación, lo que resulta en un deterioro de la integridad académica (Lund y Ting, 2023). Los verificadores de plagio han mejorado su capacidad para detectar contenidos generados mediante IA; no obstante, es muy probable que resultados producidos por IA sean catalogados como originales (Khalil y Er, 2023). Como suele suceder, la tecnología para generar y detectar avanza simultáneamente, cada una impulsando el desarrollo de la otra, por lo que una vez más, la educación en el uso se hace más importante que la insistencia en su persecución. Desde la perspectiva de los valores y la ética, el estudiantado necesita orientación sobre cómo utilizar la IA de forma eficaz, responsable y eficiente para su propio aprendizaje, y debe aprender a adoptar un pensamiento crítico a la hora de aceptar contenidos generados, explorar combinaciones de herramientas complementarias y promover comportamientos fomentados o desaconsejados al utilizar la IA para su aprendizaje (Jiayu, 2023). Educar a los y las estudiantes en los principios y mecanismos de funcionamiento de la inteligencia artificial les debe ayudar a comprender las limitaciones y los riesgos potenciales de las

aplicaciones de IA generativa. Además, existen preocupaciones sobre la privacidad de los datos, la opacidad y la explicabilidad de los algoritmos, que llevan a la necesidad de desarrollar conocimientos digitales y de uso ético de la IA entre los y las estudiantes (Yu y Guo, 2023; Stone, 2023).

Con sus ventajas e inconvenientes, las IAs son una nueva realidad que está dando lugar a un cambio en cuanto a lo que se considera parte del conjunto de herramientas esenciales del individuo moderno, hasta el punto de que algunos autores consideran el acceso a la IA un derecho del individuo en el mundo actual: “al igual que las habilidades tradicionales de alfabetización se han asociado con los derechos individuales, la comprensión de la IA es esencial en la era de la IA” (Yi, 2021). Incluso la propia UNESCO está creando un marco de competencias sobre la IA para profesorado y estudiantado, cuyo borrador fue presentado en el *Digital Learning Week* en septiembre de 2023 (UNESCO, 2023). Por lo tanto, como profesionales de la enseñanza debemos conocer las ventajas que las IAs pueden ofrecernos, así como sus debilidades y carencias. Este artículo intenta realizar un primer análisis de las capacidades de las principales IAs actuales en lo referente a las materias del ámbito de la Ingeniería de Control, tanto a nivel teórico como práctico. Para ello, este trabajo se organiza en los siguientes apartados: después de esta introducción, en la sección 2 se explicará el caso de estudio, donde se describirán las IAs escogidas para su análisis y las preguntas a realizar. A continuación, en la sección 3, se presentarán los resultados obtenidos y una discusión de los mismos. Finalmente, se presentarán algunas conclusiones y posibles trabajos futuros.

## 2. Caso de estudio

En primer lugar se deben elegir una serie de IAs para su puesta a prueba. Dada la explosión actual de aplicaciones y herramientas basadas en IAs, se hace imposible ponerlas a pruebas todas ellas, por lo que se han escogido aquellas más conocidas y fácilmente accesibles: ChatGPT 3.5 (OpenAI, 2022), Copilot (modo más preciso) (Microsoft Corporation, 2024), Meta Llama 3 (modelo 70b-8192) (Meta Platforms, Inc., 2022) y Gemini 1.0 Pro (Google AI, 2024).

Para poner a prueba las capacidades de estas IAs se generará una rúbrica con preguntas tanto teóricas como prácticas, intentando cubrir aspectos sencillos y algo más complejos. En cualquier caso se harán preguntas adecuadas a un nivel de graduado en ingeniería, ya que es el nivel donde se concentra el mayor número de alumnos y alumnas de esta disciplina.

Las respuestas aportadas por las IAs se calificarán según una escala Likert de 5 valores (Likert, 1932): (1) Muy baja calidad, (2) Baja calidad, (3) Calidad media, (4) Buena calidad, (5) Alta calidad. Además, también se valorará de forma global la extensión de las respuestas y su formato (estética, utilización de ecuaciones, ejemplos, etc.).

### 2.1. Preguntas del bloque teórico

1. **PT1a.** Explique las diferencias fundamentales entre un sistema estático y uno dinámico.
2. **PT1b.** Dentro del ámbito de la Ingeniería de Control, explique las diferencias fundamentales entre un sistema estático y uno dinámico.

3. **PT2.** Demuestre la relación entre los polos de una función de transferencia y los autovalores de la matriz dinámica de un modelo de estado del mismo sistema.
4. **PT3.** Explique cuáles son las componentes de un controlador PID, indicando para qué sirve cada una de ellas, sus ventajas y sus inconvenientes.
5. **PT4.** Bajo qué circunstancias se recomienda añadir cada una de las componentes del controlador PID.

Se han escogido 4 preguntas que cubren los aspectos fundamentales de automática básica. La primera pregunta se ha redactado de dos formas distintas (PT1a y PT1b) lo que permitirá evaluar la importancia de la redacción de las preguntas en el resultado obtenido.

### 2.2. Preguntas del bloque práctico

1. **PP1.** Dado el sistema  $G(s) = 1/(s + 1)^2$ , diseñe un controlador PID para dicho sistema.
2. **PP2.** Dado el sistema  $G(s) = 1/(s + 1)^2$ , diseñe un controlador P, PI, PD o PID, según sea necesario, para obtener un sistema en lazo cerrado con error de posición del 10 %.
3. **PP3.** Dado el sistema  $G(s) = 1/(s(s + 1)^2)$ , diseñe un controlador P, PI, PD o PID, según sea necesario, para obtener un sistema en lazo cerrado con error de posición nulo y un sobreimpulso menor del 20 %.
4. **PP4.** Genere un código de MATLAB completo para simular la planta en lazo abierto y en lazo cerrado con el controlador que has diseñado.

Para las preguntas prácticas se han escogido una par de sistemas de los propuestos por Åström y Häggglund (2000), de forma que se pueda evaluar la capacidad de las IAs para escoger el controlador adecuado y realizar el diseño con distintos requisitos.

Nota aclaratoria. En algunas situaciones las IAs se quedan bloqueadas o paran de responder. Esto suele suceder porque han sobrepasado el tiempo de respuesta que tienen prefijado. En esos casos simplemente se les pidió continuar y de esta forma se les permitió terminar la explicación interrumpida.

## 3. Resultados y discusión

En primer lugar se debe realizar una aclaración: las respuestas de las IAs generativas no son siempre las mismas, incluso cuando el comando (*prompt*) es exactamente idéntico. Su forma de trabajar internamente, así como las continuas actualizaciones de su base de conocimiento, provocan cambios en las respuestas que hacen imposible realizar un análisis exhaustivo de su “conocimiento” real. En este trabajo se ha tomado una única respuesta por cada una de las IAs estudiadas. Tenga en cuenta este hecho si pretende replicar los resultados, ya que pueden diferir de los aquí mostrados. Además, evidentemente la evaluación es subjetiva, por lo que podría no coincidir con la presentada a continuación.

Los resultados obtenidos en la rúbrica de las preguntas teóricas se muestran en la Tabla 1.

### 3.1. Bloque teórico

Tabla 1: Resultados teóricos.

	ChatGPT 3.5	Copilot	Llama 3	Gemini
PT1a	5	5	5	4
PT1b	5	4	3	4
PT2	4	3	4	3
PT3	5	4	4	2
PT4	5	5	4	5
Media	4,8	4,2	4	3,6

En general, y salvo algunos errores y omisiones no muy importantes, la mayoría de las IAs dan unas respuestas adecuadas a las preguntas planteadas, sin entrar en gran detalle ni profundizar en la materia. Evidentemente, si se planteasen las preguntas de otra forma o se solicitasen más detalles de algún aspecto concreto, se entiende que las respuestas serían más adecuadas en este sentido. El mayor de los errores podría considerarse que lo ha cometido Gemini en la respuesta a la pregunta PT3, al indicar que la acción integral reduce la oscilación del sistema.

Todas las IAs suelen comenzar las respuestas con una introducción o contextualización (lo que puede ser muy de agradecer en el caso de ser utilizada por un/a estudiante), para continuar con la respuesta y, al finalizar, suelen realizar un breve resumen.

Analizando las respuestas a las preguntas PT1a y PT1b se observa que es muy importante realizar las preguntas con el suficiente detalle, ya que de lo contrario las respuestas pueden ser muy genéricas. Respecto de la pregunta PT2, solo Llama3 hizo la demostración matemática, aunque innecesariamente compleja y con algunos errores. ChatGPT hizo una demostración conceptual, correcta pero no formal, mientras que Llama3 y Gemini se limitaron a explicar el concepto y su importancia sin realizar la demostración solicitada. Finalmente, las respuestas a la pregunta PT3 fueron correctas, salvo el error ya comentado de Gemini, aunque poco completas. ChatGPT sí que dio una respuesta más completa que el resto en esta pregunta. Las respuestas a PT4 fueron de forma general correctas, más completas y detalladas en algunas IAs que en otras, pero todas aceptables.

### 3.2. Bloque práctico

Los resultados obtenidos en la rúbrica de las preguntas prácticas se muestran en la Tabla 2.

Tabla 2: Resultados prácticos

	ChatGPT 3.5	Copilot	Llama 3	Gemini
PP1	3	3	4	5
PP2	2	1	3	2
PP3	1	1	1	2
PP4	1	5	5	1
Media	1,75	2,5	3,25	2,5

Al observar los resultados obtenidos frente a los problemas prácticos, se puede observar que estos son bastante peores que los obtenidos en las preguntas teóricas. Salvo alguna excepción en los problemas más simples, las IAs son incapaces de realizar un diseño de un controlador correctamente. Se puede observar que tienden a emplear el método de Ziegler-Nichols de forma

mecánica; al igual que añaden un integrador cuando se solicita error de seguimiento nulo, independientemente de si la planta ya lo posee o no. Por lo tanto, aunque a veces han podido acertar, seguramente de casualidad por la sencillez del problema planteado, en ningún caso debería considerar el uso de las IAs para diseñar controladores dadas sus frecuentes errores de planteamiento y diseño.

Respecto a la generación de código sí que se observa unas respuestas más adecuadas en Copilot y Llama3, no así en Gemini, que entregó un código completamente erróneo. ChatGPT generó un código que podría ser útil y ayudar a personas con problemas para programar, pero contenía errores a la hora de definir la planta del sistema. Hay que tener en cuenta que no se solicitó un código específico para realizar un simulación con datos dados, si no que se solicitó un código para realizar la simulación de un diseño previamente realizado por la propia IA. Por lo tanto, esta concatenación de solicitudes, la segunda depende de la primera, puede dificultar que las IAs generen el código adecuado.

### 3.3. Formato

Finalmente, los resultados sobre el formato y la claridad en la presentación de los resultados se muestran en la tabla 3

Tabla 3: Resultados formato.

	ChatGPT 3.5	Copilot	Llama 3	Gemini
Formato	5	4	4	5

ChatGPT formatea el texto en sus respuestas, con listas, negritas y tabulaciones que ayudan a dar un aspecto agradable y claro. Además, es capaz de escribir ecuaciones en forma gráfica, lo que ayuda enormemente en nuestro campo de estudio. Como único inconveniente, a no ser que se le solicite de forma expresa, no clarifica sus respuestas con ejemplos.

Copilot también utiliza texto formateado de forma adecuada, pero tiene la limitación de no representar ecuaciones. Aunque a veces incluye algún ejemplo, son poco clarificadores y muy simples.

Llama3, al igual que Copilot, también utiliza texto formateado de forma adecuada y tiene la limitación de no utilizar ecuaciones gráficas. Curiosamente, a pesar de ser la única que realizó la demostración matemática de la pregunta PT2, utiliza texto plano y símbolos ASCII para representar las ecuaciones, lo que da poca legibilidad a los resultados.

Finalmente, las respuestas de Gemini tienen un formato muy cuidado, tanto en el texto como con el uso de listas y tablas para comparar características, aunque no es capaz de representar ecuaciones de forma gráfica. Utiliza ejemplos claros y útiles, y realiza resúmenes interesantes. Además, una característica única respecto al resto de IAs analizadas en este documento, es que presenta referencias (normalmente páginas web) donde consultar más información o aclarar las respuestas; lo que puede ser muy útil en un contexto académico. Como problemas respecto del formato y la claridad de los resultados, debe destacarse que a veces presenta URL erróneas que la propia IA elimina, pero incomprensiblemente manteniendo el mensaje [*se quitó una URL no válida*], que no aporta nada.

## 4. Conclusiones y trabajos futuros

Mediante un estudio sencillo, en este trabajo se ha comprobado que las IAs actuales ya son capaces de ser una ayuda interesante al estudiantado en el ámbito de la ingeniería de control, al menos en el apartado teórico, tanto para resolver sus dudas como para ayudarlos en sus tareas docentes y en la codificación de las simulaciones. Sin embargo, es muy importante que al utilizar estas IAs se tenga un espíritu crítico, se comprueben los resultados y se analicen bajo un mínimo conocimiento de la materia, ya que comenten imprecisiones, son poco concretas en sus respuestas y, a veces, caen en errores que pueden ser de importancia.

Las IAs son una herramienta relativamente reciente, pero con un potencial muy importante. Su auge no es casual, y es que se están convirtiendo en unas herramientas de ayuda en todos los ámbitos. Es de esperar que los resultados de las IAs vayan mejorando notablemente en los próximos años, ya que su popularidad no deja de crecer y son un nicho de negocio e inversión en la actualidad. En cualquier caso, si su popularidad y utilidad siguen en aumento, no tardarán en nacer IAs específicas para materias más complejas, como matemáticas avanzadas o la propia ingeniería de control, lo que podría provocar una pequeña revolución en su nuestro ámbito y en la forma de plantear nuestras asignaturas.

## Agradecimientos

Este trabajo fue financiado por el proyecto *H2Integración&Control. Integración y Control de una planta piloto basada en hidrógeno para suministro energético en aplicaciones residenciales* (PID2020-116616RB-C3), Ministerio de Ciencia, Innovación y Universidades, Agencia Estatal de Investigación.

## Referencias

- Bethencourt-Aguilar, A., Castellanos-Nieves, D., Sosa-Alonso, J. J., Area-Moreira, M., 2023. Use of generative adversarial networks (GANs) in educational technology research. *Journal of New Approaches in Educational Research*. DOI: 10.7821/naer.2023.1.1231
- Divasón, J., de Pison, F. J. M., Romero, A., de Cabezón, E. S., 2023. Artificial intelligence models for assessing the evaluation process of complex student projects. *IEEE Transactions on Learning Technologies* 16, 694–707. DOI: 10.1109/TLT.2023.3246589
- Google AI, 2024. Gemini. URL: <https://llama.meta.com>
- Hemachandran, K., Verma, P., Pareek, P., Arora, N., Kumar, K. V. R., Ahanter, T., Pise, A., Ratna, R., 2022. Artificial intelligence: A universal virtual tool to augment tutoring in higher education. *Computational Intelligence and Neuroscience* 2022. DOI: 10.1155/2022/1410448
- Jiayu, Y., 2023. Challenges and opportunities of generative artificial intelligence in higher education student educational management. *Advances in Educational Technology and Psychology* 7 (9). DOI: 10.23977/aetp.2023.070914
- Khalil, M., Er, E., 2023. Will chatgpt get you caught? Rethinking of plagiarism detection. En: Zaphiris, P., Ioannou, A. (Eds.), *Learning and Collaboration Technologies*. Springer Nature Switzerland, Cham, pp. 475–487.
- Likert, R., 1932. A technique for the measurement of attitudes. *Archives of Psychology*, 1–55.
- Lopez-Carreño, J., Calvo-Lavado, C., Azpilcueta-Vasquez, M., Zárate-Pérez, E., 2022. Artificial-intelligence-based school assistant for detecting the behavior of university students. *2022 IEEE 2nd International Conference on*

- Advanced Learning Technologies on Education & Research (ICALTER), 1–4.  
DOI: 10.1109/ICALTER57193.2022.9964801
- Lund, B., Ting, W., 2023. Chatting about ChatGPT: How may AI and GPT impact academia and libraries? SSRN Electronic Journal.  
DOI: 10.2139/ssrn.4333415
- Meta Platforms, Inc., 2022. Llama 3.  
URL: <https://llama.meta.com>
- Microsoft Corporation, 2024. Copilot Pro.  
URL: <https://copilot.microsoft.com>
- OpenAI, 2022. ChatGPT 3.5.  
URL: <https://chat.openai.com>
- Popenici, S. A. D., Kerr, S., 2017. Exploring the impact of artificial intelligence on teaching and learning in higher education. *Research and Practice in Technology Enhanced Learning* 12.  
DOI: 10.1186/s41039-017-0062-8
- Ruiz-Rojas, L. I., Acosta-Vargas, P., De-Moreta-Llovet, J., González-Rodríguez, M., 2023. Empowering education with generative artificial intelligence tools: Approach with an instructional design matrix. *Sustainability*.  
DOI: 10.3390/su151511524
- Rybiński, K., Kopciuszewska, E., 2020. Will artificial intelligence revolutionise the student evaluation of teaching? A big data study of 1.6 million student reviews. *Assessment & Evaluation in Higher Education* 46, 1127–1139.  
DOI: 10.1080/02602938.2020.1844866
- Stone, C., 2023. Artificial intelligence in social work practice education. the potential use of generative ai for learning. *The Journal of Practice Teaching and Learning*.  
DOI: 10.1921/jpts.v20i3.2192
- UNESCO, 2023. Guidance for generative AI in education and research.  
URL: <https://www.unesco.org/en/articles/guidance-generative-ai-education-and-research>
- Walczak, K., Cellary, W., 2023. Challenges for higher education in the era of widespread access to generative AI. *Economics and Business Review* 9, 71–100.  
DOI: 10.18559/ebr.2023.2.743
- Wang, J., Tan, Z., Zhou, F., Hu, Z., Fu, B., Wang, Y., 2023. Evaluation of the influence of artificial intelligence on college students' learning based on group decision-making method. *Journal of Artificial Intelligence Practice*.  
DOI: 10.23977/jaip.2023.060805
- Wang, S., 2022. The day the AGI was born.  
URL: <https://www.latent.space/p/everything-we-know-about-chatgpt>
- Yang, C., Huan, S., Yang, Y., 2020. A practical teaching mode for colleges supported by artificial intelligence. *Int. J. Emerg. Technol. Learn.* 15, 195–206.  
DOI: 10.3991/ijet.v15i17.16737
- Yeralan, S., Lee, L. A., 2023. Generative AI: Challenges to higher education. *Sustainable Engineering and Innovation*.  
DOI: 10.37868/sei.v5i2.id196
- Yi, Y., 2021. Uspostavljanje koncepta UI pismenosti: Focusing on competence and purpose. *JAHHR* 12 (2), 353–368.  
DOI: 10.21860/j.12.2.8
- Yin, Y., 2021. Research on ideological and political evaluation model of university students based on data mining artificial intelligence technology. *J. Intell. Fuzzy Syst.* 40, 3689–3698.  
DOI: 10.3233/jifs-189403
- Yu, H., Guo, Y., Jun. 2023. Generative artificial intelligence empowers educational reform: current status, issues, and prospects. *Frontiers in Education* 8.  
DOI: 10.3389/educ.2023.1183162
- Zhang, E., Shi, W., 2021. The construction of university teachers' scientific research performance evaluation system under artificial intelligence. 2021 World Automation Congress (WAC), 287–290.  
DOI: 10.23919/WAC50355.2021.9559607
- Åström, K., Hägglund, T., Abr. 2000. Benchmark systems for pid control. *IFAC Proceedings Volumes* 33 (4), 165–166.  
DOI: 10.1016/s1474-6670(17)38238-1



## Modelado de un Acumulador de Energía Dinámico Mediante Volante de Inercia en Simulink

Torres, Juan Carlos <sup>a</sup>, Douairi, Hamza <sup>a</sup>, González, Jaime <sup>b</sup>, Carta, José Antonio <sup>a</sup>, Cabrera, Pedro <sup>a</sup>

<sup>a</sup> Departamento de Ingeniería Mecánica, Universidad de Las Palmas de Gran Canaria, Las Palmas, España.

<sup>b</sup> Departamento de Ingeniería Electrónica y Automática, Universidad de Las Palmas de Gran Canaria, Las Palmas, España

**To cite this article:** Torres, Juan C., Douairi, Hamza, González, Jaime, Carta, José A., Cabrera, Pedro. 2024. Modelado de un Acumulador de Energía Dinámico Mediante Volante de Inercia en Simulink. XIX Simposio CEA de Control Inteligente (2024)

### Resumen

El artículo presenta un modelo de acumulador de energía dinámico mediante un volante de inercia usando Simulink, diseñado para optimizar el uso de energía renovable en plantas desaladoras. El sistema se adapta a condiciones variables de presión y caudal. Incluye la simulación de una fuente de alimentación trifásica, la medición de potencia activa y reactiva, la medición de tensión de línea y la raíz cuadrada de la media de los cuadrados de la tensión (RMS, por sus siglas en inglés), y una máquina de inducción tipo jaula de ardilla. Se detalla la inercia del sistema y los parámetros de operación, enfatizando la validación del modelo y la importancia de la parametrización debido a la no linealidad y la necesidad de ajustes específicos para diferentes aplicaciones.

*Palabras clave:* Modelado e integración de sistemas de energía renovable, Operación y planificación del almacenamiento de energía, Modelado y simulación de sistemas de energía, Control inteligente de sistemas de energía, Sistema de tiempo continuo

### Modeling of a Dynamic Energy Accumulator Using a Flywheel in Simulink

#### Abstract

The article presents a dynamic energy storage model using a flywheel with Simulink, designed to optimize the use of renewable energy in desalination plants. The system adapts to variable pressure and flow conditions. It includes the simulation of a three-phase power supply, the measurement of active and reactive power, the measurement of line voltage and the root mean square (RMS) of the voltage, and a squirrel-cage induction machine. The system's inertia and operating parameters are detailed, emphasizing model validation and the importance of parameterization due to the non-linear nature of these systems and the need for specific adjustments for different applications.

*Keywords:* Renewable Energy System Modeling and Integration, Energy Storage Operation and Planning, Modeling and simulation of power systems, Intelligent control of power systems, Continuous time system.

## 1. Introducción

Este proyecto busca optimizar el uso de energía renovable en plantas desaladoras operando bajo condiciones variables de presión y caudal. Para ello, se propone un sistema de control innovador basado en almacenamiento dinámico de energía, utilizando volantes de inercia con gestión inteligente para ajustar las variaciones instantáneas de energía renovable.

La función del volante de inercia como regulador, se basa en que este vaya compensando las desviaciones instantáneas entre la generación y la demanda de energía en plantas desaladoras alimentadas por energía eólica. Estos volantes permiten que las plantas operen de manera aislada de la red

eléctrica convencional, adaptando su consumo a la oferta de generación variable (Matos et al., 2024).

El proyecto incluye el estudio de un prototipo de sistema mecatrónico modular, utilizando técnicas de Machine Learning para gestionar la velocidad angular del volante de inercia. Este enfoque innovador permite que el sistema aprenda a operar de manera óptima, diferenciándose de los sistemas de control tradicionales.

Del objetivo general de este proyecto, se derivan objetivos específicos, el modelado y parametrizado de cada uno de los elementos que lo componen. Por ende, se ha realizado un modelo en Simulink para representar el comportamiento del

volante con respecto a la potencia que este consuma o genere frente a las consignas de velocidad que se le den a la entrada.

## 2. Descripción de los elementos del modelo

A continuación, se describen los elementos principales del modelo de Simulink 2024, explicando su función y su contribución al sistema propuesto, representados en la Figura 1.

### 2.1 Fuente de alimentación y configuración del solucionador

En la Figura 2 se puede contemplar el “Configurador del Solucionador” define los parámetros de solución del modelo de Simulink, asegurando que el sistema de ecuaciones diferenciales que describe el modelo se resuelva correctamente durante la simulación. Por otra parte, la “Fuente de Voltaje Programable Trifásica” representa una fuente de voltaje programable trifásica, que simula el control realizado al motor a través del variador de frecuencia, utilizando la energía eólica para alimentar de forma controlada el motor. Esta fuente suministra la energía necesaria al sistema, proporcionando una entrada que alimenta al motor de inducción y otros componentes del modelo. En esta fuente se configurarán los parámetros en régimen constante y posteriormente un salto proporcional de tensión y frecuencia, simulando la operación del variador y observando la respuesta del volante frente a diversos cambios en la red.

