



XVII SIMPOSIO CEA DE CONTROL INTELIGENTE

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

LIBRO DE ACTAS

León, 27-29 de junio de 2022

Schneider
Electric


STORMSHIELD

ASTI 
MOBILE
ROBOTICS

IDOM

universidad
del león


Escuela de
Ingenierías


Colegio Oficial de
Ingenieros Industriales de León

Adi
BioPharma

ciudad
de la
energía 

 DIPUTACIÓN
DE LEÓN

 AYUNTAMIENTO DE LEÓN

XVII SIMPOSIO CEA DE CONTROL INTELIGENTE: LIBRO DE ACTAS

LEÓN, 27 al 29 de junio de 2022

ISBN: 978-84-18490-65-1

Editores:

Manuel Domínguez González

Pedro J. Cabrera Santana

Eloy Irigoyen Gordo

PRÓLOGO

Al igual que en las ediciones anteriores, el XVII 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 León y le ha correspondido la organización del mismo al Grupo de Investigación SUPPRESS de la Universidad de León, dirigido por el profesor Manuel Domínguez. Con más de 90 asistentes en algunas de las actividades del Simposio, hemos conseguido batir récords de asistencia y 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.

PROGRAMA

Lunes, 27

Tarde

Lugar: Casa Botines 

Plano de acceso 

16:30 - 17:00

Entrega de acreditación y documentación

17:00 - 17:30

Inauguración

17:45 - 18:45

Conferencia plenaria

HAS THE CYBERWARFARE STARTED? WHERE DO WE BEGIN TO SECURE OUR INFRASTRUCTURE

Ali Bozorgmir, Schneider Electric

18:45 - 19:15

Café

19:15 - 21:15

Recepción en el museo Casa Botines

MUSEO CASA BOTINES DE GAUDI

19:15h - 19:45h: Bienvenida por parte de la Directora del Museo Casa Botines Gaudí, Noemí Martínez Murciego en Sala Semisótano donde explicará la sala y también hablará sobre Gaudí

19:45h - 21:15h: Visita guiada en el Museo Casa Botines Gaudí, se divide el grupo en dos más pequeños de 25-30 pax)

21:30

Cena de trabajo

EL MODERNISTA

Sotano de Casa Botines

Martes, 28

Mañana

Lugar: Escuela de Ingenierías 9

Plano de acceso 

09:30 - 10:30

Conferencia plenaria

CIBERSEGURIDAD EN PROTOCOLOS INDUSTRIALES Y ENTORNOS OT

Antonio Martínez Algorta, Stormshield – Grupo Airbus

10:30 - 11:00

Demo de ciberseguridad en OT

11:00 - 12:30

Café y sesión de pósteres

Plano de acceso 

12:30 - 14:00

Presentaciones de las candidaturas finalistas al Premio IDOM a la Mejor Tesis Doctoral en Control Inteligente

DESIGN AND DEVELOPMENT OF SOFT-SENSORS IN THE CONTEXT OF OIL AND GAS 4.0: AN AUTOML APPROACH BASED ON MACHINE LEARNING FEATURE ENGINEERING

Iratxe Niño Adán (UPV/EHU)

ITERATIVE LEARNING CONTROL IN THE COMMISSIONING OF INDUSTRIAL PRESSES

Ignacio Trojaola (UPV/EHU)

IDENTIFICATION OF NONLINEAR PROCESSES BASED ON WIENER-HAMMERSTEIN MODELS AND HEURISTIC OPTIMIZATION

Julio Zambrano (Universidad Politécnica de Valencia)

14:00 - 16:00

Almuerzo de Trabajo

Plano de acceso 

Tarde

16:00 - 20:00

Visita técnica

ADL BIOPHARMA

21:00

Cena del simposio

CUEVA ITARIEGOS

Lugar: Villagallegos 9

Miércoles, 29

Mañana

Lugar: Escuela de Ingenierías 9
Plano de acceso 

09:30 - 10:30

Conferencia plenaria

CIUDEN: HERRAMIENTA AL SERVICIO DE LA TRANSICIÓN ENERGÉTICA
Fundación Ciudad de la energía

10:30 - 11:30

Sesión de comunicaciones y presentaciones

11:30 - 12:00

Café y sesión de pósteres

Plano de acceso 

12:00 - 13:00

Sesión de comunicaciones y presentaciones

13:00 - 13:45

Mesa redonda. Reunión del grupo temático

13:45 - 14:00

Comunicación de premios

14:00 - 14:15

Clausura

14:15 - 16:00

Almuerzo de Trabajo

Plano de acceso 

Comité Organizador

Manuel Domínguez González (Presidente)