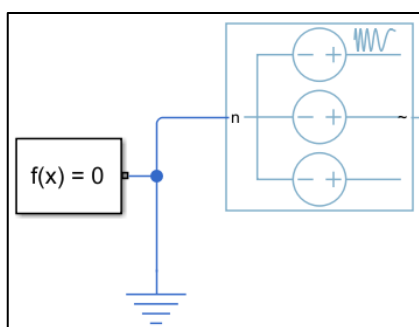


Figura 1. Bloque fuente de alimentación y configuración del solucionador.

### 2.2 Medición de potencia activa y reactiva

La Figura 3 representa el bloque crucial para el control y la regulación del sistema de energía renovable en la planta desaladora. Está compuesto por sensores que capturan los

valores de potencia activa (P) y reactiva (Q) del sistema (Willems, 2010). Estos sensores están conectados a la fuente de voltaje programable trifásica, permitiendo la monitorización en tiempo real de los parámetros eléctricos. Los datos obtenidos son esenciales para el sistema de control, proporcionando información precisa para ajustar y optimizar el uso de la energía generada por la fuente eólica. Esto asegura una operación eficiente y equilibrada de la planta desaladora.




Figura 3. Bloque de medición de potencia activa y reactiva.

### 2.3 Medición de tensión de línea y RMS

En esta sección del modelo (Figura 4), se realiza la medición de la tensión de línea trifásica y el cálculo del valor RMS. El bloque de “Voltaje de Línea Trifásica” mide las tensiones de las tres fases del sistema. Estos valores de tensión se utilizan para obtener información sobre el estado de la red y son esenciales para el control preciso del sistema de energía.

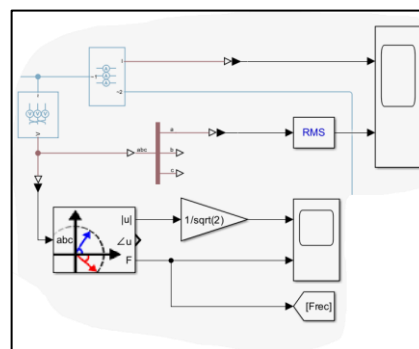


Figura 4. Bloque de medición de tensión de línea y RMS.




Figura 2. Diagrama de Bloques de Simulink.



El bloque de medición RMS calcula el valor cuadrático medio (RMS) de las señales de tensión. Esta se utiliza para la representación de la energía efectiva del sistema.

El Medidor de Fase de Positiva (PMU) basado en PLL es utilizado para calcular la secuencia positiva de las tensiones. Su principal función es sincronizar las fases y garantizar una operación estable y eficiente del motor de inducción. El PMU también calcula la magnitud y el ángulo de las tensiones, lo que permite un análisis detallado del estado de la red. La salida del PMU se normaliza usando un bloque que divide por la raíz cuadrada de dos, lo cual es necesario para convertir las mediciones a una base de referencia adecuada. Adicionalmente, se incluye un bloque que ajusta la frecuencia de la red, asegurando que las mediciones y el control sean precisos y reflejen las condiciones actuales de operación.

#### 2.4 Máquina de inducción y permutación de fases

La Máquina de Inducción tipo Jaula de Ardilla es uno de los componentes principales del sistema. Este bloque simula el comportamiento de un motor de inducción (Kundur, 1993; Lyshevski, 1999; Ojo et al., 1990). La máquina de inducción es accionada por la fuente de voltaje trifásica y su modelo incluye parámetros como la resistencia y la inductancia del rotor y el estator, para configurar estos parámetros fue necesaria la utilización de datos estimados a través de la metodología (Cetin et al., 2020).

El bloque de Permutación de Fases, Figura 5, ubicado debajo del motor de inducción, se utiliza para cambiar el orden de las fases de la señal trifásica. Esta permutación de fases es necesaria para realizar la conexión en trifásica.




Figura 5. Bloque del motor de inducción y permutación de fases.

#### 2.5 Inercia del sistema

En esta sección del modelo (Figura 6) se representa la inercia del sistema, un componente para la regulación dinámica de energía en la planta desaladora. El bloque de la "Máquina de Inducción tipo Jaula de Ardilla" está conectado a un circuito de inercia que simula diversos aspectos del comportamiento mecánico del sistema (Katsuhiko Ogata, 1990).




Figura 6. Bloque de inercia del sistema.

El circuito de inercia incluye una bobina, un condensador y un amortiguador. Cada uno de estos componentes tiene un papel específico en la simulación del comportamiento del sistema:

- **Bobina (L):** La bobina en el circuito representa la rigidez del eje del motor. La rigidez del eje es un parámetro importante que afecta la capacidad del motor para resistir deformaciones bajo carga. En el contexto del modelo, esta rigidez se simula mediante la inductancia de la bobina, que almacena energía en el campo magnético durante la operación. Para ello se toma el momento de inercia polar a través de la ecuación (1) y posteriormente se sustituye en la ecuación (2) para obtener la deformación y así sustituir en la (3) y tener la rigidez.

$$I = \frac{\pi}{2} * D^4 \quad (1)$$

$$\theta = \frac{M * L}{G * I_o} \quad (2)$$

$$k = \frac{M}{\theta} \quad (3)$$

- **Condensador (C):** El condensador en el circuito representa los parámetros de fricción rotacional del motor. La fricción rotacional es la resistencia que encuentra el rotor al girar, y está relacionada con las pérdidas mecánicas internas del motor y el coeficiente de fricción calculado durante los ensayos (Douairi et al., n.d.) Este coeficiente de fricción se refiere a la resistencia al movimiento del rotor debido a la interacción con el medio ambiente y otros componentes mecánicos. También se consideran parámetros de entrada en este bloque las fricciones estáticas y la de Coulomb y la velocidad para la fricción de Stribeck, los cuales vienen determinados intrínsecamente en los parámetros del motor.
- **Amortiguador rotacional (R):** este representa las pérdidas producidas por la deformación del eje, que a su vez está también relacionado con la rigidez del mismo. Para la obtención de este parámetro se parte de la ecuación diferencial de un movimiento rotacional.

$$I\ddot{\theta} + B\dot{\theta} + k\theta = T \quad (4)$$

En esta ecuación 4,  $I$  representa el momento de inercia del sistema,  $\ddot{\theta}$  es la aceleración angular,  $B$  es el coeficiente de amortiguamiento rotacional,  $\dot{\theta}$  es la velocidad angular,  $k$  es la rigidez rotacional del eje,  $\theta$  es el desplazamiento angular, y  $T$  es el par aplicado al sistema. Considerando que el término de la rigidez es tan elevado que la deformación angular será tan baja que se podrá despreciar. De esta forma quedaría como la ecuación 5:

$$B = \frac{T}{\omega} \quad (5)$$

El volante de inercia, representado en el diagrama, actúa como regulador dinámico que almacena y libera energía cinética para equilibrar las variaciones instantáneas entre la generación y la demanda de energía. Durante los periodos de exceso de generación de energía eólica, el volante de inercia almacena energía girando a altas velocidades. Cuando la demanda de energía supera la generación, el volante reduce su velocidad, liberando la energía almacenada para mantener la estabilidad del sistema. También se han colocado equipos de medida para obtener, velocidad, aceleración y torque generado por el volante de inercia.

### 2.6 Parámetros de operación y cálculo de deslizamiento

En la figura 7 se convierten los datos de salida del bloque de motor de unidades en tanto por uno a magnitudes reales y posteriormente se grafican. Estos datos son el Par Motor, la Velocidad del Rotor, La Potencia Activa, la Velocidad Angular del Estator (esta velocidad se compara con la velocidad del rotor para calcular el deslizamiento del motor) y el deslizamiento. Este se calcula utilizando la siguiente ecuación 6.

$$\frac{\omega_s - \omega_r}{\omega_s} \quad (6)$$

Donde  $\omega_s$  es la velocidad angular del estator y  $\omega_r$  es la velocidad angular del rotor.




Figura 7. Bloque paso de parámetros en tanto por uno a magnitudes.

El bloque “XY Graph” permite visualizar la relación entre el par motor y la velocidad angular del rotor, facilitando el análisis del comportamiento del motor bajo diversas condiciones de operación. Este tipo de visualización es útil para identificar patrones y ajustar el control del sistema de manera efectiva.

Finalmente, los resultados del cálculo de deslizamiento y otros parámetros se utilizan para ajustar el control del sistema de almacenamiento de energía. Esta integración de mediciones y cálculos es fundamental para el éxito del proyecto, permitiendo una gestión inteligente y adaptable del sistema.

### 3. Validación del modelo

Para la validación del modelo se han realizado ensayos experimentales, obteniendo valores de potencia según diferentes consignas dadas al variador de frecuencia que controla el motor. Conocida la relación tensión frecuencia (V) (7) y pudiendo calcular la frecuencia (F) (8).

$$V = 8 * F \quad (7)$$

$$F = \frac{\omega_r}{60} \quad (8)$$

Para los tres saltos seleccionados para realizar la validación los resultados obtenidos han sido. Las gráficas que relacionan la potencia-velocidad-consigna para el tramo de aceleración han sido:




Figura 8. Relación potencia-velocidad-consigna para tramo de aceleración de: a)1700-1900, b)1900-2200, c)2200-2500.

Para el tramo de desaceleración se han obtenido:




Figura 9. Relación potencia-velocidad-consigna para tramo de desaceleración de: a)2200-1900, b)1900-1700, c)2500-2200.

Trasladando los datos en forma de frecuencia y tensión a la fuente de alimentación del sistema de bloques de Simulink. Al introducirlos en el bloque de fuente de tensión y alimentar al resto del sistema se obtiene una simulación del modelo desarrollado donde se podrá ver como el volante genera o absorbe la energía frente a las variaciones de la frecuencia de la red, estimando así su capacidad como acumulador de energía dinámico. La parametrización de este tipo de sistema es muy valiosa, dado que no es un sistema lineal que, al escalarse para implementarlo en distintos tipos de sistemas vaya a tener una respuesta genérica fácil de estimar.

A continuación, se muestran los resultados del salto energético absorbido por el volante en la Figura 10, caso que se daría cuando el consumo de la planta desaladora sea inferior a la generada por la eólica.

Absorbiendo Energía					
w1 (rpm)	w2 (rpm)	Pmáx Real (kW)	Pmáx Modelo	Error Absoluto	Error Relativo
1700	1900	2,54	2,51	0,03	1,181102
1900	2200	4,05	4,09	-0,04	-0,98765
2200	2500	6,33	6,72	-0,39	-6,16114

Figura 10. Resultados del salto energético absorbido por el volante.

Por otro lado, en la Figura 11 se tiene los resultados del salto energético cedido por el volante, lo cual sucedería en caso de que la planta desaladora requiera de mayor cantidad de energía de la que está siendo generada por el parque eólico.

Cediendo Energía					
w1 (rpm)	w2 (rpm)	Pmáx Real (kW)	Pmáx Modelo	Error Absoluto	Error Relativo
2500	2200	6,88	6,77	0,11	1,598837
2200	1900	4,01	3,91	0,1	2,493766
1900	1700	2,72	2,88	-0,16	-5,88235

Figura 11. Resultados del salto energético cedido por el volante.

Como se puede observar, el sistema produce unos resultados bastante semejantes a los obtenidos en el banco de ensayo, las principales diferencias se deben, muy probablemente a errores debido a los grandes intervalos de muestreo que tienen los sensores que se han usado para la adquisición de los datos, obteniendo de esta forma la medida de la potencia desfasada de las velocidades. Al representar la entrada de un escalón unitario en la subida de velocidad por ejemplo de 1900-2200 (Figura 8. b), se pueden observar las siguientes gráficas en las Figuras 12,13,14 y 15.



Figura 12. Gráfica de par del motor frente al escalón de 1900-2200.




Figura 13. Gráfica de velocidad frente al escalón de 1900-2200.



Figura 14. Gráfica de potencia frente al escalón de 1900-2200.




Figura 15. Gráfica de deslizamiento frente al escalón de 1900-2200.

#### 4. Resultados

El modelo desarrollado en Simulink demostró ser efectivo para simular la operación de un sistema de acumulación de energía mediante volante de inercia. Se lograron los siguientes resultados clave:

- El sistema modelado fue capaz de simular con poco error los ciclos de absorción y descarga de energía con un margen pequeño de error.
- Se producen ciertos desfases en las medidas tomadas respecto a potencia y cambios de velocidad, lo cual genera la necesidad de implementar mejores equipos electrónicos para la toma de datos y posterior procesamiento de los mismos.
- Se ha puede observar como en los momentos de mayor demanda energética, el volante de inercia liberó la energía almacenada, manteniendo la estabilidad del sistema.

Estos resultados confirman la viabilidad de la línea en investigación de cara a mejorar el modelo para obtener resultados más precisos y ampliarlo de cara a poder usarlo con señales de entrada variables ya sean programables u otros bloques de Simulink con el objetivo de simular tanto la generación de un aerogenerador como el consumo de una desaladora cerrando el ciclo así de una microrred.

#### Agradecimientos

Este trabajo de investigación es parte del proyecto PID2022-142148OA-I00 financiado por MCIN/AEI/10.13039/501100011033/FEDER, UE.



Esta contribución ha sido co-financiada por la Ayuda RED2022-134588-T financiada por MICIU/AEI /10.13039/501100011033.

#### Referencias

- Cetin, O., Dalcali, A., & Temurtas, F. (2020). A comparative study on parameters estimation of squirrel cage induction motors using neural networks with unmemorized training. *Engineering Science and Technology, an International Journal*, 23. <https://doi.org/10.1016/j.jestch.2020.03.011>
- Douairi, H., Torres, J. C., Cabrera, P., & Carta, J. A. (n.d.). *Modelo lineal de pérdidas de un volante de inercia*. <https://doi.org/10.4995/riai.2020.7133>
- Katsuhiko Ogata. (1990). *Ingeniería de Control Moderna* (3a. Ed).
- Kundur, P. (1993). *Power System Stability and Control*.
- Lyshevski, S. E. (1999). *Electromechanical Systems, Electric Machines, and Applied Mechatronics*.
- Matos, C., Cabrera, P., Carta, J. A., & Melián-Martel, N. (2024). Wind-Powered Desalination on Islands: A Review of Energy–Water Pathways. In *Journal of Marine Science and Engineering* (Vol. 12, Issue 3). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/jmse12030464>
- Ojo, J. O., Consoli, A., & Lipo, T. A. (1990). *An improved Model of Saturated Induction Machine*.
- Willems, J. (2010). *The IEEE standard 1459: what and why*.

## Modelo lineal de pérdidas de un volante de inercia

Douairi, Hamza.<sup>a</sup>, Torres-Bordón, Juan Carlos<sup>a</sup>, Carta, José Antonio.<sup>a</sup>, Cabrera, Pedro.<sup>a</sup>

<sup>a</sup> *Departamento de Ingeniería Mecánica, Universidad de Las Palmas de Gran Canaria,*

**To cite this article:** Douairi, Hamza., Torres-Bordón, Juan Carlos, Carta, José Antonio, Cabrera, Pedro. 2024. Linear Loss Model of a Flywheel. XIX Simposio CEA de Control Inteligente (2024)

### Resumen

El volante de inercia es un sistema mecánico robusto que almacena energía cinética, con aplicaciones potenciales en ingeniería como transporte, energías renovables y vehículos espaciales. Destacan su alta densidad de potencia, eficiencia y larga vida útil. Se considera una opción viable para aplicaciones que requieren almacenamiento energético con ciclos de trabajo elevados. En este estudio, se busca crear un modelo lineal de pérdidas de un volante de inercia, proponiendo una estrategia inteligente para gestionar su velocidad angular. Se investiga si el método propuesto modela adecuadamente el comportamiento de la velocidad angular. El volante, ubicado en el Laboratorio de Diseño y Mantenimiento de Máquinas de la Universidad de Las Palmas de Gran Canaria, está diseñado para estabilizar una microrred eléctrica basada en energía eólica.

*Palabras clave:* Filtrado y suavizado, herramientas de minería de datos, modelado, sistemas mecatrónicos, operación y planificación del almacenamiento de energía, control inteligente de los sistemas de energía, estructuras inteligentes.

### Linear Loss Model of a Flywheel

### Abstract

The flywheel is a robust mechanical system that stores kinetic energy, with potential applications in fields such as transportation, renewable energy, and space vehicles. Its high-power density, efficiency, and long service life are outstanding. It is considered a viable option for applications requiring energy storage with high duty cycles. In this study, we aim to create a linear loss model of a flywheel and propose an intelligent strategy to manage its angular velocity. We investigate whether the proposed method adequately models the behaviour of the angular velocity. The flywheel, located in the Machine Design and Maintenance Laboratory of the University of Las Palmas de Gran Canaria, is designed to stabilize an electrical microgrid based on wind energy.

*Keywords:* Filtering and smoothing, data mining tools, modeling, mechatronic systems, energy storage operation and planning, intelligent control of energy systems, smart structures.

## 1. Introducción.

El almacenamiento y gestión eficiente de energía es crucial en la ingeniería moderna, especialmente en sistemas industriales y de energías renovables (Sayed et al., 2023). Los volantes de inercia desempeñan un papel fundamental en la acumulación y liberación de energía cinética, ofreciendo una solución robusta y eficaz para el manejo de fluctuaciones en la demanda energética (Hacene Mahmoudi, n.d.). Este artículo se centra en la creación de un modelo lineal para predecir las pérdidas de un volante de inercia, lo cual es esencial para optimizar su eficiencia y funcionamiento.

Utilizando técnicas avanzadas de minería de datos y regresión lineal, se pretende cuantificar y comprender mejor

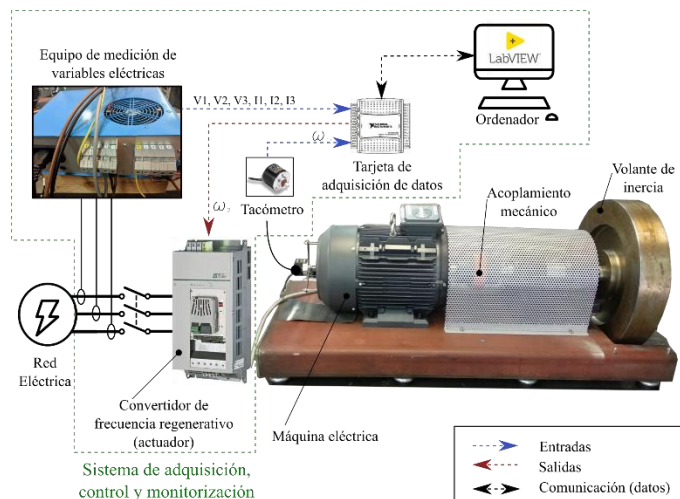
las pérdidas asociadas al volante de inercia. La metodología aplicada sigue el enfoque KDD (Knowledge Discovery in Databases), que permite extraer información valiosa de los datos recopilados. Este proceso no solo mejora la precisión en la predicción de las pérdidas, sino que también sienta las bases para futuras aplicaciones de Machine Learning (Gamarrá et al., 2016).

El modelo desarrollado se utilizará para predecir las pérdidas del volante de inercia en diversas condiciones operativas, facilitando así su integración en sistemas de gestión inteligente. Este enfoque permite ajustar de manera precisa la velocidad angular del volante, optimizando el rendimiento del sistema y reduciendo las pérdidas energéticas. Además, el conocimiento obtenido de este estudio puede aplicarse en la gestión de microrredes eléctricas basadas en fuentes

renovables, como la energía eólica, mejorando la estabilidad y eficiencia de estos sistemas (Carta et al., 2003).

## 2. Materiales

Este capítulo detalla el diseño del volante de inercia y sus subsistemas asociados, como se muestra en la Figura 1.



**Figura 1:** Sistema mecatrónico diseñado para gestionar un volante de inercia

### 2.1. Volante de inercia

El volante de inercia es una pieza fundamental del sistema, diseñada como un disco de acero AISI 1045 que se acopla a un árbol. Sus especificaciones incluyen un peso de 790 N, un diámetro de 450 mm y un espesor de 80 mm, lo que resulta en un volumen total de 9784.6 cm<sup>3</sup>. Esta masa giratoria juega un papel crucial en el almacenamiento y la transferencia de energía cinética dentro del sistema.

### 2.2. Máquina eléctrica

Se trata de una máquina eléctrica trifásica de inducción, identificada como modelo TECHTOP T2AR132S2-2, es un componente clave del sistema. Con una velocidad nominal de 2920 rpm y una tensión de 400V en corriente alterna (CA), esta máquina tiene una potencia nominal de 7.5 kW. Su función principal es convertir la energía mecánica del volante de inercia en energía eléctrica y viceversa, lo que permite la transferencia bidireccional de energía dentro del sistema. Esta máquina proporciona la capacidad necesaria para gestionar eficientemente la energía cinética almacenada en el volante de inercia, contribuyendo así al funcionamiento global del sistema de manera óptima.

### 2.3. Sistema actuador y convertidor de frecuencia

El sistema actuador se compone de un convertidor de frecuencia regenerativo Leroy-Somer Powerdrive FX33T. Este dispositivo permite la transferencia bidireccional de energía entre la red eléctrica y la máquina eléctrica trifásica de inducción. El convertidor recibe una consigna de velocidad

angular (0-2920 rpm) y actúa de dos maneras: Si la velocidad angular del volante de inercia es inferior a la consigna, el convertidor facilita el flujo de energía desde la red hacia la máquina eléctrica para alcanzar la velocidad requerida; si la velocidad angular excede la consigna, el convertidor transforma el exceso de energía cinética en energía eléctrica, la devuelve a la red y frena la máquina eléctrica para mantener la estabilidad del sistema.

### 2.4. Sistema de medición de velocidad y energía

El sistema de medición de velocidad y energía emplea una combinación de dispositivos especializados: Un transductor de velocidad angular, modelo E6C2-C, que genera 2000 pulsos por cada revolución, proporcionando una medida precisa de la velocidad del volante de inercia. Un equipo diseñado específicamente para medir las variables eléctricas del sistema. Este conjunto incluye tres transductores de intensidad LEM HAL 50-S, capaces de medir corrientes instantáneas de hasta 50 A con una precisión de  $\pm 1\%$ . Además, se emplean tres transductores de tensión LEM LV 25-P, capaces de medir tensiones instantáneas de hasta 500V. Complementando estos elementos, se incluye la electrónica necesaria para su funcionamiento y alimentación. Este sistema garantiza una medición precisa y confiable de las corrientes y tensiones trifásicas en el sistema mecatrónico, lo que permite un monitoreo detallado de su rendimiento eléctrico.

### 2.5. Tarjeta de adquisición de datos

La tarjeta de adquisición de datos National Instruments USB-6009 desempeña un papel crucial en la conversión de medidas eléctricas en datos digitales interpretables por un ordenador. Esta tecnología permite la captura precisa y eficiente de las señales eléctricas generadas por el sistema mecatrónico. La tarjeta actúa como un intermediario, traduciendo las señales analógicas en formato digital, lo que facilita su procesamiento y análisis por parte del software de control.

### 2.6. Software de monitoreo y control integrado


El ordenador alberga un sistema de monitoreo y control integrado que comprende múltiples subrutinas. Estas subrutinas están diseñadas para calcular y registrar diversas métricas, como potencia y velocidad angular, utilizando las medidas eléctricas y los pulsos generados por el sistema. Esta solución proporciona una supervisión detallada y un control efectivo del sistema mecatrónico, permitiendo una operación precisa y eficiente en tiempo real.