Pedro Jesús Cabrera Santana

Eloy Irigoyen Gordo

Juan José Fuertes Martínez

Miguel Ángel Prada Medrano

Serafín Alonso Castro

Antonio Morán Álvarez

Perfecto Reguera Acevedo

Daniel Pérez López

José Ramón Rodríguez Ossorio

Raúl González Herbón

Guzmán González Mateos

María del Carmen Benavides Cuéllar

Isaías García Rodríguez

Héctor Alaiz Moretón

José Alberto Benítez Andrades

María Teresa García Ordás

Natalia Prieto Fernández

Comité Científico-Técnico

Manuel Domínguez González

Pedro J. Cabrera Santana

Eloy Irigoyen Gordo

Juan José Fuertes Martínez

Miguel Ángel Prada Medrano

Serafín Alonso Castro

Antonio Morán Álvarez

Perfecto Reguera Acevedo

Daniel Pérez López

María del Carmen Benavides Cuéllar

Isaías García Rodríguez

Héctor Alaiz Moretón

CONFERENCIAS



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Gestión energética en microrredes renovables híbridadas con hidrógeno de uso residencial. Una propuesta multiobjetivo basada en lógica borrosa

Rey, J.^a, Segura, F.^a, Andújar, J.M.^a, Vivas, F.J.^a, Noguera, M.^a, Millán, B.^a

^a Universidad de Huelva; Centro de Investigación en Tecnología, Energía y Sostenibilidad (CITES)

To cite this article: Rey, J., Segura, F., Andújar, J.M., Vivas, F.J., Noguera, M., Millán, B.. 2022. Energy management in residential hydrogen hybridised renewable microgrids. A multi-objective proposal based on fuzzy logic. XVII Simposio CEA de Control Inteligente. 2022.

Resumen

Los sistemas de almacenamiento en microrredes basadas en fuentes de energía renovable (FER) son elementos imprescindibles para adecuar la producción a la demanda, de modo que el exceso de energía renovable presente en la red en periodos determinados, pueda ser almacenado y utilizado en situaciones de déficit de producción. Como es sabido, las FER tienen una producción no constante y no continua. Dada la naturaleza multi componente (elementos de producción y almacenamiento de características y dinámicas diferentes) de las microrredes renovables híbridadas con hidrógeno, resulta necesario implementar sistemas de gestión energética (SGE), los cuales son sistemas de control que persiguen obtener las mejores prestaciones de cada elemento para lograr de forma sinérgica un funcionamiento adecuado de la microrred. Este artículo propone, para una microrred renovable híbridada con hidrógeno de uso residencial, un SGE implementado mediante un controlador lógico borroso (CLB) multivariable y multietapa. Se trata de hacer frente a un problema multiobjetivo, con objeto de aumentar el rendimiento de la microrred en términos de eficiencia, costes operativos y vida útil de sus elementos. Para ello, se tendrá en cuenta el balance de potencia de la microrred, el rendimiento y la degradación de sus elementos, así como los costes/beneficios de la energía intercambiada con la red eléctrica principal. Los resultados obtenidos muestran un mejor rendimiento y mayor beneficio económico en comparación con SGE tradicionales basados en modelos o técnicas heurísticas.

Palabras clave: control lógico borroso, control multiobjetivo, microrredes renovables, sistemas de hidrógeno, sistemas de gestión de energía.

Abstract

Storage systems in microgrids based on renewable energy sources (RES) are essential elements to match production to demand, so that excess renewable energy present in the grid at given periods can be stored and used in situations of production shortfalls. As is well known, RES have a non-constant and non-continuous production. Given the multi-component nature (production and storage elements with different characteristics and dynamics) of hydrogen-hybridised renewable microgrids, which are control systems that seek to obtain the best performance from each element in order to achieve synergistic operation of the microgrid. This article proposes, for a residential hydrogen-hybridised renewable microgrid, an EMS implemented by means of a multivariable and multistage fuzzy logic controller (FLC). The aim is to address a multi-objective problem in order to increase the performance of the microgrid in terms of efficiency, operational costs and lifespan of its elements. This will take into account the power balance of the microgrid, the performance and degradation of its elements, as well as the costs/benefits of the energy exchanged with the main grid. The results obtained show a better performance and higher economic benefit compared to traditional EMSs based on models or heuristic techniques.

Keywords: fuzzy logic control, multi-objective control, renewable microgrids, hydrogen systems, energy management systems.