## 3. Método

En este trabajo, se adopta el enfoque KDD (Knowledge Discovery in Databases) para la gestión inteligente de la velocidad angular del volante de inercia. Este método, característico de la Minería de Datos, facilita la identificación y extracción de conocimientos ocultos y potencialmente valiosos para la comprensión profunda del sistema y el logro de objetivos específicos (Gamarrá et al., 2016). Similar al

proceso de aprendizaje humano, el KDD (*Knowledge Discovery in Databases*) examina nueva información y la vincula con objetivos específicos, empleando técnicas avanzadas de aprendizaje automático (*Machine Learning*). Estas técnicas permiten identificar patrones y regularidades en los datos, proporcionando una base sólida para la toma de decisiones informadas y la optimización en la gestión del volante de inercia. A través del uso de algoritmos de *Machine Learning*, es posible generar modelos predictivos que mejoren la eficiencia y el control del sistema, garantizando así un rendimiento óptimo y una mejor adaptación a diversas condiciones operativas. (Fayyad et al., 1996).

El proceso de KDD implica varias etapas, como se puede observar en la *Figura 2*, incluyendo la recopilación de datos, selección y limpieza de los datos incorrectos o incompletos, la propia minería de datos, la evaluación e interpretación de la precisión, y finalmente la aplicación y el uso.



**Figura 2.** Esquema general del proceso de extracción del conocimiento

### 3.1. Recopilación de datos

Para la recopilación de datos del volante de inercia, se empleó un modelo mecatrónico sofisticado utilizando LABVIEW. Este software se configuró para capturar datos relevantes del volante, diseñando módulos específicos para medir la velocidad angular y la potencia en tiempo real. El objetivo principal fue regular la velocidad angular del volante para que generara o consumiera la potencia requerida, implementando algoritmos de control que ajustaban dinámicamente la velocidad según las condiciones operativas. Esto permitió simular diversas condiciones de carga y descarga, garantizando la representatividad de los datos. Una vez recopilados, los datos de velocidad angular y potencia se almacenaron para su posterior análisis, permitiendo interpretar el comportamiento del volante y calcular con precisión las pérdidas del sistema.

### 3.2. Selección y limpieza de datos

Tras recoger los datos del volante de inercia, se generaron ficheros con las combinaciones posibles de velocidades angulares ensayadas. El siguiente paso fue seleccionar y limpiar estos datos para asegurar su calidad y relevancia en el cálculo de las pérdidas del volante de inercia.

Para la selección de datos, se escogieron los intervalos correspondientes a la velocidad angular inicial del volante, es decir, antes de cualquier cambio a otra velocidad angular. Esto permite centrarse en las condiciones iniciales del sistema, fundamentales para establecer una línea base precisa para el cálculo de las pérdidas. La selección se realizó meticulosamente para capturar el comportamiento real del volante bajo condiciones estables. Con los datos

seleccionados, se llevó a cabo un proceso de limpieza exhaustivo utilizando *MATLAB R2024a*. Se aplicaron métodos de filtrado para suavizar las señales y eliminar el ruido de alta frecuencia, asegurando que las mediciones fueran representativas del comportamiento real del volante. Se identificaron y eliminaron datos atípicos que podrían distorsionar el análisis. Finalmente, los datos se normalizaron para garantizar que todas las variables estuvieran en una escala comparable.

Este proceso de limpieza y filtrado fue fundamental para obtener un conjunto de datos de alta calidad, libre de ruido y preparado para el análisis detallado. Esto asegura que los cálculos de las pérdidas del volante de inercia se basen en datos fiables y representativos, garantizando la validez de los resultados.

### 3.3. Minería de datos

En esta fase del proyecto, se realizó la minería de datos con el objetivo de obtener el coeficiente de pérdidas del volante de inercia. Este coeficiente se determina a partir de los datos de potencia y velocidad angular del volante, los cuales se utilizan para calcular el par y posteriormente realizar una regresión lineal.

La minería de datos en este proyecto se basa en la aplicación de principios fundamentales de la física para obtener el coeficiente de pérdidas del volante de inercia. Un punto de partida crucial es la *ecuación 1* que gobierna el comportamiento dinámico del sistema rotativo:

$$I \frac{d\omega}{dt} + \gamma\omega = T \quad (1)$$

Esta ecuación representa una manifestación de la segunda ley de Newton para sistemas rotativos. En ella,  $I$  es el momento de inercia del volante,  $\frac{d\omega}{dt}$  es la aceleración angular,  $\gamma$  es el coeficiente de fricción,  $\omega$  es la velocidad angular, y  $T$  es el par aplicado al volante de inercia.

Esta ecuación encapsula la esencia del comportamiento del sistema, donde la suma de los momentos aplicados es igual al momento de inercia multiplicado por la aceleración angular, más el producto del coeficiente de fricción por la velocidad angular. Es esencial comprender que el coeficiente  $\gamma$  representa las pérdidas en el sistema, como la fricción interna y otras resistencias.

La constante de inercia ( $I$ ) del volante de inercia se calcula mediante la *ecuación 2*:

$$I = \frac{1}{2} \cdot masa \cdot R^2 \quad (2)$$

donde se debe de tener en cuenta la masa, el momento de inercia ( $I$ ) y el radio  $R$  (225 mm) del volante de inercia. La *ecuación 3* sirve para determinar la masa del volante:

$$masa = V \cdot \rho = 0,0127 \text{ m}^3 \cdot 7850 \text{ kg/m}^3 = 99,695 \text{ kg} \quad (3)$$

- $\rho$  es la densidad del acero (aprox. 7850 kg/m<sup>3</sup>)
- $V$  es el volumen (0,0127 m<sup>3</sup>).

Por lo que, resolviendo la *ecuación 4*, se obtiene así el siguiente momento de inercia:

$$I = \frac{1}{2} \cdot masa \cdot R^2 = \frac{1}{2} \cdot 99,6950 \text{ kg} \cdot 0,225^2 = 2,5235 \text{ kg} \cdot \text{m}^2 \quad (4)$$

El primer paso en la minería de datos fue utilizar las mediciones de potencia y velocidad angular para calcular el par. La relación entre la potencia ( $P$ ), el par ( $T$ ) y la velocidad angular ( $\omega$ ) se expresa mediante la *ecuación 5*:

$$P = T \times \omega \quad (5)$$

Reordenando la *ecuación 5*, se puede obtener la *ecuación 6* y resolver el par como:

$$T = P/\omega \quad (6)$$

Con los valores de par y velocidad angular calculados, el siguiente paso fue aplicar una regresión lineal para obtener el coeficiente de pérdidas del volante de inercia. Para entender esto mejor, primero simplificamos la *ecuación 1*. Consideramos el caso en el que no hay aceleración angular, es decir, la velocidad angular ( $\omega$ ) es constante y la aceleración angular ( $d\omega/dt$ ) es cero. Por lo tanto, cuando  $d\omega/dt = 0$ , la *ecuación 1* se reduce a la *ecuación 7*:

$$T = \gamma\omega \quad (7)$$

Esta expresión revela una relación lineal entre el par y la velocidad angular, donde el coeficiente " $\gamma$ " representa las pérdidas del sistema. Sin embargo, para obtener este coeficiente con precisión, es esencial asegurarse de que la gráfica de  $T$  en función de  $\omega$  pase por el origen. Esto significa que cuando la velocidad angular es cero, el par aplicado al volante de inercia también lo es. Esta condición inicial es crucial, ya que nos permite determinar el coeficiente de pérdidas directamente de la pendiente de la gráfica. Esencialmente, el coeficiente de pérdidas se interpreta como la pendiente de esta relación lineal entre el par y la velocidad angular. Aquí es donde entra en juego la regresión lineal. Esta técnica estadística permite modelar la relación entre dos variables (en este caso, el par y la velocidad angular) mediante una línea recta que mejor se ajuste a los datos experimentales. Al ajustar esta línea, podemos determinar la pendiente, que representa el coeficiente de pérdidas del volante de inercia. La regresión lineal nos proporciona una herramienta poderosa para cuantificar y comprender las pérdidas en el sistema de forma precisa y basada en datos reales.

### 3.4. Evaluación e interpretación

Para evaluar las estimaciones numéricas de los modelos propuestos, utilizamos las métricas de error absoluto medio (MAE), error porcentual absoluto medio (MAPE) y el coeficiente de determinación (R-cuadrado).

El MAE se define por la siguiente *ecuación 8*, donde los valores estimados están representados por la letra " $\hat{e}_i$ " y los valores observados por la letra " $o_i$ ". El MAE se expresa en las mismas unidades que los parámetros que compara (Carta, Cabrera, et al., 2015).

$$MAE = \frac{1}{n} \sum_{i=1}^n |o_i - \hat{e}_i| \quad (8)$$

El MAPE se define por la siguiente *ecuación 9* y es una medida relativa que expresa el error como un porcentaje de los datos observados (Carta, Cabrera, et al., 2015).

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{o_i - \hat{e}_i}{o_i} \right| \quad (9)$$

El R-cuadrado se obtiene mediante la *ecuación 10* y mide la proporción de la variación en la variable de respuesta ( $y$ ) explicada por las variables independientes ( $x$ ) (Lozano et al., 2020).

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} \quad (10)$$

Siendo  $SSE$  la suma de los errores al cuadrado (Sum of Squared Errors),  $SSR$  la suma de las regresiones al cuadrado (Sum of Squared Regression), y  $SST$  es la suma total de los cuadrados (Sum of Squared Total).

Estas métricas nos permiten evaluar de manera integral la precisión y calidad de los modelos propuestos, proporcionando una comprensión detallada de su rendimiento en comparación con los datos observados.

### 3.5. Aplicación y uso

Una vez creado y validado el modelo de regresión lineal para predecir las pérdidas del volante de inercia, se procede a su integración en un sistema de gestión inteligente. El objetivo principal es emplear el modelo para mejorar la comprensión y optimización del sistema en futuras aplicaciones de Machine Learning.

El modelo lineal desarrollado se utilizará para conocer y predecir las pérdidas del volante de inercia, lo que permite tener en cuenta estos factores en la gestión del sistema. En futuras aplicaciones, este conocimiento se integrará en algoritmos de Machine Learning que gestionarán de manera inteligente la velocidad angular del volante, respondiendo a las condiciones cambiantes del entorno operativo. La integración de este modelo permitirá al sistema ajustar de manera precisa la velocidad angular del volante de inercia en función de diversas variables operativas. Con esta información, el modelo predictivo estimará las pérdidas del volante de inercia y ajustará su velocidad angular para optimizar el rendimiento del sistema.

Esta implementación no solo mejora la eficiencia del volante de inercia, sino que también facilita su integración en sistemas más complejos. Por ejemplo, en aplicaciones futuras, el sistema de almacenamiento de energía con el volante de inercia podría formar parte de una microrred eléctrica renovable generación eólica y una planta desaladora (Carta, González, et al., 2015). La gestión inteligente del volante de inercia aseguraría que la potencia requerida para el instante futuro se calcule adecuadamente, basándose en la diferencia entre la potencia generada por el aerogenerador y la potencia consumida por la planta desaladora (González et al., 2018).

## 4. Resultados y conclusiones

El presente estudio se centró en la creación de un modelo lineal para predecir las pérdidas de un volante de inercia. Para ello, se recopilaron datos de la velocidad angular del volante y de la potencia, a partir de los cuales se calcularon el par y el coeficiente de pérdidas. Se generaron dos gráficas principales: una que muestra la relación entre el par y la velocidad angular, y otra que compara el par real con el par estimado.

La *Figura 3* revela una clara tendencia lineal positiva entre el par y la velocidad angular del volante de inercia. La *ecuación 11* representa la regresión lineal obtenida:

$$y = 0.0044x \quad (11)$$



La ecuación anterior establece una relación matemática precisa entre ambas variables. La solidez del modelo lineal para explicar la variabilidad del par se ve respaldada por un elevado coeficiente de determinación  $R^2$  de 0.953, indicando que el 95.3% de los cambios en el par pueden ser explicados por la velocidad angular. Estos resultados confirman que el par generado por el volante de inercia aumenta de manera constante a medida que aumenta su velocidad angular. Este comportamiento se debe a la mayor inercia rotacional del volante a mayores velocidades, lo que requiere un mayor par para su aceleración o desaceleración. La alta correlación entre

Es importante destacar que el coeficiente de pérdidas obtenido, de  $0.0044 \text{ Nm}/(\text{rad}/\text{s})$ , indica la eficiencia del volante de inercia. Un coeficiente de pérdidas bajo, como en este caso, sugiere que el volante de inercia almacena energía de manera eficiente y la libera con poca pérdida durante su rotación

La Figura 4 compara el par real con el par estimado a partir de la multiplicación de la velocidad angular por el coeficiente de pérdidas. Se observa una fuerte correlación entre ambas variables, con un coeficiente de determinación  $R^2$  de 0.9868. Esto indica que el 98.68% de la variabilidad del par real puede ser explicada por el modelo lineal.




Figura 3. Relación entre el par y la velocidad angular del volante de inercia.

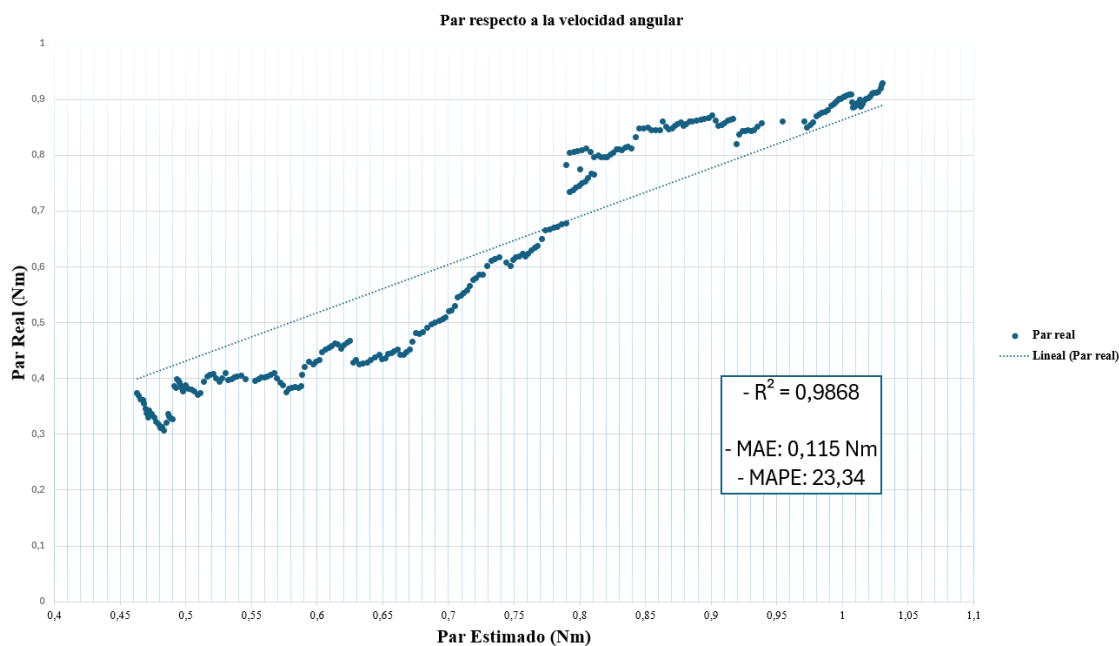


Figura 4. Comparación entre el par real y el par estimado en un volante de inercia.

el par y la velocidad angular, junto con el elevado valor de  $R^2$ , demuestran que el modelo lineal es una herramienta confiable para predecir el par a partir de la velocidad angular.

La precisión del modelo se verifica por el bajo error medio absoluto (MAE) de 0.115 Nm, el cual representa la diferencia promedio entre el par real y el par estimado.

Por otra parte, el error porcentual medio absoluto (MAPE) del 23.34% indica que las estimaciones del modelo son precisas en relación con el valor real. La alta correlación entre el par real y el par estimado, junto con los bajos valores de MAE y MAPE, permiten confiar en las predicciones del modelo para diferentes valores de velocidad angular.

Estos resultados subrayan la eficacia del modelo lineal en la predicción del par generado por el volante de inercia basado en su velocidad angular. La alta precisión y el bajo coeficiente de pérdidas reflejan la eficiencia del sistema, proporcionando una base sólida para decisiones informadas y optimización del sistema mecatrónico. Este estudio destaca la importancia de modelos matemáticos precisos en la comprensión y mejora de sistemas mecánicos complejos, y demuestra el potencial de la regresión lineal como herramienta analítica en ingeniería.

### Agradecimientos

Este trabajo de investigación es parte del proyecto PID2022-142148OA-I00 financiado por MCIN/AEI/10.13039/501100011033/FEDER, UE.



Esta contribución ha sido co-financiada por la Ayuda RED2022-134588-T financiada por MICIU/AEI/10.13039/501100011033.

### Referencias

- Carta, J. A., Cabrera, P., Matías, J. M., & Castellano, F. (2015). Comparison of feature selection methods using ANNs in MCP-wind speed methods. A case study. *Applied Energy*, 158, 490–507. <https://doi.org/10.1016/j.apenergy.2015.08.102>
- Carta, J. A., González, J., Cabrera, P., & Subiela, V. J. (2015). Preliminary experimental analysis of a small-scale prototype SWRO desalination plant, designed for continuous adjustment of its energy consumption to the widely varying power generated by a stand-alone wind turbine. *Applied Energy*, 137, 222–239. <https://doi.org/10.1016/j.apenergy.2014.09.093>
- Carta, J. A., González, J., & Subiela, V. (2003). Operational analysis of an innovative wind powered reverse osmosis system installed in the Canary Islands. *Solar Energy*, 75(2), 153–168. [https://doi.org/10.1016/S0038-092X\(03\)00247-0](https://doi.org/10.1016/S0038-092X(03)00247-0)
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). *From Data Mining to Knowledge Discovery in Databases* (© AAAI) (Vol. 17). [www.ffly.com/](http://www.ffly.com/)
- Gamarra, C., Guerrero, J. M., & Montero, E. (2016). A knowledge discovery in databases approach for industrial microgrid planning. In *Renewable and Sustainable Energy Reviews* (Vol. 60, pp. 615–630). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2016.01.091>
- González, J., Cabrera, P., & Carta, J. A. (2018). *Wind Energy Powered Desalination Systems*.
- Hacene Mahmoudi, N. G. M. G. J. B. (n.d.). *Renewable Energy Technologies for Water Desalination*.
- Lozano, A., Cabrera, P., & Blanco-Marigorta, A. M. (2020). Non-linear regression modelling to estimate the global warming potential of a newspaper. *Entropy*, 22(5). <https://doi.org/10.3390/E22050590>
- Sayed, E. T., Olabi, A. G., Alami, A. H., Radwan, A., Mdallal, A., Rezk, A., & Abdelkareem, M. A. (2023). Renewable Energy and Energy Storage Systems. In *Energies* (Vol. 16, Issue 3). MDPI. <https://doi.org/10.3390/en16031415>

## Modelos de predicción neuro-borrosos para un aerogenerador en una planta de fabricación industrial

Chicaiza, W.D., Gómez, J., Camacho, P.G., Escaño, J.M.\*

*Departamento de Ingeniería de Sistemas y Automática, Escuela Técnica Superior de Ingeniería. Universidad de Sevilla.  
Camino de los Descubrimientos, s/n, 41092 Sevilla. España.*

**To cite this article:** Chicaiza, W.D., Gómez, J., Camacho, P.G., Escaño, J.M., 2024. Neurofuzzy prediction models for a wind turbine of an industrial manufacturing plant. XIX Simposio CEA de Control Inteligente (2024)

### Resumen

Este trabajo se centra en el desarrollo de modelos de predicción neuro-fuzzy para un sistema de energía renovable basado en una red Adaptive Neuro-Fuzzy Inference System (ANFIS), un aerogenerador que forma parte de una planta de fabricación industrial multimáquina. Este modelo es una parte del conjunto de modelos que forman el gemelo digital de la planta de fabricación que se utilizará para realizar estrategias de control y optimización para maximizar el uso de fuentes de energía renovables dentro de una arquitectura de Gemelo Digital (GD) de sus contrapartes físicas. El modelo se utiliza para capturar el comportamiento del aerogenerador. Se aplica un proceso de agrupación para mitigar la saturación de datos y conseguir un comportamiento realista de la generación de energía. Los modelos neurofuzzy obtenidos muestran un buen rendimiento de las predicciones de la dinámica no lineal en todo el rango de operación en ambos sistemas. Se ha ideado un método para seleccionar la predicción más fiable entre las distintas disponibles, centrándose en su aplicabilidad a la producción.

*Palabras clave:* Modelado neuroborroso, ANFIS, ACP

### Neurofuzzy prediction models for a wind turbine of an industrial manufacturing plant

#### Abstract

This paper focuses on developing neuro-fuzzy prediction models for a renewable energy system based on an Adaptive Neuro-Fuzzy Inference System (ANFIS) network, a wind turbine that is part of a multi-machine industrial manufacturing plant. This model is a part of the set of models that form the digital twin of the manufacturing plant that will be used to realize control and optimization strategies to maximize the use of renewable energy sources within a Digital Twin (DT) architecture of their physical counterparts. The model is used to capture the behavior of the wind turbine. A clustering process is applied to mitigate data saturation and achieve realistic power generation behaviour. The neurofuzzy models obtained show a good performance of the predictions of the non-linear dynamics throughout the operating range in both systems. A method has been devised to select the most reliable forecast among the various forecasts available, with a focus on its applicability to production.

*Keywords:* Neuro-Fuzzy modeling, ANFIS, PCA

### 1. Introducción

En los últimos años, la adopción de recursos renovables para la generación de electricidad ha aumentado con parques eólicos terrestres y marinos, los cuales se utilizan para satisfacer la demanda de los consumidores. Al mismo tiempo, el precio

elevado de la energía está llevando a las industrias a adoptar diversas soluciones para dar potencia a sus distintos procesos de fabricación, evitando así la conexión con la red eléctrica. Un objetivo principal de estas plantas es maximizar el uso de energías renovables en su consumo energético. Para aplicar técnicas de optimización, es imprescindible tener modelos dinámicos de los

\*Autor para correspondencia: jescano@us.es  
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

recursos de generación. Aunque se dispone de buenos servicios de previsión meteorológica, es necesario incluir las ecuaciones dinámicas de los generadores (por ejemplo, la parte mecánica de la turbina eólica) y el sistema de control para predecir la energía generada.

El modelado de sistemas físicos complejos y no lineales, puede presentar ciertas dificultades. Además, el diseño de estrategias de optimización y control óptimo utilizando modelos no lineales para predecir el comportamiento del sistema implica una carga computacional considerable. Este es el principal obstáculo cuando el problema debe resolverse en un tiempo limitado, considerando el tiempo de muestreo. Por lo tanto, es indispensable emplear modelos simples que permitan un tiempo de computación adecuado y que, al mismo tiempo, sean lo más fieles posible a la dinámica del sistema. El modelado borroso ha demostrado ser una técnica efectiva para modelar y controlar sistemas no lineales y complejos, representando con éxito el modelo no lineal original (Zhong, 2020). Además, esta técnica de modelado permite un rápido aprendizaje de parámetros y una alta capacidad de ejecución.

En este artículo presenta un caso basado en una planta de fabricación industrial que está compuesta por una microrred que aprovecha el recurso eólico para suministrar energía a los procesos de producción (Gómez et al., 2023). La planta está compuesta por varias máquinas de control numérico por ordenador (CNC), un generador combinado de potencia y calor (CHP), dos fuentes de energía renovable para la producción de electricidad (Turbina eólica y paneles fotovoltaicos) y un banco de baterías para el almacenamiento de energía. Es necesario tener, entre otras, la predicción de la potencia generada por el aerogenerador. Dado que las variables meteorológicas que pueden predecirse en el horizonte son escasas (velocidad del viento e irradiancia global) y que la generación de energía renovable responde a un modelo no lineal complejo, el cual incluye la dinámica del controlador del mismo, se ha decidido usar un sistema de inferencia borroso (FIS) para predecir la generación de energía renovable. Este modelo será parte del gemelo digital que será usado para realizar estrategias de control y optimización.

El resto del documento se estructura de la siguiente manera. La sección 2 muestra el tratamiento inicial de los datos para ambos sistemas energéticos. En la sección 3 se presentan los modelos predictivos basados en sistemas de inferencia neuroborrosos adaptativos (ANFIS) así como los procesos de aprendizaje y sus estructuras. La sección 4 presenta la metodología para la selección de las predicciones de velocidad del viento. Por último, en la sección 5 se muestran las conclusiones.