*Autor para correspondencia: jesus.rey@diesia.uhu.es

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

1. Introducción

En un contexto en el que impera la necesidad de reducir la dependencia de combustibles fósiles (debido a enormes problemas medioambientales y geopolíticos), la apuesta por energías renovables y modelos de generación distribuidos centra el objetivo de las políticas europeas en materia climática (Vivas et al., 2018). Por otro lado, la vital importancia del mercado residencial (debido al peso de este sector, que viene aumentando desde 1960) para descarbonizar la economía (Jafari et al., 2019), el cual tiene patrones de demanda muy desiguales, lleva a la necesidad de sistemas de almacenamiento de energía para garantizar la demanda energética a partir de fuentes de energía renovables (FER). En ese sentido, un sistema de almacenamiento prometedor para microrredes renovables, es el basado en baterías hibridado con los basados en hidrógeno. Éstos, si la producción, almacenamiento y consumo de hidrógeno se produce en la misma red, suelen estar compuestos por un electrolizador, un tanque de almacenamiento y una pila de combustible, de estructura simple o modular (Abo-Elyousr et al., 2021). En general, en este tipo de microrredes, el uso de buses de corriente continua (CC) mejora el comportamiento de la microrred, evitando, entre otros, problemas relacionados con la potencia reactiva (Vivas et al., 2018). En estos sistemas híbridos de almacenamiento de energía, las baterías funcionan mejor en el corto-medio plazo y los sistemas de hidrógeno en el largo plazo (Herr et al., 2017).

Respecto a la estructura del sistema de pila de combustible en la microrred, uno multi-stack ofrece mayor durabilidad y eficiencia (Marx et al., 2014). Sin embargo, al añadir un mayor número de variables al sistema de gestión de energía (SGE) de la microrred, se requiere un control más complejo (Calderón et al., 2020). Sin embargo y como contrapartida, el SGE puede afrontar el problema de control con más grados de libertad, lo cual permite gestionar la microrred tanto desde el punto de vista técnico (satisfaciendo la demanda) como económico, haciéndola más eficiente y rentable (Ullah et al., 2021).

Para la gestión de los sistemas de almacenamiento, se proponen diferentes SGE tales como los fundamentados en técnicas heurísticas, basados en histéresis y reglas deterministas. En ellos, la producción renovable es empleada, en primera instancia, para recargar baterías (Bizon et al., 2015). También están los basados en una doble banda de histéresis, que persiguen reducir la degradación que los sistemas de hidrógeno sufren a consecuencia de los arranques y paradas (Ziougou et al., 2011). A estos se suman los SGE basados en modelos, donde se pueden encontrar aplicaciones de control predictivo para resolver problemas complejos de optimización multivariable (Hu et al., 2021), o de técnicas multiobjetivo lineales invariantes en el tiempo para optimizar la distribución energética en el corto plazo, así como para reducir la complejidad asociada a los problemas no lineales (Freire et al., 2020). Sin embargo, entre las referencias consultadas, no se garantiza un control real del bus de CC ni se considera el uso y gestión de sistemas de pila de combustible de tipo modular.

Para tratar con problemas complejos de control y fuertemente no lineales, la técnica de control borroso tipo Mandani (Mamdani and Assilian, 1975) lleva décadas

mostrando éxitos desde el punto de vista práctico. Así, el problema de control no necesita de un modelo explícito, sino que se puede reemplazar mediante reglas lingüísticas fácilmente interpretables (Barragan et al., 2020). Esto permite incorporar a las reglas el conocimiento de un experto en el problema de control abordado (Andújar et al., 2007). En concreto, para el problema propuesto en este trabajo, se encuentran en la literatura diferentes soluciones basadas en control lógico borroso (CLB), como un CLB optimizado mediante algoritmos genéticos y evolutivos para reducir los costes de operación de la red eléctrica principal y de las horas de operación del sistema de almacenamiento, teniendo en cuenta la variabilidad en los precios de la red eléctrica principal y la intermitencia de las FER (Athari & Ardehali, 2016). Otro ejemplo es un CLB para el control de los convertidores de potencia de los generadores renovables y de los sistemas de almacenamiento, para así regular la tensión en el bus de CC en la microrred (Nabipour et al., 2020).

Por ser los elementos más delicados y caros, las acciones de control se suelen centrar en mejorar la eficiencia del ciclo completo de hidrógeno (producción-almacenamiento-consumo). Así, nuevamente en el ámbito de los CLB, se pueden encontrar SGE cuyo objetivo es conseguir que la pila de combustible opere en su punto de mayor eficiencia (Keskin Arabul et al., 2017), o optimizar la eficiencia del sistema de almacenamiento junto a los costes de la red eléctrica principal (Al-Sakkaf et al., 2019).