## 2. Procesado de datos de entrada

El objetivo del modelo es la predicción de la potencia activa del generador. El preprocesamiento inicial de los datos históricos de la fuente renovable implica interpolar los datos inconsistentes entre las muestras y eliminar los valores atípicos de cada variable. Es crucial la selección cuidadosa de las variables que afectan al proceso

Los datos recogidos por el SCADA contienen mediciones hechas por los sensores de la instalación de la turbina eólica. Las variables de esos sensores se muestran en la Tabla 1.

Además, el SCADA almacena diariamente los datos en una hoja Excel. El registro de datos se realiza cada 10 minutos, de acuerdo con el estándar IEC 61400 de la industria eólica.

Tabla 1: Datos históricos de operación de la turbina eólica

Variable	Descripción	Unidad
<i>Date</i>	Fecha del registro	-
<i>Mr</i>	Lectura del contador	-
<i>Eg</i>	Electricidad generada	<i>kWh</i>
<i>ws</i>	Velocidad del viento	<i>m/s</i>
<i>Q</i>	Potencia reactiva	<i>kW</i>
<i>P</i>	Potencia activa AC	<i>kW</i>
<i>Rs</i>	Velocidad del rotor	<i>rpm</i>
<i>Np</i>	Posición góndola	°

El análisis revela que la potencia activa se satura durante el exceso de viento debido a la falta de unidades de almacenamiento o conexiones a la red para verter el exceso de energía. Para obtener datos precisos y no afectados por estas saturaciones, se aplicó un proceso de agrupamiento para filtrar los valores correspondientes.

El conjunto de datos resultante abarca 288 días, con 7 variables medidas a intervalos de 10 minutos. La salida del modelo es la potencia activa generada, utilizando variables del recurso eólico como entradas. La carga computacional para la evaluación de modelos basados en datos aumenta con el número de entradas. Las técnicas de reducción de dimensionalidad ofrecen ventajas al preservar la información relevante en un espacio reducido, facilitando así los procesos de control y optimización en tiempo real.

En este estudio, se emplean la agrupación de matrices de coeficientes de correlación y el Análisis de Componentes Principales (ACP). La agrupación identifica y descarta las variables no correlacionadas con los resultados del modelo, agrupando aquellas que sí lo están. El ACP reduce la dimensionalidad al transformar los conjuntos de datos en nuevas variables no correlacionadas dentro de un espacio de dimensiones reducidas, lo que mejora la eficiencia computacional. A continuación, se explican los fundamentos teóricos de ambas técnicas.

El coeficiente de correlación mide la asociación entre variables. El más usado es el coeficiente de correlación de Pearson, que es un coeficiente de correlación lineal ( $\rho$ ). El  $\rho$  para un par de variables ( $\mathbf{x}, \mathbf{y}$ ) con  $n$  muestras  $\mathbf{x} = [x_{1,1}, \dots, x_{n,1}]$  y  $\mathbf{y} = [y_{1,1}, \dots, y_{n,1}]$  se calcula utilizando (1)

$$\rho(x, y) = \frac{1}{n-1} \sum_{i=1}^n \left( \frac{x_{i,1} - \mu_x}{\sigma_x} \right) \left( \frac{y_{i,1} - \mu_y}{\sigma_y} \right), \quad (1)$$

donde  $\mu_x, \mu_y$  and  $\sigma_x, \sigma_y$  son la media y la desviación estándar de  $\mathbf{x}$  y  $\mathbf{y}$  muestras, respectivamente. Los valores que  $\rho$  puede tomar están entre  $[-1, 1]$ , donde  $\rho = -1$  representa una correlación negativa completa,  $\rho = 1$  representa una correlación positiva completa, y un valor de  $\rho = 0$  indica que las variables ( $\mathbf{x}, \mathbf{y}$ ) no están correlacionadas.

La matriz de coeficientes de correlación obtenida para la turbina de viento con  $M = 7$  variables es  ${}^WTR \in \mathfrak{R}^{7 \times 7}$ .

La Fig. 1 muestra la matriz de coeficientes de correlación de las variables del aerogenerador. A continuación, se ordenan

las variables según el grado de correlación de cada entrada en relación con la salida deseada para la matriz. Este análisis indica las variables que más afectan a la salida del modelo respecto a un umbral ( $\rho \geq 0,5$ ).

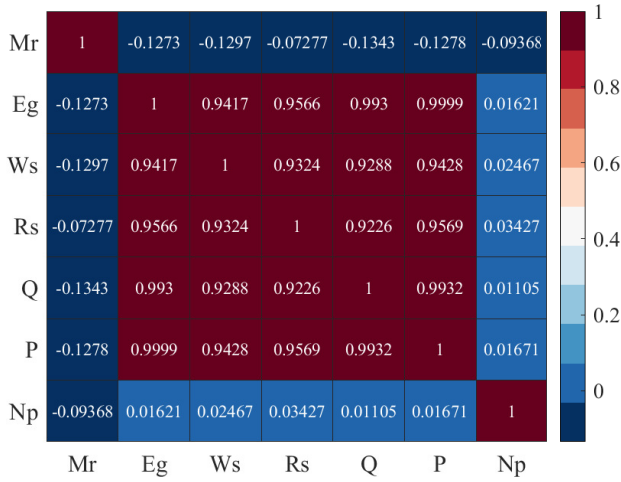


Figura 1: Matriz de coeficientes de correlación para la turbina de viento.

Los datos históricos recogidos sobre la fuente de energía renovable eólica se almacenan en una matriz  ${}^s\mathbf{X}$ . La variable  $s \subset \{WT\}$  representa la fuente renovable: turbina de viento (WT). Donde  ${}^s\mathbf{X} \in \mathfrak{R}^{N \times M}$ ,  $N$  es el número total de muestras, y  $M$  es el número de variables de la matriz.

Como el ACP se define por el criterio de varianza que depende de las unidades de medida, esto implica que los componentes principales de la matriz de covarianza  ${}^s\mathbf{R}$  cambian si las unidades de medida de cada variable tienen una escala diferente, como se señala en (Jolliffe and Cadima, 2016). Además, las diferentes escalas de las variables pueden afectar al proceso de aprendizaje basado en datos debido a su naturaleza, magnitud e inconsistencias. Esto se resuelve mediante el proceso de normalización, como se señala en (Chicaiza et al., 2022). Por lo tanto, cada variable  $m$  en la matriz de datos  ${}^s\mathbf{X}$  debe ser normalizada a media cero y varianza unitaria para darles el mismo peso, dado por

$$\mathbf{z}_{i,j} = \frac{x_{i,j} - \bar{x}_j}{\sigma_j}. \quad (2)$$

Las nuevas variables normalizadas se almacenan en la matriz  ${}^s\mathbf{Z}$  y se organizan en conjuntos: entrenamiento, comprobación y validación.

El ACP de un conjunto de datos normalizado  ${}^s\mathbf{Z} \in \mathfrak{R}^{N \times M}$ , con rango  $r$  ( $r \leq \min\{N, M\}$ ) se obtiene a partir de su matriz de covarianza  ${}^s\mathbf{R} \in \mathfrak{R}^{r \times r}$  y su Descomposición en Valores Singulares (DVS) usando (3) y (4), respectivamente.

$$(N-1){}^s\mathbf{R} = {}^s\mathbf{Z}^T {}^s\mathbf{Z} \quad (3)$$

$${}^s\mathbf{Z} = {}^s\mathbf{U} {}^s\mathbf{S} {}^s\mathbf{V}^T \quad (4)$$

donde  $N$  es el número total de muestras en la matriz  ${}^s\mathbf{Z}$ . Como puede observarse en (4), la DVS de la matriz  ${}^s\mathbf{Z}$  está relacionada con la descomposición en autovalores de la matriz de covarianza  ${}^s\mathbf{R}$ , donde  $\mathbf{U} \in \mathfrak{R}^{n \times r}$ ,  $\mathbf{V} \in \mathfrak{R}^{m \times r}$  son matrices con columnas ortogonales <sup>1</sup> y  ${}^s\mathbf{S} \in \mathfrak{R}^{r \times r}$  es una matriz diagonal  $\text{diag}\{\sigma_1, \sigma_2, \dots, \sigma_r\}$  cuyos elementos son la raíz cuadrada de los autovalores de  ${}^s\mathbf{Z}^T {}^s\mathbf{Z}$  en orden decreciente ( $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r$ ).

Así, sustituyendo (4) en (3) el ACP se obtiene como

$$(N-1){}^s\mathbf{R} = {}^s\mathbf{V} {}^s\mathbf{\Lambda} {}^s\mathbf{V}^T, \quad (5)$$

donde,  ${}^s\mathbf{\Lambda} \in \mathfrak{R}^{r \times r}$  es una matriz diagonal  $\text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_r\}$  con los autovalores de  $(N-1){}^s\mathbf{R}$  en orden decreciente ( $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r$ ), cuyo valor es  $\lambda_r = \sigma_r^2$ . Las columnas de  ${}^s\mathbf{V}$  son los autovectores  $\mathbf{v}_r$  de los autovalores  $\lambda_r$  y marcan la dirección del nuevo espacio de componentes principales (CP).

En este caso, el ACP sólo se calcula para el conjunto de entrenamiento y los autovectores que contienen los coeficientes de los componentes principales de cada variable se utilizan para proyectar los conjuntos de comprobación y validación. Este proceso se aplica a la fuente de energía.

Los autovectores de  ${}^s\mathbf{V}$  se almacenan en una nueva matriz  ${}^s\mathbf{P} \in \mathfrak{R}^{M \times M}$  llamada *matriz de carga*. La matriz  ${}^s\mathbf{P}$  contiene los coeficientes de los componentes principales de cada variable  $M$  y se utiliza para proyectar los datos en un nuevo espacio de dimensión reducida utilizando (6).

$${}^s\mathbf{T} = {}^s\mathbf{Z} \times {}^s\mathbf{P} \quad (6)$$

donde,  ${}^s\mathbf{T} \in \mathfrak{R}^{N \times M}$  es la *matriz de puntuación* que contiene un nuevo componente  $\mathbf{t}_M$  proyectado sobre su respectivo componente principal  $\mathbf{p}_M$ . Normalmente, la matriz de datos se proyecta sobre el componente que contiene la mayor variabilidad. No existe correlación entre las nuevas variables proyectadas. Además, la calidad de un componente principal puede medirse de forma estándar como una proporción porcentual de la varianza total (Jolliffe and Cadima, 2016).

$$\pi_j = \frac{\lambda_j}{\sum_{j=1}^p \lambda_j} \times 100 \% \quad (7)$$

Se mide la calidad de cada componente principal obtenida a partir de los datos de la fuente renovable para observar la variabilidad que presentan y así elegir la de mayor variabilidad para proyectar los datos sobre ella. Para el conjunto de datos WT, su primera CP representa una variabilidad de 96,48 %.

La proyección se obtiene mediante:

$${}^s\mathbf{Trn} = \left[ \text{Trn}, {}^s\mathbf{T} \quad \text{Trn} \mathbf{P}_s(k+1) \right], \quad (8a)$$

$${}^s\mathbf{Chk} = \left[ \text{Chk}, {}^s\mathbf{T} \quad \text{Chk} \mathbf{P}_s(k+1) \right], \quad (8b)$$

donde  $\mathbf{P}_s(k+1)$  representa la potencia activa de la fuente de energía en un estado futuro. Por lo tanto, se forman conjuntos de entrenamiento (*trn*) y conjuntos de comprobación (*chk*) que se utilizarán en el proceso de aprendizaje del ANFIS.

<sup>1</sup>Por tanto  $\mathbf{U}^T \mathbf{U} = \mathbf{I} = \mathbf{V}^T \mathbf{V}$  con la matriz identidad  $\mathbf{I} \in \mathfrak{R}^{r \times r}$ . Las columnas de  $\mathbf{V}$  son los autovectores de  ${}^s\mathbf{Z}^T {}^s\mathbf{Z} \in \mathfrak{R}^{m \times m}$  asociados a sus autovalores no nulos. Del mismo modo, las columnas de  $\mathbf{U}$  son los autovectores de  ${}^s\mathbf{Z} {}^s\mathbf{Z}^T \in \mathfrak{R}^{n \times n}$  (Jolliffe and Cadima, 2016).

### 3. Modelo de predicción neuroborrosa

Se utilizan dos redes ANFIS para capturar el comportamiento del aerogenerador. El ANFIS utiliza conjuntos de entrenamiento y de comprobación para capturar la dinámica del sistema en el proceso de aprendizaje, permitiendo un modelo aceptable que prediga su comportamiento. En este proceso, el ANFIS mira el RMSE normalizado del conjunto de entrenamiento y del conjunto de comprobación para no sobreajustar sólo el primer conjunto, lo que haría que el FIS obtenido emitiera valores inapropiados para valores que no se han visto en el proceso de aprendizaje. De esta forma, se busca un término medio donde el aprendizaje sea general en ambos conjuntos (Chicaiza et al., 2022).

El ANFIS utilizado para modelar la instalación eólica utiliza como entrada la proyección de la velocidad del viento ( $w_s$ ) y la potencia activa ( $P_{WT}$ ) en el primer componente principal y como salida la potencia activa ( $P_{WT}$ ) en el siguiente instante ( $k + 1$ ).

En este caso, se aplica un método de agrupación sustractiva (*Subtractive Clustering, SC*) en el aprendizaje de ANFIS. SC estima los números iniciales y los centros de las funciones de pertenencia (*Memberships Functions, MFs*). Las MFs contienen los *parámetros antecedentes* de las reglas borrosas y caracterizan los conjuntos difusos. De esta manera, se aplica un método de aprendizaje híbrido que combina mínimos cuadrados y descenso de gradiente (Jang, 1993; Ghosh and Chakraborty, 2012); el descenso de gradiente para determinar la media, altura y anchura de las MFs gaussianas denotadas como *parámetros antecedentes* y los mínimos cuadrados para estimar los coeficientes de cada función polinómica de primer orden referida como *parámetros lineales consecuentes* para cada época o barrido. Los parámetros de la red ANFIS obtenidos durante el proceso de aprendizaje se presentan en la Tabla 2.

Tabla 2: Parámetros ANFIS

Descripción	ANFIS
Tipo MF:	Gaussiana
Método de optimización:	Híbrido
Tipo de MF de salida:	Lineal
<b>FIS</b>	<b>WT</b>
Número de MFs:	2
Número de reglas:	2
Rango de influencia	0,7
Número de épocas:	1500

Los conjuntos de entrenamiento y comprobación presentan errores pequeños, lo que indica que el aprendizaje fue general. Los índices de error obtenidos en el proceso de aprendizaje para el modelo y su tiempo de hermanamiento ( $t_{tw}$ ) se muestran en la Tabla 3.

Tabla 3: Índice nRMSE obtenido en el proceso de aprendizaje de ANFIS y su tiempo de actualización

RMSE mínimo de Entrenamiento & Comprobación		Aprendizaje ANFIS
FIS		WT
$nRMS E_{Train}$		0,2474
$nRMS E_{Check}$		0,2455
$t_{tw}(h)$		0,035

Una vez finalizado el proceso de aprendizaje ANFIS, se obtiene un Neurofuzzy  $FIS_{WT}$  que predice la potencia activa generada por la turbina eólica. Consiste en un FIS que contiene 2 reglas de tipo TS (Takagi and Sugeno, 1985):

$$\begin{aligned} \text{IF } x_1 \text{ is } F_{1j} \text{ and } x_2 \text{ is } F_{2j} \text{ and } x_i \text{ is } F_{ij}, \\ \text{THEN : } f_j(x) = g_{0j} + g_{1j}x_1 + \dots + g_{ij}x_i \end{aligned}$$

donde la descripción de cada uno de los parámetros que componen la regla está ampliamente descrita en (Chicaiza et al., 2022). Cada regla tiene unos *parámetros antecedente* y *consecuente*. Ambos parámetros fueron adaptados en el proceso de aprendizaje. La salida de cada regla es una combinación lineal de las variables de entrada sumada a un término constante. La salida final del sistema de inferencia borrosa es la media ponderada de cada salida de la regla.




Figura 2: Modelo neuroborroso para predecir la potencia activa de una turbina de viento.

La estructura FIS de los modelos predictivos para la turbina eólica se representa en la Fig. 2, donde la matriz  $WT P^{2 \times 1}$  es un vector que representa el primer componente del ACP calculado previamente en el caso de la estructura  $FIS_{WT}$ .

El proceso de validación compara la salida de  $FIS_{WT}$  con el conjunto de datos de validación (58 días). Además, este conjunto de validación no se utilizó en el proceso de aprendizaje de la red ANFIS.

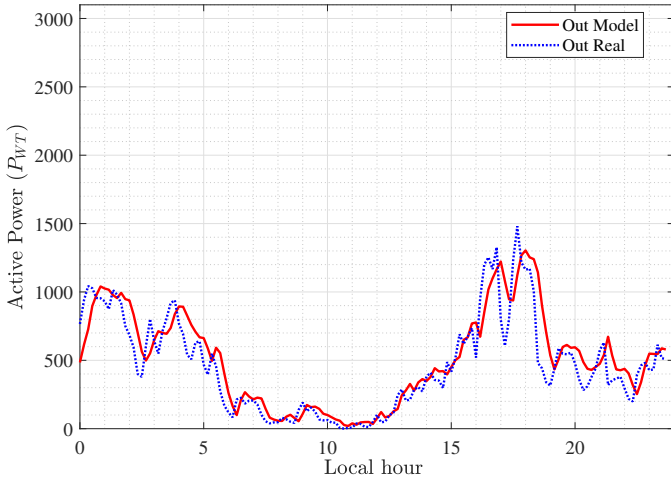


Figura 3: Validación del modelo de turbina eólica,  $FIS_{WT}$  salida del modelo vs datos reales.

La Fig. 3 muestra que  $FIS_{WT}$  es capaz de predecir el valor real de la potencia activa de la turbina de viento con  $R^2 = 0,85$ , como se muestra en la Tabla 4.

Tabla 4: Índice de validación de los modelos de predicción neuroborrosos para un día concreto.

Índices de error	Modelo $FIS_{WT}$
Media	46,49 [kW]
RMS E	162,97 [kW]
$R^2$	0,85
$t/muestreo$ (ms)	0.09553
$t/dia$ (s)	0.6689

Se ha realizado una segunda evaluación del modelo neuroborroso con el conjunto completo de validación del sistema, como se muestra en la Fig. 4. Esta evaluación considera los datos durante el día y la noche y sus índices de error, como se muestra en la Tabla 5.




Figura 4: Evaluación del modelo  $FIS_{WT}$  de la turbina de viento. Salida del modelo vs datos reales (Zoom de una región específica).

Las métricas de validación indican que el modelo de predicción neuroborroso tiene una buena precisión y capta la dinámica no lineal en todo el rango de funcionamiento (día y noche). Además, se incluye el tiempo medio de ejecución de cada muestra y el tiempo total de evaluación con todos los datos.

Obsérvese que el tiempo de ejecución por muestra es inferior a 1 milisegundo.

Tabla 5: Índice de validación de los modelos de predicción neuroborrosos para el conjunto de validación completo

Índices de error	Modelo $FIS_{WT}$
Media	32,49 [kW]
RMS E	291,39 [kW]
$R^2$	0,91
$t/muestreo$ (ms)	0.1004
$t/dia$ (s)	0.7025

#### 4. Selección de las previsiones de velocidad de viento

Para mejorar la precisión de las predicciones, se han asegurado diversos accesos a servicios y bases de datos de predicción de la velocidad del viento. Se ha ideado un método para seleccionar la predicción más fiable entre las opciones disponibles, centrándose en su aplicabilidad a la producción. Se han integrado medidas sencillas para fortificar el método frente a posibles fallos de ejecución.

La figura 5 ilustra el método integral junto con el modelo neuroborroso, haciendo hincapié en la integración de datos de varias fuentes mediante diversas técnicas. Se recomiendan múltiples conexiones a diferentes bases de datos, teniendo en cuenta las posibles fuentes de fallos.

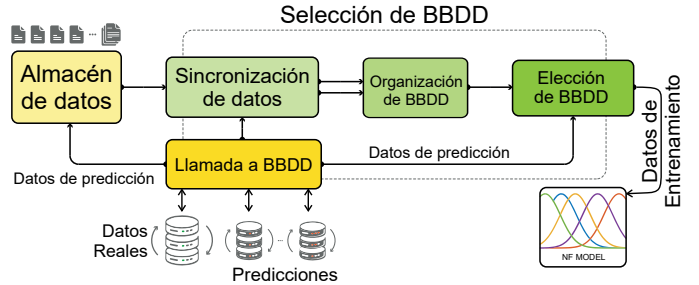


Figura 5: Esquema de selección meteorológica

El algoritmo comienza accediendo a los archivos de previsión de velocidad del viento almacenados en el mismo intervalo de tiempo que el intervalo actual (por ejemplo, entre las 11 AM y las 11:30 AM) dentro del intervalo de análisis, denotado como AH (por ejemplo, los últimos 10 días). Posteriormente, el módulo solicita los datos reales de velocidad del viento en el pasado para todo el intervalo AH a las API designadas y los segmenta en intervalos de longitud AH.

Los fallos durante la sincronización, a menudo debidos a previsiones incompletas, se abordan rellenando los segmentos que faltan con los primeros o los últimos valores disponibles. Esta medida correctiva garantiza la integridad del proceso de sincronización, facilitando un análisis preciso de las previsiones de velocidad del viento.

Una vez sincronizados los datos de predicción con los datos reales, se calcula el error medio de cada una de las fuentes en cada día, utilizando la Ecuación 9 para ordenarlas de menor a

mayor según el error cometido.  $E^i$  es el error medio de la fuente  $i$ ,  $S$  es el número de muestras,  $v^k$  es el valor real en la muestra  $k$ , y  $\bar{v}^k$  es el valor predicho de las fuentes de datos en la muestra  $k$ .

$$E^i = \frac{1}{S} * \sum_{k=1}^S |v^k - \bar{v}^k| \quad (9)$$

Una vez ordenadas todas las fuentes, se pasan al módulo siguiente, que elige la mejor fuente de datos para cada intervalo de tiempo. Por último, una vez ordenadas todas las fuentes de datos de previsión, se obtiene de esta lista la mejor disponible.

Para ello, se solicitan al módulo *Call for APIs* los datos actuales de velocidad del viento de todas las fuentes de previsión, y una vez que los datos están disponibles, se eligen los datos de la primera fuente que aparece en la lista ordenada. Esto significa que si sólo se pasa el nombre de la mejor fuente, y en algún momento no está disponible, el método se ejecuta igualmente.

Una vez generada la previsión, se envía al modelo neuroborroso para predecir la potencia producida por la turbina eólica. Si no se hubiera podido obtener la previsión de ninguna fuente, el algoritmo habría seleccionado la fuente con el error medio más bajo de los 40 días anteriores.

Por último, la Figura 6 muestra un ejemplo de la predicción de la velocidad del viento para un día determinado. En ella, además de reflejar lo anterior, se pueden observar dos bandas: la azul representa el error medio obtenido para cada muestra durante el horizonte de análisis, y la roja el error medio máximo en cada instante obtenido en el mismo horizonte de 40 días. Estas dos bandas se utilizarán para implementar en el futuro técnicas de control con incertidumbre en el MPC.

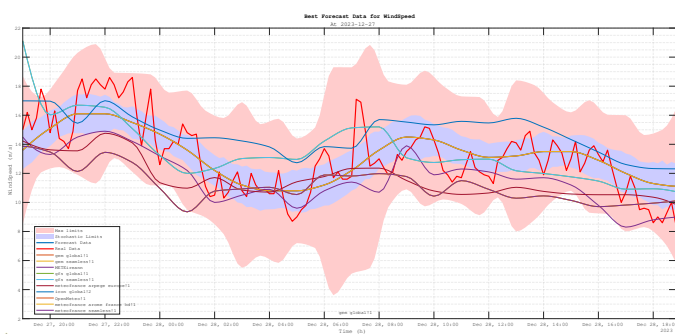


Figura 6: Ejemplo de previsión meteorológica

## 5. Conclusiones y trabajos futuros

En este trabajo se ha desarrollado un modelo de predicción neuroborroso para un generador eólico. Este modelo ha sido validado con datos reales, mostrando un buen resultado en la predicción de la dinámica no lineal en todo el rango de operación del sistema.

Además, se ha desarrollado un método para seleccionar la mejor predicción entre las diferentes predicciones disponibles.

Este método se ha desarrollado con la idea de que pueda ser llevado a producción, por lo que se han implementado varias medidas sencillas para asegurar que el método es robusto ante fallos que puedan ocurrir durante su ejecución. Como trabajo futuro, se propone utilizarlo para la implementación de técnicas de control óptimo con incertidumbre.

## Agradecimientos

Los autores agradecen a la Comisión Europea la financiación de este trabajo en el marco del proyecto DENiM. Este proyecto ha recibido financiación del programa de investigación e innovación Horizonte 2020 de la Unión Europea bajo el acuerdo de subvención n° 958339. Además, este trabajo también ha sido financiado por PID2022-142069OB-I00/AEI/10.13039/501100011033/ FEDER, UE a por la Junta de Andalucía (Consejería de Transformación Económica, Industria, Conocimiento y Universidades) por la ayuda de investigación Laboratorio de Ingeniería para la Sostenibilidad Energética y Medioambiental .<sup>EN</sup>GREEN”, referencia QUAL21 006 USE

The authors thank to the European Commission for funding this work under project DENiM. This project has received funding from the European Union’s Horizon 2020 research and innovation programme under grant agreement No. 958339. In addition, this work has also been funded by PID2022-142069OB-I00/AEI/10.13039/501100011033/ FEDER, UE and by the Junta de Andalucía (Consejería de Transformación Económica, Industria, Conocimiento y Universidades) through the research grant Laboratorio de Ingeniería para la Sostenibilidad Energética y Medioambiental .<sup>EN</sup>GREEN”, reference QUAL21 006 USE.

## Referencias

- Chicaiza, W. D., Machado, D. O., Len, A. J. G., Gonzalez, J. M. E., Alba, C. B., de Andrade, G. A., Normey-Rico, J. E., 2022. Neuro-fuzzy digital twin of a high temperature generator. *IFAC-PapersOnLine* 55 (9), 466–471, 11th IFAC Symposium on Control of Power and Energy Systems CPES 2022. DOI: <https://doi.org/10.1016/j.ifacol.2022.07.081>
- Ghosh, A., Chakraborty, M., 2012. Hybrid optimized back propagation learning algorithm for multi-layer perceptron. *International Journal of Computer Applications* 57.
- Gómez, J., Chicaiza, W. D., Escaño, J. M., Bordons, C., 2023. A renewable energy optimisation approach with production planning for a real industrial process: An application of genetic algorithms. *Renewable Energy* 215, 118933. DOI: <https://doi.org/10.1016/j.renene.2023.118933>
- Jang, J.-S., 1993. Anfis: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics* 23 (3), 665–685. DOI: 10.1109/21.256541
- Jolliffe, I. T., Cadima, J., 4 2016. Principal component analysis: a review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 374. DOI: 10.1098/RSTA.2015.0202
- Takagi, T., Sugeno, M., 1 1985. Fuzzy identification of systems and its applications to modeling and control. *IEEE transactions on systems, man, and cybernetics* SMC-15 (1), 116–132. URL: <https://doi.org/10.1109/tsmc.1985.6313399> DOI: 10.1109/tsmc.1985.6313399
- Zhong, Z., 2020. *Modeling, Control, Estimation, and Optimization for Microgrids: A Fuzzy-Model-Based Method*. CRC Press, New York, NY.



## Integration of artificial intelligence with automation for predictive maintenance in sustainable hydrogen production plants

Abiola, A O.\*, Segura, F M.\*, Andújar, J M., Barragán, A. J.

*Research Centre on Technology, Energy and Sustainability (CITES), University of Huelva, 21071 Huelva, Spain.*

**To cite this article:** Abiola, A O., et al. 2024. Integration of artificial intelligence with automation for predictive maintenance in sustainable hydrogen production plants. XIX Simposio CEA de Control Inteligente (2024)

### Abstract

Automation in modern industries is possible with the aid of sensors that measure signals needed for control, fault detection and decision making about a process. Such decisions include the time to perform predictive maintenance which is not possible when there is a failure in one of the sensors. Artificial intelligence techniques can be used to detect faults in a sensor and predict what its correct reading should be using signals from other sensors involved in the process. For accurate prediction, a signal from an alternative sensor, or a combination of signals from different sensors, should be selected that has a strong correlation with the signal to be predicted. In this study, to demonstrate the application of artificial intelligence in automation, an electrolyser operating in an automated process has been considered. A Deep Reinforcement Learning (DRL) algorithm was developed to select the best signal among others with the highest correlation coefficient of 0.99. The selected signal was then used in a long short-term memory (LSTM) to predict faulty temperature signals in the electrolyser. The root-mean-square error (RMSE) of the predicted signal was 0.1351.

**Keywords:** Automation, hydrogen technology; PEM electrolyser; predictive maintenance; artificial intelligence; reinforcement learning; neural network; long short-term memory (LSTM).

### 1. Introduction

Automation was first described in 1947 by Ford Motor Company as the enhanced usage of electromechanical, hydraulic, and pneumatic machinery in an attempt to reduce labour in the manufacturing sector (Noble, 1984).

In the paper by Sundari et al., (2021) it was concluded that automation is made possible through sensors, controllers, data storage and communications. The quality, production rate and customer satisfaction are enhanced through the realization of such automation process. These benefits of automation can further be enhanced by integration with artificial intelligence (AI), which is a form of digital technology that gives machines the ability to do what humans were normally doing such as making predictions and decisions (Spencer et al., 2021). In the paper, the author indicated that AI-enabled digital automation is growing to such a degree that data-based intelligent systems are re-organising and coordinating the whole sectors of the economy. Integration of automation with AI can be applied to various sectors of the economy such as manufacturing industries, agriculture, energy generation, healthcare, and many more. However, such integration is still new as indicated in a paper by (Zheng, 2023) who studied the application of AI in electrical automation and control engineering. In this present

study, the integration of automation and AI is further investigated within the field of renewable energy (RE) systems with a focus on proton exchange membrane (PEM) electrolyser. We conducted a search through selected databases namely ScienceDirect, MDPI and IEEE from 2001 to 2023. Keywords used were automation, control, sensors, AI and RE. Logical operators such as “OR”, “AND” as well as wildcard operator (\*) were used to narrow the search and the results shown in Figure 1.

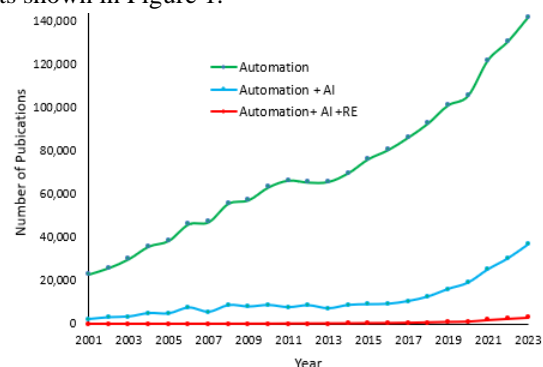


Figure 1: Analysis of publications on automation, artificial intelligence and application to renewable energy from 2001 to 2023 in the present work.

\*Corresponding author: [abiodun.abiola@alu.uhu.es](mailto:abiodun.abiola@alu.uhu.es); [francisca.segura@diesia.uhu.es](mailto:francisca.segura@diesia.uhu.es)  
Attribution-Non Commercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

The results of the database investigated, show that studies on the topic of automation have progressively increased over the years reaching as much as 141,982 publications in 2023, while those on the integration of automation with AI were initially slow in progression until 2017 when a spike occurred in number of academic works. However, when the application of these integrated technologies (automation and AI) was considered within the field of RE, it was observed that there is very limited number of studies done. Therefore, this study seeks to contribute to the body of knowledge on the integration of AI with automation and its application in the field of RE considering a PEM electrolyser as study case.

### 1.1 Application of artificial intelligence to electrolysers

In a paper by (Vasseur and Dunkels, 2010) one of the benefits of automation is for condition monitoring. This concept can be applied together with AI for the maintenance of electrolysers which are used within the field of RE technology to produce hydrogen. Rey et al. (2023) indicated that operation and maintenance cost is repeated along the lifespan of hydrogen-based microgrids and affect the replacement costs. Electrolysers used in such system can only function effectively to produce hydrogen at the desired parameters if its components do not fail during the period of operation. Failures can be avoided if they are detected early and resolved. To achieve this, there is a need to define an appropriate maintenance strategy. Predictive maintenance is one of such solution, but it often relies on data from sensors embedded in electrolysers which can also become faulty, resulting into false prediction of potential faults. Consequently, maintenance will not be performed at the right time and failure will occur. To address this problem, AI concept can be applied to make predictions on sensor readings based on data obtained from another instrument within the process. In this paper, authors develop a novel algorithm using Deep Reinforcement Learning (DRL) to select best feature(s) among measured data of the electrolyser, which can best predict on the target sensor data for predictive maintenance. The features are used as input into a type of deep neural network called long short-term memory (LSTM) to make prediction. This is depicted in Figure 2.

### 1.2 Previous works on intelligent condition monitoring

Regarding the scientific literature, very few authors focus their work on addressing the problem of maintenance in PEM electrolysers using AI. For example, Kumar et al. (2021) propose an artificial neural network based on LSTM capable of detecting and localizing faults at every time step without any pre-processing. But the artificial intelligence-based faults detection system is only applied to the power electronics of the electrolyser. Mohamed et al. (2022) used machine learning to predict up to eleven different parameters of the electrolytic cell using only four input parameters. Lee et al. (2023) presents a prognostics and health management (PHM) model based on machine learning to predict the load voltage of the electrolyser for the state of health information. The voltage is used as a state of health indicator which increases according to the time elapsed, and it is caused by the degradation of the electrolyser.

## 2. Materials and Method

In this paper, an intelligent predictive maintenance model is developed to predict sensor data in an PEM electrolyser for condition monitoring of the process and fault prediction. The model takes input data from other sensor(s) to be used for predicting a desired output. Hydrogen temperature is one of such desired data based on its importance in PEM electrolysers as discussed in (Chandesris et al., 2015). In the experimental study, results show that membrane degradation is strongly influenced by temperature.

Hence, considering the importance of temperature in the degradation of an electrolyser, this work uses hydrogen temperature as the sensor data to be predicted. With the predicted data, an intelligent predictive model allows monitoring and detection of any worsening condition.

### 2.1. Study case of a PEM electrolyser within an automated process

Experimental data from a previous work (Mancera et al., 2020), is used for the demonstration of the integration of AI with automation, focusing on a PEM electrolyser operating within a process. Layout of a section of the process is shown in Figure 3.

From Figure 3, the sensor data used for the current study are from the hydrogen pressure transmitter (PT112), hydrogen temperature transmitter (TT121), stack voltage (V) and cooling water temperature transmitter (TT105). Other resource needed is a computer equipped with an Intel(R) Core (TM) i5-8250U CPU @ 1.60GHz 1.80 GHz, 8.00 GB memory, 64-bit, x64-based processor. The operating system is Windows 11 Enterprise while software considered is MATLAB®.

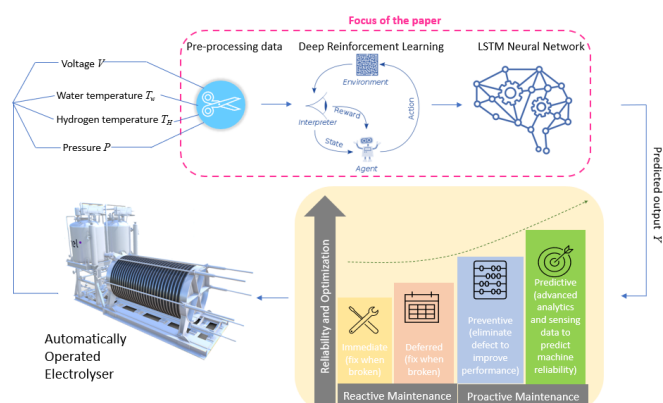


Figure 2: Illustration of problem statement and focus of the paper.

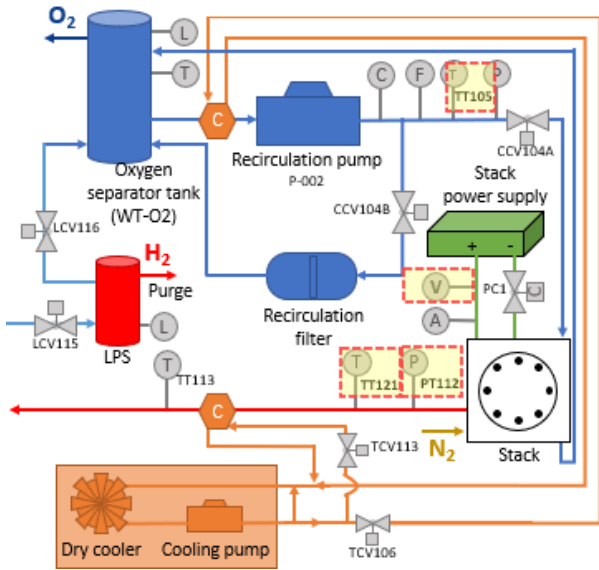


Figure 3: Layout of the automated process involving a PEM electrolyser. (Sensor data used for this study are highlighted as dashed squares).

### 2.2. Method. Phase 1. Pre-processing of input data

Sensor data is pre-processed by normalizing the experimental dataset to ensure that one feature does not affect the contribution of the other in the artificial intelligent models to be developed (Hudson et al., 2023).

Normalizing can be done in several ways. One alternative consists of ensuring that the range of all the features (data) are within 0 to 1. In another form called z-scoring, the input data are pre-processed using (1) where the data have a mean of 0 and standard a deviation of 1. For this study, z-scoring is used as shown in Figure 4, considering that it helps to stabilize and speed up network training (Hudson et al., 2023).

$$zScoring = \frac{Sensor\ Data(feature) - Mean}{Standard\ deviation} \quad (1)$$

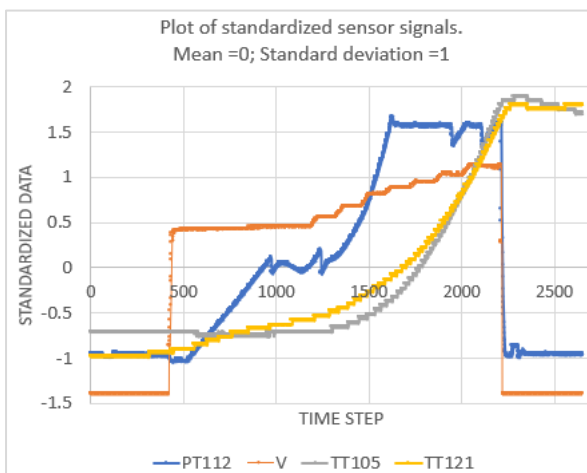


Figure 4: Normalised sensor data

### 2.3. Method. Phase 2: DRL for selecting features.

After pre-processing the data, a novel algorithm is developed based on DRL to select among the various sensor

data, the one that has the greatest correlation to hydrogen temperature sensor (TT121) which is to be predicted with minimum root-mean-squared-error (RMSE).

DRL is a subcategory of reinforcement learning within the parent body of AI (MathWorks®, 2019). The structure of the DRL algorithm is shown in Figure 5.

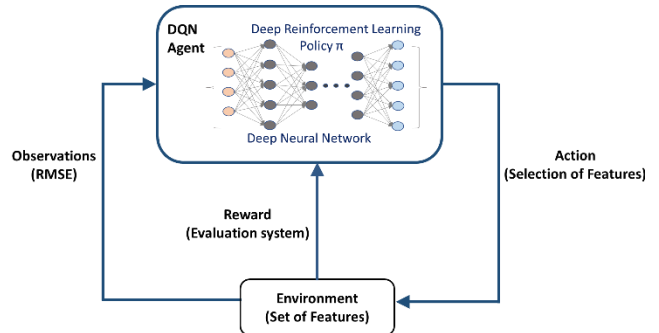


Figure 5: The concept of Deep Reinforcement Learning (DRL)

In the DRL model, an intelligent agent takes actions among several options to achieve an intended objective which is defined within the memory of the agent. The objective in this case is to determine which sensor data has the highest correlation to the hydrogen temperature.

The actions available to the agent are the selection of various sensor data called features, while the reward is a defined scalar amount added each time the agent chooses a feature that is more correlated to the hydrogen temperature compared to a previous selection. If a new action taken (selection) has less correlation compared to the previous, then the agent loses the reward. Before the agent begins the process of taking actions, it is first trained to identify increased or reduced correlation. An RMSE is the feedback to the agent, and it is calculated for each iteration using an internal neural network within the agent to determine the correlation values of each feature. The feedback of observations is used by the reinforcement learning policy within the agent to adjust the action and get the desired objective.

For the DRL agent, the entire feature set that can be selected to measure the correlation to the hydrogen temperature includes individual sensor data or a combination of two or more as follows: [PT112], [TT105], [V], [PT112 TT105], [PT112 V], [TT105 V] and [PT112 TT105 V]. When the agent finally determines which sensor data has the highest correlation to the hydrogen temperature, the data from the sensor will then be used as input to another AI model called long short-term memory (LSTM) neural network, which will eventually be used for predicting the hydrogen temperature in case its sensor fails during electrolyser operation; the concept of LSTM is discussed in section 2.5. Hence two AI models (DRL and LSTM) are developed and used together to predict the hydrogen temperature in the event of failure of its sensor.

Without the DRL it will be tedious and time-consuming to take each sensor data (feature), feed into the LSTM model and check the root-mean-square error (RMSE). This manual approach can be further complicated with features that number in the tens, hundreds or more from the dataset of electrolysers.

2.4. Method. Phase 3. Authors approach: DRL-based algorithm for feature selection

A novel DRL algorithm has been developed and implemented in MATLAB for feature selection as follows:

- Step 1 *Input data consisting of features: Pressure [PT112], Cooling water temperature [TT105], stack Voltage [V] and Hydrogen temperature [TT121].*
- Step 2 *Normalize each feature using: z-scoring.*
- Step 3 *Create the system of observation: RMSE*
- Step 4 *Obtain the matrix consisting of the subset of features. Subset 1 = [PT112]; Subset 2 = [TT105], Subset 3 = [V]; Subset 4 = [PT112, TT105], Subset 5 = [PT112, V]; Subset 6 = [TT105, V]; Subset 7 = [PT112, V, TT105].*
- Step 5 *For feature subset having two or more sensor data, obtain a single representation by computing the average.*
- Step 6 *Create DRL environment with observations and actions*
- Step 7 *Create a policy for the DRL agent to decide actions*
- Step 8 *Define discrete actions for the DRL agent. Each action is denoted by a scalar value (1 to 7) and represents the selection of each feature from the set of 7.*
- Step 9 *Define the reward for the agent for correct actions. Reward = 2 for correct; and -1 for incorrect actions*
- Step 10 *Train the DRL agent*
- Step 11 *For each stochastic action, RMSE is calculated as observations for each action. If (RMSE<sub>new</sub> < RMSE<sub>old</sub>) and (Reward > 0), then Store feature selected by the agent. Else Take action to select another feature from the subset. Endif*

The parameters used to train the DRL agent are listed in the Table 1. These were the optimal values that enabled the agent to be trained for recognizing its environment and take actions.

Table 1: Parameters used to train the DRL agent.

DRL Model Component	Type	Training Parameter	Value
DRL Agent policy	Deep Q-Network (MathWorks Inc, 2019)	Learning Rate	0.01
		Number of hidden layers	128
		Discount factor	0.99
		Batch size	64
		Initial epsilon	1
		Epsilon decay	0.005
		Epsilon min	0.01
Environment		Number of Training episodes	50
		Observation type	Continuous
		Observation dimension	[3,1]
		Action Type	Discrete
		Actions	[1,2,3,4,5,6,7]
		Observation Lower Limit	[-inf, -inf, 0]
		Observation Upper Limit	[inf, inf, inf]

The DRL algorithm has been developed using Simulink programming interface in MATLAB and shown in Figure 6. The training parameters were input into the DRL agent as well. After iterations, the feature with least RMSE was selected by the agent; which is the feature with highest correlation with TT121.

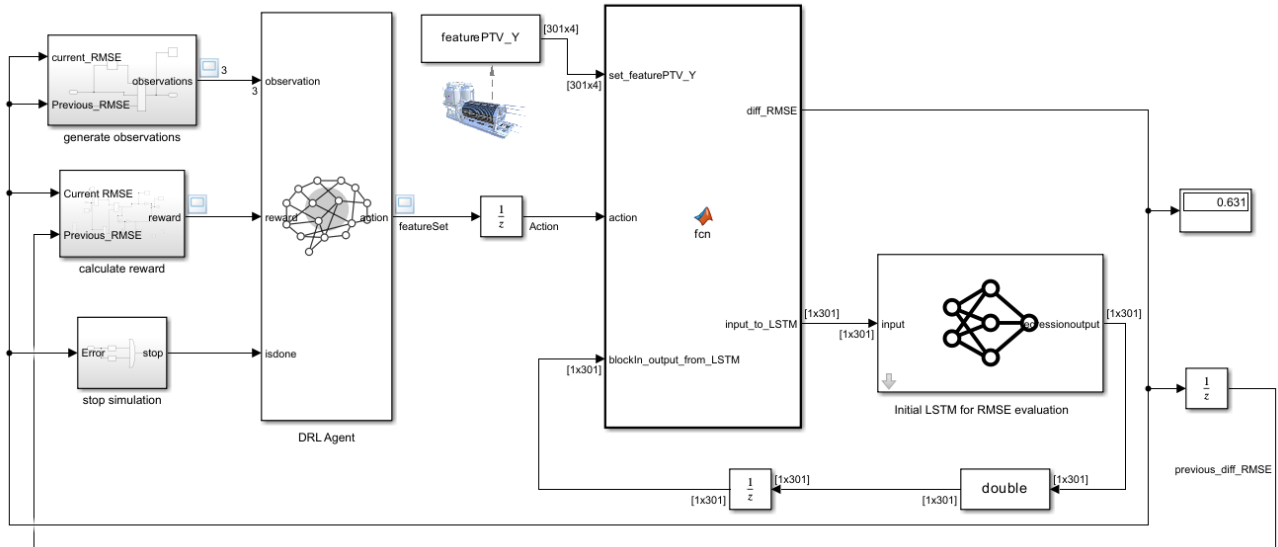


Figure 6: MATLAB programming environment for the developed DRL algorithm

2.5. Method Phase 4. Development of an intelligent predictive model for maintenance of the PEM electrolyser

After the DRL model has selected the feature with the highest correlation to the hydrogen temperature (TT121), the dataset of this feature is used to train another deep neural network called long-short-term-memory (LSTM) in Figure 7. After training the LSTM model, it can be used to predict the hydrogen temperature for maintenance in the event of failure of the existing sensor.

The concept of LSTM was introduced by (Hochreiter and Schmidhuber, 1997). LSTM neural networks belong to a type of recurrent neural network (RNN) which itself is a subcategory under deep neural network (DNN). The DNN is a type of supervised learning under machine learning and artificial intelligence concepts.

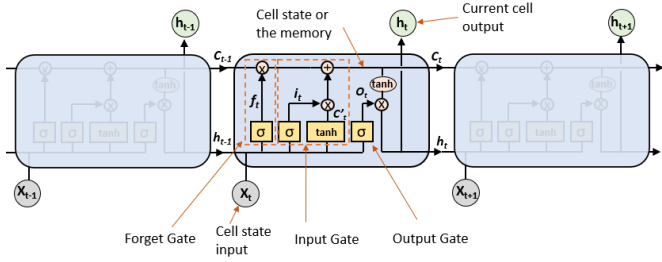


Figure 7: Conceptual design of LSTM neural network

LSTM neural network is configured from three gates where it can store both present and historical information after it has been trained with input data. The governing equations are:

$$\text{Forget Gate: } f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$\text{Input Gate: } i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\text{Output Gate: } O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$\text{Candidate valve } C'_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

$$\text{Cell State: } C_t = f_t * C_{t-1} + i_t * C'_t \quad (6)$$

$$\text{Hidden State: } h_t = \sigma_t * \tanh(C_t) \quad (7)$$

Where  $t$  is the time step,  $b$  is a bias added for each gate.  $W_f$ ,  $W_i$  and  $W_o$  are the weight of each gate.  $h_t$  and  $h_{t-1}$  are the output for the hidden layers in time steps  $t$  and  $t-1$  respectively.  $x_t$  is the input at time  $t$  and  $\sigma$  is the sigmoid activation function.

Based on these equations, an LSTM neural network was designed in MATLAB as shown in Figure 8.

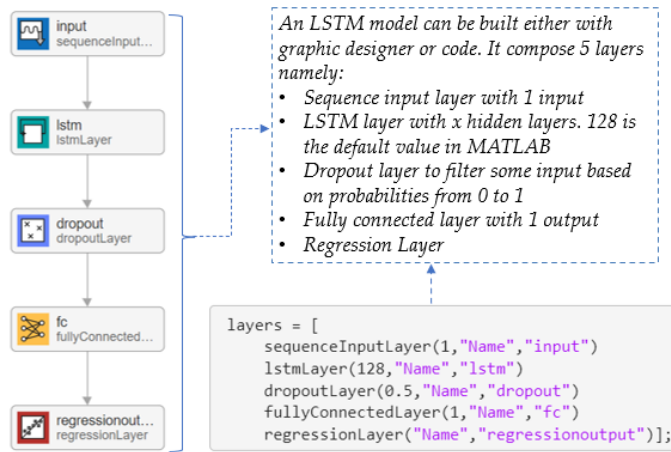


Figure 8: Conceptual design of LSTM neural network.

The flow chart of the entire process to deploy AI technique for the electrolyser is shown in Figure 9.

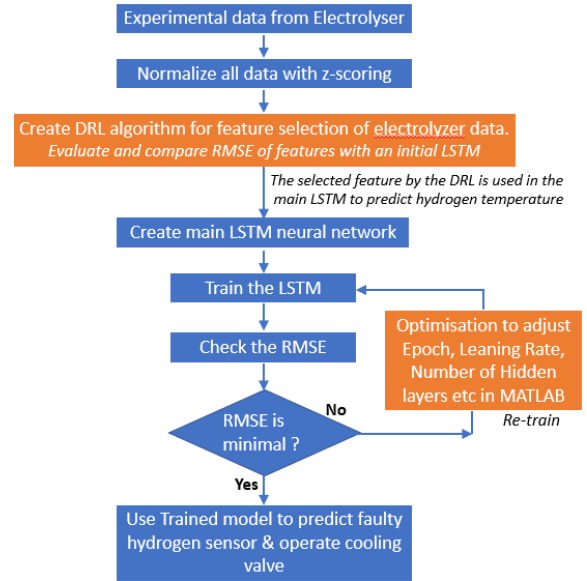


Figure 9: Flow chart for implementing intelligent maintenance in PEM electrolyser.

The physical implementation of the AI model designed for the electrolyser is shown Figure 10.

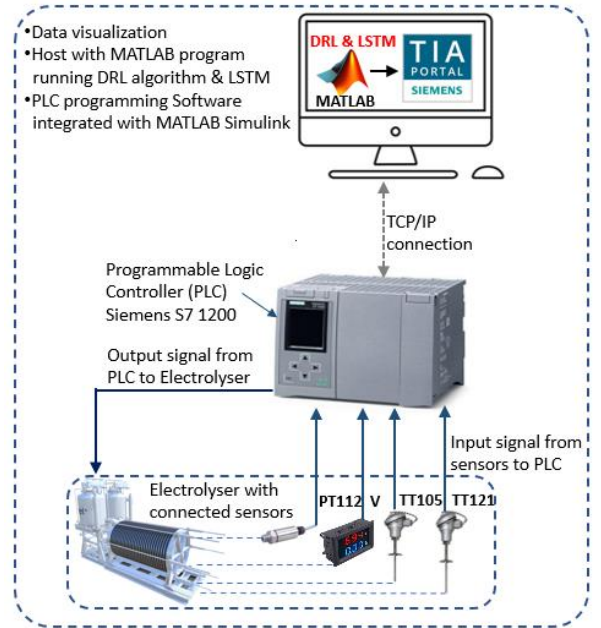


Figure 10: Overview for the entire system for the intelligent maintenance

### 3. Results

#### 3.1. Results of feature selection by the novel DRL algorithm.

Figure 11 shows a plot of the agent's action to select features, observations (RMSE) and reward received for each action. It is important to note that there is a time-step difference between the instant when the agent takes actions and when observations are made. The feature with highest correlation to TT121 is feature 2(TT105).

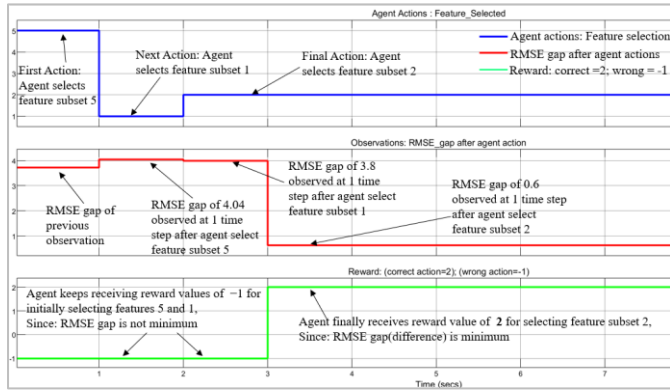


Figure 11: Plot of DRL model showing agent actions, RMSE and rewards.

Validation of the selection by the DRL is done using a correlation plot (Guyon and Elisseeff, 2003) between the various sensor data as shown in Figure 12 which confirms that TT105 has the highest correlation to TT121 with value of 0.99.

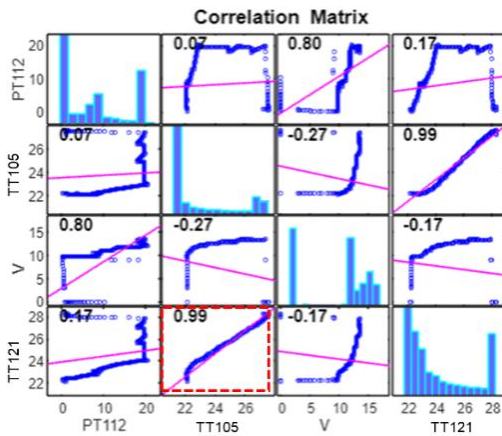


Figure 12: Correlation coefficient between various electrolyser data.

### 3.2. Training and testing of the LSTM neural network.

TT105 is used as input data and is divided into training (90%) and testing (10%) sets. There are several parameters that can influence the accuracy of the LSTM during training; to study them, a parametric analysis is performed as shown in Figure 13.

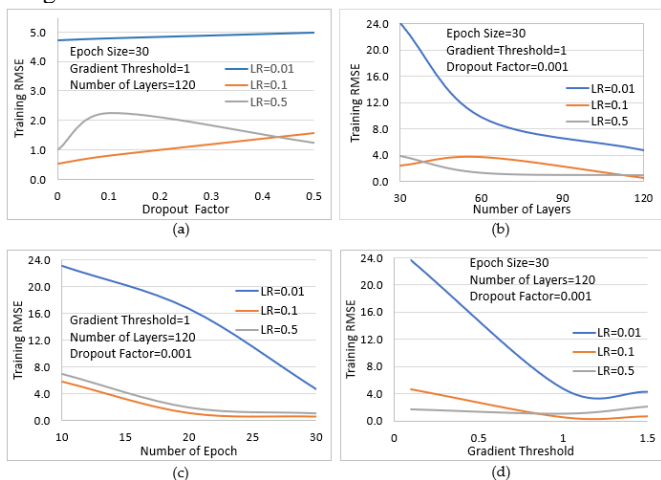


Figure 13: Optimisation of parameters to reduce RMSE during training of the LSTM. The effect of variation in (a) Dropout factor; (b) Number of layers; (c) Number of Epoch and (d) Gradient Threshold on the RMSE, are shown.

An optimum parameter set which gave an RMSE of 0.09 during training and 0.1351 during test is shown in Table 2.

Table 2: Parameters used to train the LSTM.

Training Parameter	Value	Training RMSE (LSTM)	Testing RMSE (Predicted variable TT121).
Learning Rate	0.1		
Number of layers	40		
Epoch	400	0.09	0.1351
Gradient Threshold	1		
Dropout	None (0)		

The trained LSTM network was tested by using it to predict the electrolyser hydrogen temperature (TT121). Figure 14 shows a plot of the actual and predicted sensor data.




Figure 14: Plot showing actual and predicted hydrogen temperature (TT121).

### 3.3. Accuracy validation and comparison with related papers.

Table 3 compares the authors' proposal with other proposals found in the literature in terms of RMSE.

Table 3: Comparison of testing RMSE with other papers

Study	Method Used	Testing RMSE
Authors' proposal	Hybrid of deep reinforcement learning (DRL) and long-short-term memory (LSTM)	0.1351
(Siraskar et al., 2023)	Reinforcement Learning hybridised with LSTM	0.5196*
Duhirwe et al., 2023	Hybrid of DRL with extreme gradient boosting	4.008
Pannakkong et al., 2023	Reinforcement Learning based on Double DQN	0.3956*

\*RMSE is obtained from:  $\sqrt{\text{mean squared error}(MSE)}$

## 4. Discussion

The developed AI model (novel DRL algorithm and LSTM) have been able to select the cooling water temperature sensor (TT105) as the best feature with the highest correlation (0.99) to the hydrogen temperature sensor (TT121). This is shown in Figures 11 and 12. The DRL algorithm saves computation time

since it uses a small sample of data for feature selection and also a single representation of features having multiple sensor data as indicated in step 5 of section 2.4. Hence it can be extended for cases with tens or hundreds of sensor data. Furthermore, the LSTM was able to use the cooling water temperature of the PEM electrolyser to predict the hydrogen temperature with an RMSE value of 0.1351 which is good compared to other papers shown in Table 5.

A limitation of the AI model is that it needs to be re-trained to adapt to a different hydrogen system, such as an alkaline electrolyser or fuel cell with different physical phenomena.

## 5. Conclusions

This proposal shows that integration of AI with automation can indeed be beneficial in various fields such as in RE technologies. A case study was demonstrated with a PEM electrolyser in which a hybridized AI model (DRL & LSTM) was integrated within an automated process for condition monitoring and forecasting critical process data (hydrogen temperature) for use in predictive maintenance of the system.

Due to the limitation discussed in the previous section as regards the need to retrain the AI model for a different hydrogen system, further work is needed to develop models that can be adapted to these changes.

## Acknowledgement

This work has been partially carried out thanks to the support of (1) Grant Ref: PID2020-116616RB-C31 and (2) Grant Ref. RED2022-134588-T found by MICIU/AEI /10.13039/501100011033.

## References

Chandesris, M., Médeau, V., Guillet, N., Chelghoum, S., Thoby, D., Fouda-Onana, F., 2015. Membrane degradation in PEM water electrolyser. *International Journal of Hydrogen Energy* 40, 1353–1366. <https://doi.org/10.1016/j.ijhydene.2014.11.111>

Duhirwe, P.N., Ngarambe, J., Yun, G.Y., 2023. Energy-efficient virtual sensor-based deep reinforcement learning control of indoor CO<sub>2</sub> in a kindergarten. *Frontiers of Architectural Research* 12, 394–409. <https://doi.org/10.1016/j.foar.2022.10.003>

Guyon, I., Elisseeff, A., 2003. An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research* 3, 1157–1182.

Hochreiter, S., Schmidhuber, J., 1997. Long Short-Term Memory. *Neural Computation* 9, 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

Hudson, M., Martin, B., Hagan, T., Demuth, H.B., 2023. *Deep Learning Toolbox™ User's Guide*. MathWorks Inc, Natick, Massachusetts.

Kumar, R., Kumar, S., Cirrincione, G., Cirrincione, M., Guilbert, D., Ram, K., Mohammadi, A., 2021. Power Switch Open-Circuit Fault-Diagnosis Based on a Shallow Long-Short Term Memory Neural Network. *Energy Conversion Congress and Exposition*. Institute of Electrical and Electronics Engineers Inc., 483–488. <https://doi.org/10.1109/ECCE47101.2021.9595018>

Lee, H., Gu, J., Lee, B., Cho, H.-S., Lim, H., 2023. Prognostics and health management of alkaline water electrolyser. *Energy and AI* 13, 100251. <https://doi.org/10.1016/j.egyai.2023.100251>

Mancera, J.J.C., Manzano, F.S., Andújar, J.M., Vivas, F.J., Calderón, A.J., 2020. An optimized balance of plant for a medium-size PEM electrolyser. *Electronics* 9. <https://doi.org/10.3390/electronics9050871>

MathWorks Inc, 2019. *Reinforcement Learning Toolbox™ User's Guide R2023a*. MathWorks Inc, Natick, Massachusetts.

Mohamed, A., Ibrahim, H., Yang, R., Kim, K., 2022. Optimization of Proton Exchange Membrane Electrolyser Cell Design Using Machine Learning. *Energies* 15. <https://doi.org/10.3390/en15186657>

Noble, D., 1984. *Forces of Production: A Social History of Industrial Automation*. Knopf, New York.

Pannakkong, W., Vinh, V.T., Tuyen, N.N.M., Buddhakulsomsiri, J., 2023. A Reinforcement Learning Approach for Ensemble Machine Learning Models in Peak Electricity Forecasting. *Energies* 16. <https://doi.org/10.3390/en16135099>

Rey, J., Segura, F., Andújar, J.M., Ferrario, A.M., 2023. The Economic Impact and Carbon Footprint Dependence of Energy Management Strategies in Hydrogen-Based Microgrids. *Electronics* 12. <https://doi.org/10.3390/electronics12173703>

Siraskar, R., Kumar, S., Patil, S., Bongale, A., Kotecha, K., 2023. Reinforcement learning for predictive maintenance. *Artificial Intelligence Review*. <https://doi.org/10.1007/s10462-023-10468-6>

Spencer, D., Cole, M., Joyce, S., Whittaker, X., Stuart, M., 2021. Digital automation and the future of work. European Union, Brussels.

Sundari, V.K., Nithyashri, J., Kuzhaloli, S., Subburaj, J., Vijayakumar, P., Jose, P.S.H., 2021. Comparison analysis of IoT based industrial automation and improvement of different processes - Review. *Materials Today: Proceedings*. Elsevier Ltd, 2595–2598. <https://doi.org/10.1016/j.matpr.2020.11.338>

Vasseur, J.-P., Dunkels, A., 2010. *Industrial Automation. Interconnecting Smart Objects with IP*. Elsevier, 325–333. <https://doi.org/10.1016/B978-0-12-375165-2.00021-1>

Zheng, W., 2023. Research on the Application of Intelligent Technology in Electrical Automatic Control Engineering. *4th International Conference for Emerging Technology*. Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/INCET57972.2023.10169979>





## Hacia la gestión de comunidades energéticas con Aprendizaje por Refuerzo

Arnay del Arco, R.<sup>a</sup>, Riverón-Miranda, I.<sup>a</sup>, Hamilton-Castro, A.<sup>a</sup>, Torres-Álvarez, S.<sup>a</sup>, González-Cava, J.M.<sup>a</sup>, Castilla, I.<sup>a</sup>, González Díaz, B.<sup>b</sup>, Méndez-Pérez, J.A.<sup>a,\*</sup>.

<sup>a</sup> Departamento de Ingeniería Informática y de Sistemas, Universidad de La Laguna, Avda. Astrof. Francisco Sánchez, S/N, 38206, La Laguna, Tenerife, España.

<sup>b</sup> Departamento de Ingeniería Industrial, Universidad de La Laguna, Avda. Astrof. Francisco Sánchez, S/N, 38206, La Laguna, Tenerife, España.

**To cite this article:** Arnay del Arco et al., 2024. Towards the management of energy communities with Reinforcement Learning. XIX Simposio CEA de Control Inteligente (2024)

### Resumen

En este documento se presenta el diseño de un trabajo en curso para la implementación de un sistema para la gestión de energía en comunidades energéticas. La gestión de estos sistemas tiene una complejidad extraordinariamente elevada que ha sido generalmente resuelta con sistemas basados en reglas o con métodos de programación lineal entera mixta (MILP). Sin embargo, una de las herramientas que surge con un alto potencial en este contexto son los métodos de aprendizaje por refuerzo (RL). La propuesta que se presenta aquí describe el diseño de un algoritmo Deep Q-Network (DQN) para la gestión de comunidades energéticas. Se presentan los elementos básicos que conforman la metodología que se seguirá, tanto la definición del estado como las acciones y la función de valor-acción.

*Palabras clave:* Sistemas de energía, Comunidad energética, EMS, Aprendizaje por refuerzo, BMS.

### Towards the management of energy communities with Reinforcement Learning

#### Abstract

This paper presents the design of an ongoing work for the implementation of a system for energy management in energy communities. The management of these systems is extraordinarily complex, which has generally been solved with rule-based systems or MILP optimization methods. However, one of the tools that emerges with high potential in this context is reinforcement learning (RL) methodology. The proposal presented here describes the design of a Deep Q-Network (DQN) algorithm for the management of energy communities. The basic elements that define the methodology to be followed are presented, both the definition of the state, the actions, and the value-action function.

*Keywords:* Energy systems, Energy community, EMS, Reinforcement learning, BMS.

## 1. Introducción

Las comunidades energéticas se han convertido en actores clave en la transición energética hacia un modelo más sostenible. Estas agrupaciones de ciudadanos, empresas y entidades locales se unen para gestionar de forma conjunta la producción, el consumo y la distribución de energía renovable en su entorno (Figura 1). La Ley 24/2013, de 26 de diciembre, del Sector Eléctrico en España define en su artículo 6 el concepto de comunidad energética.

En (Barabino et al., 2023) se hace una revisión del estado del arte sobre Comunidades Energéticas con especial atención al modelado de los distintos elementos que las componen. En

el trabajo se incluye también una descripción detallada de los modelos de negocio y las funciones objetivo implicadas.

Los sistemas de almacenamiento de energía en baterías (BESS) son un componente clave para las comunidades energéticas, ya que permiten almacenar el excedente de energía renovable generado localmente y utilizarlo cuando sea necesario, mejorando así la autosuficiencia energética y la sostenibilidad de estas comunidades. La gestión eficiente de estos sistemas es crucial para maximizar sus beneficios y optimizar su funcionamiento. Las posibilidades de explotación de estos sistemas de almacenamiento se enfocan a la optimización del autoconsumo, el arbitraje energético (compra y venta de energía para maximizar los beneficios) y la provisión de servicios a la red.

\*Autor para correspondencia: jamendez@ull.edu.es

Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)




Figura 1. Diagrama esquemático de una comunidad energética.

La gestión del flujo de energía en estos sistemas supone un reto de complejidad elevada por la cantidad de variables, restricciones e interacciones presentes. Las metodologías más comunes para el desarrollo de los sistemas de gestión de energía (EMS) se han basado sobre todo en optimizadores MILP (programación lineal entera mixta). Ejemplos de aplicaciones de MILP pueden verse en (Pasqui et al., 2023), (Cosic et al., 2021) y (Stentati, Paoletti y Vicino, 2023). Otra opción usada para la gestión son los sistemas basados en lógica borrosa (Riverón et al., 2024). En todos estos trabajos se pone de relieve el potencial de este tipo de estrategias para reducir los costes de operación de la comunidad y su contribución a la reducción de emisiones de CO<sub>2</sub>.

Sin embargo, la complejidad de estos sistemas conectados entre sí, con un número elevado de ligaduras y con múltiples interacciones, puede comprometer el rendimiento de estrategias basadas en optimización clásica o en sistemas basados en reglas. En este punto es donde surgen métodos de inteligencia artificial para facilitar tanto el modelado de los sistemas (Díaz-Longueira et al., 2023) como la gestión de la energía (Alam et al., 2022) (Lee et al., 2024).

De las propuestas basadas en inteligencia artificial para la gestión de la energía, las más prometedoras son las que se basan en algoritmos de Aprendizaje por refuerzo (Reinforcement Learning, RL). Recientemente han aparecido algunos trabajos que muestran resultados preliminares de mucho interés. En este sentido son destacables los resultados que aparecen en (Binyamin, Slama Y Zafar, 2024) donde se propone un método de gestión aplicado a viviendas familiares. En (Li et al., 2024) se propone el algoritmo CuEMS para microrredes optimizando beneficios y comfort de los usuarios.

Un trabajo más directamente enfocado a la gestión en comunidades energéticas es publicado en (Palma et al., 2024). En este estudio se muestra, a través de simulaciones realizadas en diversos contextos, que el rendimiento del algoritmo RL propuesto es superior a los controladores basados en reglas que marcan el estado del arte actual.

En la mayoría de los trabajos considerados el estado del sistema se define mediante medidas en el instante actual de las variables de interés. Parece razonable que desarrollar un sistema de gestión que además sea capaz de contar con información del comportamiento de las variables en el futuro puede ser un punto de mejora importante.

La propuesta de trabajo que se quiere desarrollar persigue combinar la gestión inteligente en la que se incorpore información de valor sobre la futura evolución de las variables. Además, a diferencia de las estrategias existentes basadas en algoritmos RL, en este trabajo se pretende incluir como acción el desplazamiento de carga en el sistema, para favorecer la

gestión de la demanda y así obtener un rendimiento aún mayor del sistema global.

## 2. Metodología

### 2.1. Aprendizaje por refuerzo

El aprendizaje por refuerzo (RL) es un área del aprendizaje automático que se ocupa de diseñar un agente inteligente que toma acciones en un entorno dinámico para maximizar una recompensa acumulada. El objetivo del agente es aprender la mejor política para maximizar la función de recompensa a largo plazo.

La Figura 2 muestra el esquema de interacciones de un sistema de aprendizaje por refuerzo. Con esta estructura el agente va interaccionando con el entorno mediante las acciones que va decidiendo,  $a_t$ , a partir de los estados observados,  $s_t$ . El aprendizaje del agente se realiza para maximizar la suma acumulada de recompensas,  $R_t$ , durante su evolución en el tiempo.

Existen diferentes opciones el algoritmo de entrenamiento del sistema, entre las más comunes se encuentran los algoritmos Q-learning, SARSA y Deep Q-Network (DQN). En este trabajo se tomará el algoritmo DQN que es una variante del algoritmo Q-Learning basado en redes neuronales profundas para aproximar la función de valor-acción (Q). La función  $Q(s,a)$  devuelve la recompensa que el agente recibirá al ejecutar la acción  $a$  desde el estado  $s$ . El uso de redes neuronales profundas permite a DQN superar algunas de las limitaciones asociadas al Q-Learning tradicional, como los problemas cuando la dimensionalidad es elevada, y las dificultades para aprender políticas efectivas en entornos complejos con espacios de estado y acción grandes.

### 2.2. Diseño del sistema de gestión inteligente de energía

En este estudio se considerará una tipología de comunidad energética en la que sólo se cuenta con un miembro generador que cuenta con una instalación fotovoltaica con sistemas de almacenamiento de baterías y conexión a la red. El problema que se quiere resolver se refiere a la gestión de la batería para conseguir un incremento en los beneficios del sistema en términos de costes de operación y maximización de la energía. Asimismo, se considerará un escenario en el que es posible una gestión de la demanda, de tal modo que el sistema inteligente de gestión de demanda debe proporcionar una estimación del desplazamiento de carga a considerar en cada instante.

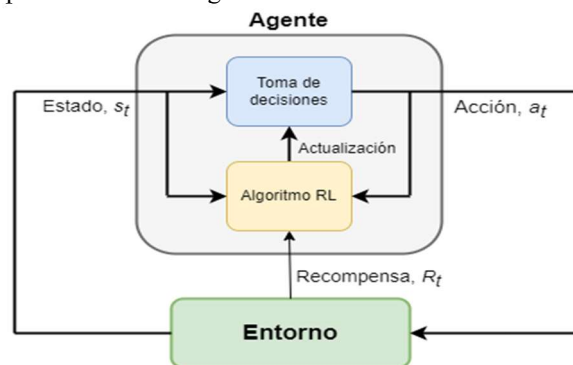


Figura 2: Esquema general de un sistema de aprendizaje por refuerzo.

El funcionamiento del algoritmo DQN se basa en la maximización de la función de valor-acción  $Q(s, a; \vartheta)$ , donde  $s$  es el estado del sistema,  $a$  representa las acciones del sistema y  $\vartheta$  son los parámetros de la red neuronal que implementa la función  $Q$ . La función de valor-acción en el instante  $t$  viene definida por la siguiente expresión:

$$Q(s_t, a_t; \vartheta) = R_t + \max_{a_{t+1}} Q(s_{t+1}, a_{t+1}; \vartheta') \quad (1)$$

En esta expresión interviene una red neuronal principal, con matriz de parámetros  $\vartheta$ , que es usada para estimar los valores  $Q$  asociados al estado  $s$  y acción  $a$  actuales,  $Q(s, a; \vartheta)$ . Se usa segunda red neuronal objetivo (target Neural Network), parametrizada por  $\vartheta'$ , con la misma arquitectura que la red principal y cuyo fin es aproximar los valores- $Q$  del estado destino  $s_{t+1}$  y la siguiente acción  $a_{t+1}$ .

Es interesante destacar que el aprendizaje tiene lugar en la red principal. La red objetivo no se actualiza durante un conjunto de iteraciones, transcurridas las cuales, los parámetros de la red principal se copian a la red objetivo. De esta manera se facilita que el aprendizaje se transmita de la red principal a la otra, con lo cual se mejorará la exactitud en las estimaciones calculadas por la red objetivo.

En la expresión (1), el término  $R_t$  representa la recompensa asociada a la acción  $a_t$ . El espacio de acción considerado consta de dos variables. Por un lado, se plantea el control de carga-descarga de energía que implica la selección de una operación de carga-descarga y la determinación de la intensidad de esa carga o descarga. Para ello se define la variable asociada,  $a^1$ , como una variable dentro rango continuo  $[-1, 1]$ . Para la acción de descarga se tomarían valores desde  $-1$  a  $0$ , mientras que la acción de carga desde  $0$  a  $1$ . Por otra parte, se considerará como segunda acción,  $a^2$ , el valor de desplazamiento de carga en el sistema, que se refiere a qué porcentaje de la carga sería conveniente desplazar a otro intervalo horario para mejorar el rendimiento del sistema (load shifting).

La recompensa  $R_t$  en nuestro sistema viene definida por la siguiente expresión

$$R_t = Rev_t^g - Cost_t^g - Cost_t^b \quad (2)$$

donde  $Rev_t^g$  representa los beneficios por la venta de energía a la red en el periodo  $t$ ,  $Cost_t^g$  representa los costes de energía comprada a la red y  $Cost_t^b$  representa los costes de uso de la batería.

En cuanto al estado que define el sistema, se ha considerada un hipotético escenario de precios variables en el que las variables que definirían las acciones son

- $G_t$  (kWh), energía generada en el periodo considerado.
- $L_t$  (kWh), demanda de energía en el periodo considerado.
- $\hat{G}_{24}$  (kWh), predicción de generación para las próximas 24h.
- $\hat{L}_{24}$  (kWh), predicción de demanda para las próximas 24h.
- $C_t$  (€/kWh), coste de la energía tomada desde la red.
- $V_t$  (€/kWh), precio de venta de electricidad a la red.
- $SOC$  (%), estado de carga de la batería.

Como se observa, se incluyen variables de predicción de generación y demanda en un plazo de 24h para aumentar la información necesaria para el buen uso de la batería y el desplazamiento de las cargas.

### 3. Desarrollo del trabajo

El problema será resuelto en simulación usando *Python* y las librerías correspondientes de *TensorFlow* y *PyTorch* para implementación de los algoritmos de aprendizaje. El muestreo que se considerará en este trabajo es de 3h (8 muestras por día). Y se considerará un escenario de simulación de 7 días para el entrenamiento del sistema de gestión. Una vez validada la propuesta, se ensayará en una planta piloto de 60kWp con capacidad de almacenamiento en baterías de Ion-Litio de 22kWh. Esta planta formará parte de una comunidad energética que se está desarrollando en el marco del proyecto europeo SATComm (Sustainable Atlantic Communities). El objetivo será desplegar la estrategia desarrollada y compararla con otras propuestas de gestión estándar.

### Agradecimientos

Este trabajo está siendo parcialmente financiado por el proyecto Sustainable Atlantic Communities (Satcomm, EAPA\_0019/2022) cofinanciado por la Unión Europea a través de la convocatoria Interreg Atlantic Area.

### Referencias

- Palma, G., Guiducci, L., Stentati, M., Rizzo, A. and Paoletti, S. 2024. Reinforcement Learning for Energy Community Management: A European-Scale Study. *Energies*, 17, 1249. DOI: 10.3390/en17051249.
- Stentati, M., Paoletti, S., Vicino, A., 2023. Optimization and Redistribution Strategies for Italian Renewable Energy Communities. *IEEE EUROCON 2023 - 20th International Conference on Smart Technologies*.
- Lee S., Seon, J., Ghyu Sun, Y., Hyun Kim, S., Kyeong, C., In Kim, D., and Young Kim, J., 2024. Novel Architecture of Energy Management Systems Based on Deep Reinforcement Learning in Microgrid. *IEEE Transactions on Smart Grid*, Vol. 15, No. 2.
- Binyamin, S.S., Ben Slama, S.A. and Zafar, B. Artificial intelligence-powered energy community management for developing renewable energy systems in smart homes. *Energy Strategy Reviews*. 51 (2024) 101288.
- Diaz-Longueira, A., Timiraos, M., Mendez Perez, J.A., Casteleiro-Roca, J.L. and Jove, E., 2023. Daily Accumulative Photovoltaic Energy Prediction Using Hybrid Intelligent Model. In: García Bringas, P., et al. *Hybrid Artificial Intelligent Systems*. HAIS 2023. Lecture Notes in Comp Science, vol 14001. Springer, Cham. DOI: 10.1007/978-3-031-40725-3\_49.
- Alam, M., Rahman, H., Ahmed, F., Zaman, Chowdhury, M. and Jang, Y.M., 2022. Deep learning based optimal energy management for photovoltaic and battery energy storage integrated home micro-grid system. *Scientific Reports*, 12:15133, Nature.
- Riverón, I., Gómez, J.F., González, B. and Méndez, J.A., 2024. An intelligent strategy for hybrid energy system management. *Trends in Renewable Energy and Power Quality*. Chapter 29. Cambridge Scholars Publishing. ISBN (13): 978-1-5275-9433-3.
- Pasqui, M., Felice A., Messagie, M., Coosemans, T., Bastianello, T.T., Baldi, D., Lubello, P., Carcasci, C., 2023. A new smart batteries management for Renewable Energy Communities. *Sustainable Energy, Grids and Networks* 34, 101043.
- Li, J., Jiang, Z., Chen, Z., Liu, J., Cheng, L., 2024. CuEMS: Deep reinforcement learning for community control of energy management systems in microgrids. *Energy & Buildings* 304, 113865.
- Cosic, A., Stadler, M., Mansoor, M., Zellinger, M., 2021. Mixed-integer linear programming based optimization strategies for renewable energy communities. *Energy* 237, 121559.
- Barabino, E., Fioriti, D., Guerrazzi, E., Mariuzzo, I., Poli, D., Raugi, M., Razaei, E., Schito, E. and Thomopoulos, D., 2023. Energy Communities: A review on trends, energy system modelling, business models, and optimisation objectives. *Sustainable Energy, Grids and Networks* 36 (2023) 101187.

## Ajuste multiobjetivo de PIDs robustos para el control de temperatura de una pila tipo PEM

Veyna, U.<sup>a</sup>, Blasco, X.<sup>a,\*</sup>, Herrero, J.M.<sup>a</sup>, Pajares, A.<sup>a</sup>, Ramos, C.<sup>a</sup>

<sup>a</sup>Instituto Universitario de Automática e Informática Industrial. Universitat Politècnica de València, 46022, Valencia, España.

### Resumen

Este trabajo describe el diseño de un control PID multibucle robusto de las temperaturas de una pila PEMFC. Se utiliza un enfoque de optimización multiobjetivo, considerando incertidumbre en los parámetros del modelo dinámico. Se define un nuevo indicador de calidad en el proceso de optimización, la eficiencia robusta utópica, para ajustar los parámetros del PID. Para comparar este enfoque, se abordan los diseños alternativos basados en la optimización del peor caso y el desempeño del sistema en el modelo nominal. Los resultados muestran que los controladores sintonizados en base a la eficiencia robusta utópica exhiben un mejor equilibrio entre el desempeño óptimo sobre el modelo nominal y la robustez en presencia de incertidumbre.

*Palabras clave:* Ajuste robusto de controladores, Optimización multiobjetivo, Control de temperatura PEMFC

### Multi-objective tuning of robust PIDs for temperature control of a PEMFC stack

#### Abstract

This work describes the design of a robust multi-loop PID control of the temperatures of a PEMFC stack. A multi-objective optimization approach is used, considering uncertainty in the dynamic model parameters. A new quality indicator in the optimization process, the utopian robust efficiency, is defined to tune the PID parameters. To compare this approach, alternative designs based on worst-case optimization and system performance in the nominal model are addressed. The results show that controllers tuned based on the utopian robust efficiency exhibit a better balance between optimal performance over the nominal model and robustness in the presence of uncertainty.

*Keywords:* Robust controller tuning, Multi-objective optimization, PEMFC temperature control

## 1. Introducción

Debido a los problemas de calentamiento global y contaminación, existe un interés creciente en el uso de sistemas basados en pilas de combustible. Uno de los posibles campos de aplicación es el uso de sistemas combinados de calor y energía. Estos sistemas producen electricidad y calor (cogeneración) para el suministro de energía en el sector residencial (micro-CHP) (Ellamla et al., 2015). La pila de combustible de membrana de intercambio de protones (PEMFC) puede ser el motor principal de un micro-CHP. La ventaja de estos sistemas es la posibilidad de aprovechar la energía térmica producida como resultado de la generación eléctrica mejorando notablemente el rendimiento global (Navarro Giménez et al., 2019).

La vida útil de la pila y la eficiencia general del sistema micro-CHP dependen en gran parte del control adecuado de las temperaturas. Estos sistemas pueden utilizar un sistema de refrigeración para enfriar la pila y mantener su temperatura en

su valor óptimo. La durabilidad, la fiabilidad y la eficiencia energética de la pila dependen en gran medida del diseño correcto de este sistema de control (Huang et al., 2018).

En sistemas no lineales es útil diseñar controladores utilizando técnicas de optimización. En esta aplicación particular, se pretende ajustar el control de temperatura de una pila PEMFC implicando más de un objetivo: el gradiente de temperatura de la pila y el esfuerzo de control. En trabajos anteriores (Pajares et al., 2020b; Navarro et al., 2020; Navarro Giménez et al., 2019) se ha abordado este problema resolviendo una optimización multiobjetivo utilizando un modelo nominal sin considerar incertidumbres. Sin embargo, en aplicaciones reales, los parámetros del sistema están sujetos a variaciones e incertidumbre. Una ligera modificación de los parámetros del proceso puede provocar efectos notables en las soluciones óptimas obtenidas, resultando en suboptimidad o infactibilidad (Shang et al., 2017).

Para formular un problema de optimización de control ro-

\*Autor para correspondencia: xblasco@isa.upv.es  
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

busto que tenga como objetivo lograr una respuesta adecuada del sistema a pesar de las variaciones de parámetros se deben considerar dos elementos clave: la definición de escenarios de incertidumbre y el establecimiento de indicadores robustos que evalúen la sensibilidad de las soluciones resultantes. Definir un conjunto de escenarios (conjuntos de parámetros del modelo) que represente adecuadamente las incertidumbres es una tarea compleja (Shang et al., 2017). Para evitar soluciones demasiado conservadoras, el modelado de incertidumbre debería excluir escenarios con baja probabilidad de existencia. Además, el número de escenarios debe ser suficiente para representar el espacio de variaciones, pero no demasiado grande para que el coste computacional del análisis de robustez sea asequible. Además, formular un problema de optimización bajo incertidumbre implica el establecimiento de indicadores asociados a criterios y/o restricciones de robustez específicos. El indicador robusto *Minmax* (Veyna et al., 2023b) se utiliza a menudo para minimizar el peor caso de cada componente del vector objetivo cuando se evalúa para el conjunto de escenarios que definen la incertidumbre. En la bibliografía se pueden encontrar otros indicadores utilizados, por ejemplo, la media y la desviación estándar (Paenke et al., 2006).

Un problema adicional que aparece en este contexto es que la optimización para el proceso nominal y la robustez en presencia de incertidumbre suele estar en conflicto (Gaspar-Cunha and Covas, 2008). Las soluciones obtenidas en el escenario nominal suelen ser menos robustas para el resto de escenarios. Y si, por ejemplo, se minimiza la varianza respecto de un conjunto de escenarios de incertidumbre, el desempeño de las soluciones obtenidas en el escenario nominal puede estar lejos de ser óptimo. En este trabajo se propone utilizar el indicador de robustez llamado *eficiencia robusta utópica*. Con este indicador se buscan controladores con un equilibrio entre optimalidad para el modelo nominal y robustez para la incertidumbre.

Para ilustrar la propuesta, se plantea ajustar una estructura de control PID multibucle para controlar las temperaturas de un sistema PEMFC con incertidumbre en el modelo, utilizando optimización multiobjetivo y el indicador mencionado. Para comparar y resaltar las ventajas obtenidas se resuelven dos ajustes alternativos adicionales: optimización con el modelo de parámetros nominales y con el indicador robusto *Minmax*.

## 2. Problemas de optimización multiobjetivo bajo incertidumbre

Para plantear una optimización multiobjetivo bajo incertidumbre se requieren dos elementos clave: 1) un conjunto de escenarios que representen adecuadamente las incertidumbres del sistema y 2) indicadores que evalúen la calidad de la robustez de las soluciones definidas.

### 2.1. Formulación de marcos de incertidumbre

La incertidumbre se puede modelar como variaciones de los parámetros del modelo. Por tanto, estos parámetros afectan a la función objetivo (Paenke et al., 2006). Una función multiobjetivo  $f(x, p)$  se puede definir como  $f(x, p) = [f_1(x, p), f_2(x, p), \dots, f_q(x, p)]$ , donde  $q \in \mathbb{N}$  es el número de objetivos. Un vector de decisión  $x \in Q$ ,  $x = [x_1, x_2, \dots, x_h]$ ,

donde  $h \in \mathbb{N}$  es el número de variables de decisión. Un modelo de parámetros con incertidumbre  $p$  se define como  $p = [p_1, p_2, \dots, p_k]$ , donde  $k \in \mathbb{N}$  es el número de parámetros donde se consideran variaciones. En aplicaciones reales de ingeniería, definir adecuadamente un marco de incertidumbre pasa por construir un conjunto,  $P = \{p^1, p^2, \dots, p^m\}$ ,  $m \in \mathbb{N}$ , de escenarios ( $p^i$ ) altamente representativos que describan bien el sistema y, al mismo tiempo, con un número limitado de escenarios ( $m$ ) para que el coste computacional que requiere su análisis sea asequible (Veyna et al., 2023b).

### 2.2. Conceptos de dominancia robusta de Pareto

Para realizar un análisis de robustez, es necesario definir indicadores apropiados. Estos indicadores de robustez evalúan el desempeño de una solución bajo incertidumbres y establecen diferentes definiciones de dominancia de Pareto.

**Definición 1.** *Dominancia de Pareto (Miettinen, 2012):* Dado un escenario  $p$ , un vector de decisión  $x^1$  está dominado por otro vector de decisión  $x^2$  si,  $f_i(x^2, p) \leq f_i(x^1, p)$  para todo  $i \in [1, 2, \dots, q]$  y  $f_j(x^2, p) < f_j(x^1, p)$  para al menos un  $j$  tal que  $j \in [1, 2, \dots, q]$ .

La dominancia de Pareto entre vectores  $x \in Q$  en el escenario  $p$  se denota como  $x^2 \leq^p x^1$ . La no dominancia entre vectores se denota como  $x^2 \not\leq^p x^1$ . El conjunto de soluciones de Pareto en el escenario  $p$  se denota como  $X^p = \{x \in Q \mid \nexists x^0 \in Q : x^0 \leq^p x\}$ . Entonces, para el conjunto de escenarios de incertidumbre  $P = \{p^1, p^2, \dots, p^m\}$ , se define la familia de conjuntos de Pareto  $\{X^{p^1}, X^{p^2}, \dots, X^{p^m}\}$ .

**Definición 2.** *Dominancia robusta (Veyna et al., 2023a):* Dado un conjunto de escenarios  $P = \{p^1, p^2, \dots, p^m\}$ , un vector de decisión  $x^1$  está robustamente dominado por otro vector  $x^2$  si la dominancia  $x^2 \leq^{p^s} x^1$  para todos los  $s \in [1, 2, \dots, m]$ .

La dominancia robusta entre vectores se denota como  $x^2 \leq^P x^1$ . La dominancia no robusta se indica como  $x^2 \not\leq^P x^1$ .

**Definición 3.** *Eficiencia robusta Minmax basada en puntos (Ide and Schöbel, 2016):* dado un conjunto de escenarios de incertidumbre  $P = \{p^1, p^2, \dots, p^m\}$ , la eficiencia Minmax basada en puntos del vector  $x \in Q$  está definida por la función  $f^{max}(x, P) = [f_1^{max}(x, P), f_2^{max}(x, P), \dots, f_q^{max}(x, P)]$ . Donde el componente  $f_i^{max}(x, P)$  tal que  $i \in [1, 2, \dots, q]$  se define como  $f_i^{max}(x, P) = \max_{p \in P} f_i(x, p)$ .

La función  $f^{max}(x, P)$  determina el valor máximo que alcanza una solución  $x$  bajo  $P$  en cada  $f_i$  tal que  $i \in [1, 2, \dots, q]$ .

**Definición 4.** *Dominancia robusta Minmax basada en puntos.* Dado un conjunto de escenarios de incertidumbre  $P = \{p^1, p^2, \dots, p^m\}$ , un vector de decisión  $x \in Q$  está dominado por otro vector  $x^0 \in Q$  bajo el concepto robusto Minmax basado en puntos (denotado como  $x^0 \leq^{max} x$ ) si se cumple alguna de las siguientes condiciones:

- Condición 1:  $f^{max}(x, P) = f^{max}(x^0, P)$ :  
 $x^0 \leq^{max} x$  si  $x^0 \leq^P x$ .
- Condición 2:  $f^{max}(x, P) \neq f^{max}(x^0, P)$ :  
 $x^0 \leq^{max} x$  si  $f_i^{max}(x^0, P) \leq f_i^{max}(x, P)$  para todo  $i \in [1, 2, \dots, q]$  y  $f_j^{max}(x^0, P) < f_j^{max}(x, P)$  para al menos un  $j \in [1, 2, \dots, q]$ .

Las soluciones no dominadas forman el conjunto robusto Minmax basado en puntos  $X^{Wc} = \{x \in Q | \exists x^0 \in Q : x^0 \leq^{max} x\}$ .

Para definir soluciones con un desempeño equilibrado en todo el marco de incertidumbre, se define el indicador de *eficiencia robusta utópica* (Definición 5). Este indicador evalúa la desviación global del desempeño de una solución relativa a los puntos utópicos definidos en problemas de optimización para cada escenario  $p \in P$ . Con este indicador se busca un buen equilibrio entre robustez y optimalidad nominal.




Figura 1: Parámetros de la función  $\Delta f_i(x, p^s)$ .

**Definición 5.** *Eficiencia robusta utópica* (Veyna et al., 2023a): dado un conjunto de escenarios  $P = \{p^1, p^2, \dots, p^m\}$ , la función  $f^{ut}(x, P) = [f_1^{ut}(x, P), f_2^{ut}(x, P), \dots, f_q^{ut}(x, P)]$  define la eficiencia robusta utópica de un vector  $x$ . Donde el elemento  $f_i^{ut}(x, P)$  tal que  $i \in [1, 2, \dots, q]$  se define como se indica en las ecuaciones (1)-(2).

$$f_i^{ut}(x, P) = \sum_{s=1}^m \Delta f_i(x, p^s) \quad (1)$$

$$\Delta f_i(x, p^s) = \frac{f_i(x, p^s) - \min(f_i(X^{p^s}, p^s))}{\max(f_i(X^{p^s}, p^s)) - \min(f_i(X^{p^s}, p^s))} \quad (2)$$

La función  $f^{ut}(x, P)$  define una medida normalizada para la desviación global de la función objetivo bajo incertidumbres  $f_i^{ut}(x, P) = [f_i^{ut}(x, p^1), f_i^{ut}(x, p^2), \dots, f_i^{ut}(x, p^m)]$  sobre los puntos utópicos  $\min(f_i(X^{p^s}, p^s))$ ,  $s \in [1, 2, \dots, m]$  determinados para cada escenario. La figura 1 muestra un ejemplo gráfico en 2 dimensiones ( $i \in [1, 2]$ ) donde se indican los parámetros de la función  $\Delta f_i(x, p^s)$  para un escenario  $p^s$ ,  $s \in [0, 1, \dots, m]$ .

**Definición 6.** *Dominancia robusta utópica*: dado un conjunto de escenarios  $P = \{p^1, p^2, \dots, p^m\}$ , un vector de decisión  $x \in Q$  está dominado bajo el concepto robusto utópico por otro vector de decisión  $x^0$  (denotado como  $x^0 \leq^{ut} x$ ) si  $f_i^{ut}(x^0, P) \leq f_i^{ut}(x, P)$  para todo  $i \in [1, 2, \dots, q]$  y  $f_j^{ut}(x^0, P) < f_j^{ut}(x, P)$  para al menos un  $j \in [1, 2, \dots, q]$ .

Con esta definición, las soluciones no dominadas constituyen el conjunto robusto utópico  $X^{Ut} = \{x \in Q | \exists x^0 \in Q : x^0 \leq^{ut} x\}$  que destaca por representar un desempeño equilibrado en todos los escenarios (Veyna et al., 2023a).

### 3. Descripción del sistema y formulación del problema de control

#### 3.1. Descripción del sistema PEM

El sistema a controlar se describe con detalle en (Navarro Giménez et al., 2019). De forma resumida, dispone de

una pila PEMFC alimentada por hidrógeno y aire para generar energía eléctrica y calor. Se utiliza una carga electrónica programable para emular un consumo residencial de electricidad. Un radiador ventilado simula el consumo de energía térmica (agua caliente y calefacción). Además, la energía térmica se puede almacenar en un tanque de agua.

El control se centra en el sistema de refrigeración. El modelo obtenido tiene dos salidas relacionadas con el refrigerante líquido (agua osmotizada): las temperaturas de entrada y salida del agua de la pila  $T_{w_{out}}$  y  $T_{w_{in}}$ . Las acciones de control son  $u_{T_{w_{out}}}$ , que representa el caudal de agua en el circuito de refrigeración primario, y  $u_{T_{w_{in}}}$ , que es el caudal de agua en el circuito de refrigeración secundario. La única perturbación considerada es la corriente eléctrica ( $I$ ) demandada por la pila. Este modelo no lineal se construye a partir de primeros principios y fue validado experimentalmente en su rango operativo (de 140 a 200A).

El modelo dinámico tiene 31 parámetros  $p = [p_1, p_2, \dots, p_{31}]$ . En (Navarro Giménez et al., 2019) se pueden encontrar detalles de la identificación de parámetros y validación de un modelo nominal. En (Pajares et al., 2020a) se analizan modelos casi óptimos y se presenta una aproximación de los rangos operativos para las incertidumbres de los parámetros cuando el sistema opera alrededor de su punto de ajuste.

#### 3.2. Modelado de incertidumbre

La metodología utilizada para el modelado de las incertidumbres en los parámetros de este sistema ha sido presentada en un trabajo previo (Veyna et al., 2023b). El resultado es un conjunto de modelos de incertidumbre que representan escenarios de ocurrencia altamente probables de acuerdo con los ensayos experimentales, el conjunto de modelos es  $P^\alpha = \{p^1, p^2, \dots, p^{180}\}$ . Es un conjunto limitado de modelos que permite reducir el grado de conservadurismo y representa un coste computacional razonable para abordar el proceso de optimización. La metodología requiere la siguiente información inicial:

1. El modelo de parámetros nominales. A partir del proceso de identificación (Navarro Giménez et al., 2019), se define el modelo nominal de parámetros  $p^0 = [p_1^0, p_2^0, \dots, p_{31}^0]$  (Se muestran los valores en (Veyna et al., 2023b)).
2. Límite de degradación para la respuesta del sistema. Del experimento realizado en el proceso de validación, se asocia un error de temperatura promedio  $J_{avg} = 0.26^\circ C$  con el modelo nominal identificado (ver el ensayo de validación del modelo en (Navarro Giménez et al., 2019)). A partir de estos datos se establece el límite de degradación de la temperatura de  $0.65^\circ C$  como grado de tolerancia para la clasificación de modelos de incertidumbre con una fiabilidad aceptable.
3. Rangos de variación iniciales para cada parámetro. Los rangos de exploración  $[pp_i, \overline{pp}_i]$ ,  $i = [1, 2, \dots, 31]$  en los que se explora inicialmente el dominio de incertidumbre, se definen por la desviación de  $\pm 95\%$  del valor nominal de cada parámetro.

La metodología propuesta en (Veyna et al., 2023b) realiza una serie de filtrados. Inicialmente el proceso de modelado de incertidumbre comienza con el conjunto de modelos  $\mathbf{P}^{\phi_1} = \{\mathbf{p}^1, \mathbf{p}^2, \dots, \mathbf{p}^{1500}\}$ , que se define con 1500 modelos creados mediante muestreo aleatorio dentro del rango operativo establecido en el análisis de sensibilidad. Luego, se aplican tres filtros para reducir el conjunto. Al aplicar el primer filtro se obtiene el subconjunto de 1202 modelos. Se han excluido los modelos improbables relacionados con variaciones en el espacio de parámetros. Aplicando el segundo filtro, se obtiene el subconjunto de 860 modelos, eliminando puntos que no superan una desviación relativa del modelo nominal comparando con datos experimentales. El último filtro se utiliza para simplificar uniformemente el modelado a una representación computacionalmente aceptable para evaluar la sensibilidad de una solución en un análisis de robustez. Se define el subconjunto  $\mathbf{P}^\alpha$  con 180 modelos.

Para realizar las comparaciones posteriores es necesario localizar los modelos de peor caso. Utilizando la estrategia de selección de modelo definida en la etapa 3 de la metodología descrita en (Veyna et al., 2023b), se identifica el modelo del peor caso  $\mathbf{p}^* \in \mathbf{P}^\alpha$ . Esta estrategia de selección de modelo consiste en utilizar un conjunto de controladores de referencia para caracterizar el desempeño del conjunto de incertidumbre  $\mathbf{P}^\alpha$  en el espacio objetivo.

### 3.3. Formulación del problema de control de temperatura

El sistema de control tiene como objetivo mantener  $T_{wout}$  y  $T_{win}$  en sus referencias, mientras que los cambios en la demanda de corriente eléctrica ( $I$ ) producen fluctuaciones transitorias indeseables en la temperatura de la pila. El control de temperatura debe responder a las perturbaciones para minimizar las excursiones de  $T_{wout}$  y  $T_{win}$  de sus referencias,  $r_{T_{wout}} = 65^\circ\text{C}$  y  $r_{T_{win}} = 60^\circ\text{C}$ , respectivamente. En (Navarro et al., 2020) se propone una estructura de control multibucle (ver figura 2); esta estructura consta de dos controladores PI con anti-windup, uno para el control de  $T_{wout}$  (mediante el uso de  $u_{T_{wout}}$ ) y el otro para el control de  $T_{win}$  (usando  $u_{T_{win}}$ ). Por lo tanto, el controlador tiene cuatro parámetros para ajustar (dos por cada PI),  $[K_{c1}, T_{i1}, K_{c2}, T_{i2}]$ , donde  $K_{c1}$  y  $K_{c2}$  están en  $(\text{l/min})/^\circ\text{C}$  y  $T_{i1}$  y  $T_{i2}$  en (s).

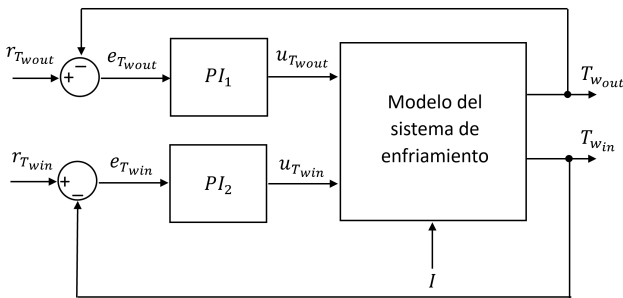


Figura 2: Estructura de control PI multibucle para temperaturas  $T_{wout}$  y  $T_{win}$ .

La formulación del problema de optimización multiobjetivo bajo incertidumbres tiene como objetivo minimizar los objeti-

vos  $f_1$  y  $f_2$  establecidos en las ecuaciones (3) y (4).

$$f_1(\mathbf{x}, \mathbf{p}) = \frac{1}{T_{sim}} \int_0^{T_{sim}} |e_{T_{wout}}| dt + \frac{1}{T_{sim}} \int_0^{T_{sim}} |e_{T_{win}}| dt \quad (3)$$

$$f_2(\mathbf{x}, \mathbf{p}) = \frac{1}{T_{sim}} \int_0^{T_{sim}} \left| \frac{du_{T_{wout}}(t)}{dt} \right| dt + \frac{1}{T_{sim}} \int_0^{T_{sim}} \left| \frac{du_{T_{win}}(t)}{dt} \right| dt \quad (4)$$

Donde  $\mathbf{p} = [p_1, p_2, \dots, p_k]$  es el vector de parámetros del modelo y  $\mathbf{x} = [K_{c1}, T_{i1}, K_{c2}, T_{i2}]$  es el vector de decisión (que contiene los parámetros del controlador). Los límites inferior y superior para el ajuste del controlador son  $\underline{\mathbf{x}} = [\underline{K}_{c1}, \underline{T}_{i1}, \underline{K}_{c2}, \underline{T}_{i2}]$  y  $\overline{\mathbf{x}} = [\overline{K}_{c1}, \overline{T}_{i1}, \overline{K}_{c2}, \overline{T}_{i2}]$ .

El objetivo  $f_1(\mathbf{x}, \mathbf{p})$  evalúa el desempeño de los controladores sumando los errores absolutos medios de las temperaturas del refrigerante a la entrada y salida de la pila (en  $^\circ\text{C}$ ) con respecto a sus referencias (ecuación (5)).

$$e_{T_{wout}} = r_{T_{wout}} - T_{wout}; \quad e_{T_{win}} = r_{T_{win}} - T_{win} \quad (5)$$

El objetivo  $f_2(\mathbf{x}, \mathbf{p})$  evalúa el esfuerzo de control sumando los valores absolutos promedio de las tasas de cambio de las acciones de control ( $u_{T_{wout}}$  y  $u_{T_{win}}$ ) en  $(\text{l/min})/s$ .  $T_{sim}$  es el tiempo de simulación (3300s).




Figura 3: Señal de demanda de corriente eléctrica utilizada en el diseño del control. El primer escalón aplicado es en  $t = 100$  s y la duración de cada escalón es de 800 s. El tiempo total de simulación es de 3300 s.

El propósito de los objetivos  $f_1$  y  $f_2$  es conseguir una eficiencia eléctrica óptima y un mínimo deterioro de la pila y actuadores. El control de temperatura debe responder a cambios en la demanda de corriente eléctrica. La figura 3 muestra la señal de corriente eléctrica utilizada para el diseño del control que presenta escalones y atraviesa todo el rango de validez del modelo no lineal (de 140 a 200A). Dadas estas condiciones y los indicadores de robustez mostrados en la sección 2, el problema de optimización multiobjetivo se plantea bajo tres formulaciones:

a) En condiciones nominales, función  $f(\mathbf{x}, \mathbf{p}^0)$

$$\min_{\mathbf{x}} f(\mathbf{x}, \mathbf{p}^0) \quad (6)$$

$$f(\mathbf{x}, \mathbf{p}^0) = [f_1(\mathbf{x}, \mathbf{p}^0), f_2(\mathbf{x}, \mathbf{p}^0)] \quad (7)$$

b) Bajo el indicador robusto  $\text{Minmax } f^{max}(\mathbf{x}, \mathbf{P})$

$$\min_{\mathbf{x}} f^{max}(\mathbf{x}, \mathbf{P}^\alpha) \quad (8)$$

$$f^{max}(\mathbf{x}, \mathbf{P}^\alpha) = [f_1^{max}(\mathbf{x}, \mathbf{P}^\alpha), f_2^{max}(\mathbf{x}, \mathbf{P}^\alpha)] \quad (9)$$

c) Bajo el indicador robusto utópico  $f^{ut}(\mathbf{x}, \mathbf{P})$

$$\min_{\mathbf{x}} f^{ut}(\mathbf{x}, \mathbf{P}^\beta) \quad (10)$$

$$f^{ut}(x, P^\beta) = [f_1^{ut}(x, P^\beta), f_2^{ut}(x, P^\beta)] \quad (11)$$

Donde  $P^\alpha = \{p^1, p^2, \dots, p^{180}\}$  es el conjunto de modelos que describen el marco de incertidumbre global del sistema y  $P^\beta = \{p^0, p^*\}$  es el conjunto formado por el modelo nominal ( $p^0$ ) y el modelo del peor caso ( $p^*$ ) definido a partir de la aplicación de la etapa 3 de la metodología de modelado de la incertidumbre. Las formulaciones a), b) y c) están sujetas a  $\underline{x} \leq x \leq \bar{x}$ , tales que:  $\underline{x} = [-8, 1, -8, 1]$ ,  $\bar{x} = [-0.1, 120, -0.1, 120]$ .

#### 4. Análisis de resultados

La optimización de los problemas formulados en las ecuaciones (6)-(11), se han realizado con el algoritmo eVMOGA (Herrero et al., 2009), aunque se podría utilizar cualquier otro algoritmo de optimización multiobjetivo. Tras finalizar el proceso de optimización, se obtienen los conjuntos de Pareto siguientes: el conjunto de controladores  $X^{Nom}$  que optimiza la función  $f(x, p^0)$ , el conjunto  $X^{Wc}$  que minimiza el indicador  $f^{max}(x, P^\alpha)$ , y el conjunto  $X^{Ut}$  que minimiza el indicador  $f^{ut}(x, P^\beta)$ . El número de controladores que componen cada uno de estos conjuntos son:  $\#X^{Nom} = 31$ ,  $\#X^{Wc} = 47$  y  $\#X^{Ut} = 56$ . Para comparar el desempeño óptimo y robusto de estos conjuntos de controladores, las figuras 4-5 muestran el análisis con las funciones  $f^{ut}(x, P^\beta)$ ,  $f^{max}(x, P^\alpha)$  y  $f(x, p^0)$  de los distintos conjuntos obtenidos.

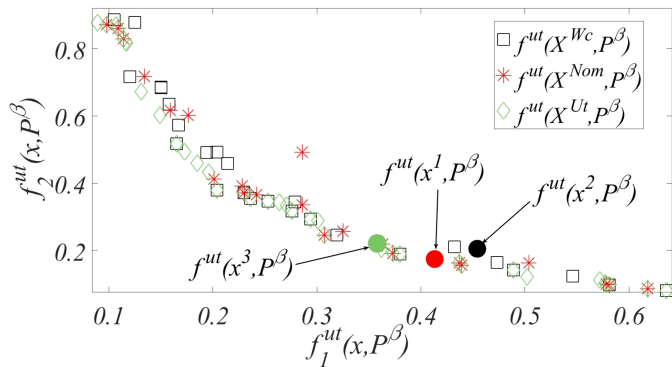


Figura 4: Desempeño de los controladores  $X^{Nom}$ ,  $X^{Wc}$ , y  $X^{Ut}$  bajo las funciones  $f^{ut}(x, P^\beta)$ .

$f^{ut}(x, P^\beta)$  evalúa el equilibrio de desempeño entre el escenario nominal  $p^0$  y el escenario del peor caso  $p^*$ . La figura 4 muestra que los controladores  $X^{Ut}$  (diamantes verdes) pertenecen al frente de optimización  $f^{ut}(X^{Ut}, P^\beta)$  definido a partir del concepto robusto utópico. Con este mismo indicador, algunas soluciones  $x \in X^{Nom}$  (asteriscos rojos) y  $x \in X^{Wc}$  (cuadrados negros) representan controladores subóptimos y otros pertenecen al frente de optimización.

Esta figura resalta tres controladores de referencia:  $x^3 \in X^{Ut}$  (círculo verde sólido),  $x^2 \in X^{Wc}$  (círculo negro sólido) y  $x^1 \in X^{Nom}$  (círculo rojo sólido), el desempeño de estos controladores se analiza a continuación.

La figura 5 muestra el desempeño de los conjuntos  $X^{Ut}$ ,  $X^{Wc}$  y  $X^{Nom}$  en el espacio objetivo  $[f_1(x, p), f_2(x, p)]$  bajo las funciones  $f(x, p^0)$  (escenario nominal) y  $f^{max}(x, P^\alpha)$  (peor caso en el modelo de incertidumbre). Las cruces y asteriscos rojos

representan los controladores  $x \in X^{Nom}$ , los círculos y cuadrados negros indican los controladores  $x \in X^{Wc}$ , y los triángulos y diamantes verdes representan los controladores  $x \in X^{Ut}$ .

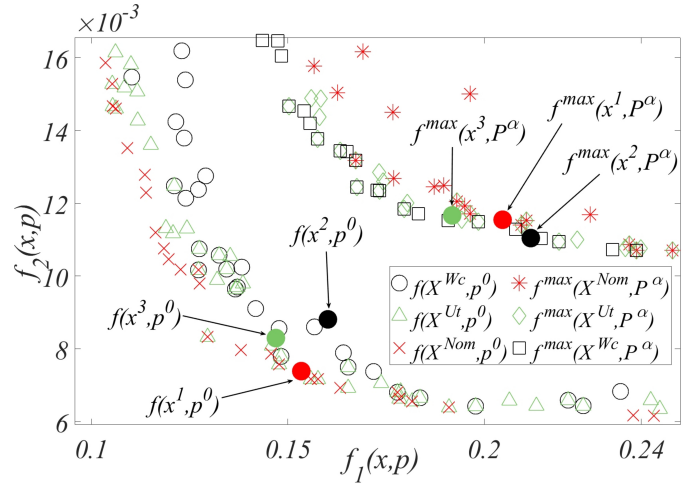


Figura 5: Desempeño de los controladores  $X^{Nom}$ ,  $X^{Wc}$ , y  $X^{Ut}$  bajo las funciones  $f(x, p^0)$  y  $f^{max}(x, P^\alpha)$ .

Esta figura evidencia el conflicto entre los controladores  $X^{Nom}$ , que busca el desempeño óptimo en el escenario nominal  $p^0$ , y los controladores  $X^{Wc}$ , que tienen como objetivo minimizar el indicador robusto  $Minmax f^{max}(x, P^\alpha)$  para el conjunto de de incertidumbre  $P^\alpha$ .




Figura 6: Respuesta del sistema obtenida con los controladores  $x^1 \in X^{Nom}$  (rojo),  $x^2 \in X^{Wc}$  (negro), y  $x^3 \in X^{Ut}$  (verde) para el modelo nominal  $p^0$ .

El conjunto de controladores  $X^{Ut}$  tiende a mostrar un equilibrio entre ambos indicadores de desempeño. Hay soluciones  $x \in X^{Nom}$  y  $x \in X^{Wc}$  que también pertenecen al frente de optimización  $f^{ut}(X^{Ut}, P^\beta)$  (que se muestra en la figura 4) ya que son multimodales. Soluciones  $x \in X^{Ut}$  que no pertenecen al frente  $f^{max}(X^{Wc}, P^\alpha)$  o  $f(X^{Nom}, p^0)$  presentan un mejor equilibrio entre desempeño óptimo y robusto. En esta figura, los controladores de referencia  $x^3 \in X^{Ut}$ ,  $x^2 \in X^{Wc}$  y  $x^1 \in X^{Nom}$  también están resaltados.



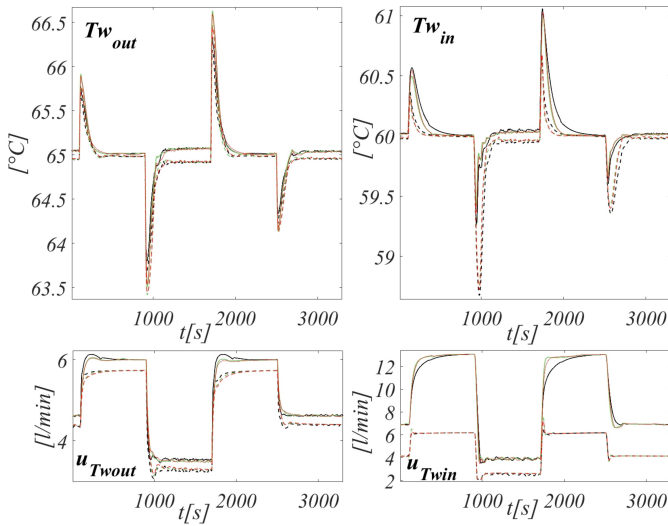


Figura 7: Envolvente para los pts  $P^\alpha$  de la respuesta del sistema obtenida con los controladores  $x^1 \in X^{Nom}$  (rojo),  $x^2 \in X^{Wc}$  (negro) y  $x^3 \in X^{Ut}$  (verde). Las líneas continuas indican límites superiores. Las líneas discontinuas indican límites inferiores.

Para visualizar otra comparación entre la tendencia de desempeño de los controladores  $X^{Ut}$ ,  $X^{Wc}$  y  $X^{Nom}$  obtenidos de diferentes enfoques de optimización, la figura 6 muestra la respuesta del sistema con los controladores de referencia resaltados antes  $x^1 \in X^{Nom}$  (rojo),  $x^2 \in X^{Wc}$  (negro), y  $x^3 \in X^{Ut}$  (verde) para el modelo nominal  $p^0$ . Esta figura muestra nuevamente que el controlador  $x^3 \in X^{Ut}$  exhibe una respuesta del sistema con un desempeño equilibrado con respecto a los controladores  $x^1 \in X^{Nom}$  y  $x^2 \in X^{Wc}$  para las salidas  $[T_{wout}, T_{win}]$  y entradas  $[u_{Twout}, u_{Twin}]$ .

Por otro lado, la figura 7 muestra la envolvente de respuestas del sistema para las salidas y entradas obtenidas al simular los controladores  $x^3 \in X^{Ut}$  (verde),  $x^2 \in X^{Wc}$  (negro) y  $x^1 \in X^{Nom}$  (rojo) con el conjunto de modelos de incertidumbre  $P^\alpha$ . Las líneas continuas y discontinuas representan los límites superior e inferior de cada envolvente, respectivamente. Estos límites muestran la degradación del desempeño de cada controlador bajo incertidumbre. El equilibrio del desempeño en el espacio objetivo bajo los escenarios nominal y del peor caso involucrados en la definición del conjunto  $X^{Ut}$  hace que la solución  $x^3 \in X^{Ut}$  muestre una tendencia a exhibir un rango de degradación (área delimitada por los límites superior e inferior verdes) con menor amplitud durante el tiempo de simulación.

## 5. Conclusiones

Este artículo muestra el ajuste multiobjetivo de un sistema de control PID multibucle robusto. El proceso consiste en controlar las temperaturas de un sistema micro-CHP con pila de combustible tipo PEM. El sistema es complejo y se puede determinar el grado de incertidumbre en los parámetros de su modelo no-lineal. El ajuste se fundamenta en un adecuado modelado

del conjunto de incertidumbres (suficientemente representativo pero con un número limitado de escenarios para su viabilidad computacional). Los resultados muestran que el indicador de eficiencia robusta utópica resulta ser eficaz para ajustar los controladores con un equilibrio entre un desempeño para el modelo nominal y robustez frente a las incertidumbres de los parámetros del modelo.

## Agradecimientos

Este trabajo ha sido financiado en parte por el proyecto PID2021-124908NB-I00 MCIN/AEI/10.13039/501100011033/ y por “FEDER Una forma de hacer Europa”; mediante subvención PRE2019-087579 financiada por MCIN/AEI/10.13039/501100011033 y por “FSE Invirtiendo en tu futuro”; y por la Generalitat Valenciana a través del proyecto CIAICO/2021/064.

## Referencias

- Ellamla, H. R., Staffell, I., Bujlo, P., Pollet, B. G., Pasupathi, S., 2015. Current status of fuel cell based combined heat and power systems for residential sector. *Journal of Power Sources* 293, 312–328.
- Gaspar-Cunha, A., Covas, J. A., 2008. Robustness in multi-objective optimization using evolutionary algorithms. *Computational optimization and applications* 39, 75–96.
- Herrero, J. M., García-Nieto, S., Blasco, X., Romero-García, V., Sánchez-Pérez, J. V., García-Raffi, L., 2009. Optimization of sonic crystal attenuation properties by ev-moga multiobjective evolutionary algorithm. *Structural and Multidisciplinary Optimization* 39 (2), 203–215.
- Huang, L., Chen, J., Liu, Z., Becherif, M., 2018. Adaptive thermal control for pemfc systems with guaranteed performance. *International Journal of Hydrogen Energy* 43 (25), 11550–11558.
- Ide, J., Schöbel, A., 2016. Robustness for uncertain multi-objective optimization: a survey and analysis of different concepts. *OR spectrum* 38 (1), 235–271.
- Miettinen, K., 2012. *Nonlinear multiobjective optimization* (Vol. 12). Springer Science & Business Media.
- Navarro, S., Herrero, J. M., Blasco, X., Simarro, R., 01 2020. Design and experimental validation of the temperature control of a pemfc stack by applying multiobjective optimization. *IEEE Access* 8, 183324–183343.
- Navarro Giménez, S., Herrero Durá, J. M., Blasco Ferragud, F. X., Simarro Fernández, R., 2019. Control-oriented modeling of the cooling process of a PEMFC-Based  $\mu$ -CHP system. *IEEE Access* 7, 95620–95642.
- Paenke, I., Branke, J., Jin, Y., 2006. Efficient search for robust solutions by means of evolutionary algorithms and fitness approximation. *IEEE Transactions on Evolutionary Computation* 10 (4), 405–420.
- Pajares, A., Blasco, F. X., Herrero, J. M., Vicente Salcedo, J., 2020a. Analyzing the nearly optimal solutions in a multi-objective optimization approach for the multivariable nonlinear identification of a pem fuel cell cooling system. *IEEE Access* 8, 114361–114377.
- Pajares, A., Blasco, X., Herrero, J. M., Simarro, R., 2020b. Multivariable controller design for the cooling system of a pem fuel cell by considering nearly optimal solutions in a multiobjective optimization approach. *Complexity* 2020.
- Shang, C., Huang, X., You, F., 2017. Data-driven robust optimization based on kernel learning. *Computers & Chemical Engineering* 106, 464–479.
- Veyna, U., Blasco, X., Herrero, J., Pajares, A., 2023a. Non dominated robust solutions design under a multi-objective optimization approach. applied to robust controllers tuning. Under review in a JCR journal.
- Veyna, U., Blasco, X., Herrero, J., Pajares, A., 2023b. Parameter uncertainty modeling for multiobjective robust control design. application to a temperature control system in a proton exchange membrane fuel cell. *Engineering Applications of Artificial Intelligence* 119, 105758.



ISBN 978-84-18465-97-0



**UNIVERSIDAD  
DE BURGOS**

**Servicio de Publicaciones e  
Imagen Institucional**



**CEA**  
comité  
español de  
automática



**CONTROL  
INTELIGENTE**