La principal novedad de este trabajo es que utiliza un SGE basado en un CLB que permite la gestión de una microrred renovable hibridada con hidrógeno de uso residencial, la cual está conectada a la red principal, e integra el ciclo completo de hidrógeno, cargas residenciales y recarga de vehículos eléctricos. Además, para satisfacer la demanda en el corto y medio plazo, integra un sistema de almacenamiento basado en baterías de plomo ácido, cuya función es también estabilizar la tensión en el bus de CC. Esto permite que los controladores locales de las fuentes renovables que vierten energía al bus de CC solo se preocupen de la máxima transferencia de potencia, no de estabilizar la tensión a su salida. Asimismo, la microrred integra una pila de combustible multi-stack (PCME), en concreto dos. El CLB diseñado que implementa el SGE, permite una operación segura de la microrred en función de la energía almacenada, la tensión del bus de CC, el balance de potencia, la degradación y eficiencia del sistema de almacenamiento y el coste de intercambio con la red eléctrica principal, lo cual ha permitido resolver un problema complejo multiobjetivo. Además, los resultados de la simulación muestran una mejora en el comportamiento de la microrred a nivel técnico y económico.

2. Descripción de la microrred objeto de estudio

La microrred, ubicada en la Universidad de Huelva, cuenta con un bus de 360 VCC alimentado por un campo de paneles fotovoltaicos (FV) de 10 kWp de potencia, conectado mediante un convertidor de CC/CC al bus de CC. Para el almacenamiento de energía, se dispone, para la respuesta en el corto-medio plazo, de un banco de baterías de plomo ácido de 36 kWh y, para la respuesta en el largo plazo, de un sistema de hidrógeno formado por un electrolizador alcalino de 1 Nm³/h, un tanque de hidrógeno a 30 bar de 1 Nm³ de capacidad volumétrica y un sistema de modular de pila de

combustible de tipo PEM (membrana de electrolito de polímero) de 6 kW. El sistema de pila de combustible está implementado a partir de dos stacks conectados en paralelo con diferente grado de degradación cada uno. Por último, la microrred cuenta con una comunicación bidireccional con la red eléctrica principal (Figura 1).

El balance de potencia de la microrred vendrá definido por la diferencia entre la generación de origen renovable y la demanda (CVAC es el conjunto calefacción, ventilación y aire acondicionado), que debe ser satisfecha bien por el sistema híbrido de almacenamiento de energía (SHAE) o bien por la red eléctrica principal. El criterio de signo elegido por los autores es: signo negativo en el balance de potencia implica potencia extraída del bus, mientras que el signo positivo implica potencia inyectada en el bus de CC (1):

$$P_{BAL}(k) = P_{FV}(k) - P_{CARGA}(k) = \underbrace{P_{BAT}(k) + P_{H_2}(k)}_{P_{HESS}(k)} + P_{RED}(k) \quad (1)$$

Donde:

$P_{FV}(k)$: potencia generada por los paneles FV (W).

$P_{CARGA}(k)$: potencia demandada por la carga (W).

$P_{BAT}(k)$: potencia de batería (W).

$P_{H_2}(k)$: potencia del sistema de hidrógeno (W).

$P_{RED}(k)$: potencia de la red eléctrica principal (W).

$P_{H_2}(k)$ y $P_{RED}(k)$ se pueden expresar como (2):

$$P_{H_2}(k) = \begin{cases} P_{ELE}(k), & P_{H_2}(k) < 0 \\ P_{PCME}(k), & P_{H_2}(k) \geq 0 \end{cases} \quad (2)$$

$$P_{Grid}(k) = \begin{cases} P_{REDSAL}(k), & P_{RED}(k) < 0 \\ P_{REDEN}(k), & P_{RED}(k) \geq 0 \end{cases}$$

Donde:

$P_{ELE}(k)$: potencia consumida por electrolizador (W).

$P_{PCME}(k)$: potencia generada por la PCM (W).

$P_{REDSAL}(k)$: potencia vertida a la red eléctrica principal (W).

$P_{REDEN}(k)$: potencia suministrada por la red eléctrica principal (W).




Figura 1. Arquitectura de la microrred objeto de estudio.

3. Diseño del SGE basado en lógica borrosa

Debido a la reducida vida útil de las pilas de combustible, altamente dependientes de las condiciones de

operación, la PCME requiere acciones de control locales para evitar altas degradaciones del mismo (Calderón et al., 2020). Además, debido a la baja eficiencia del ciclo de hidrógeno, es necesario considerar la potencia de operación, el tiempo de operación y el número de ciclos.

Por otra parte, desde el punto de vista económico, se debe calcular el punto de ajuste de potencia de la microrred en función del balance de potencia, de la energía almacenada y el coste de conexión con la red principal.

3.1. Estructura del controlador lógico borroso

Debido a que la operación del SHAE y la interacción con la red eléctrica principal dependen del balance de potencia, se ha definido un SGE (Figura 2) basado en los controladores siguientes: uno para momentos de exceso de potencia (CLB_E) y otro para momentos de déficit (CLB_D), los cuales operan en paralelo. Además, se emplea un controlador basado en eventos (CBE) para determinar las variables de salida del CLB en función del signo del balance de potencia. Por último, con objeto de aumentar la vida útil de la PCME, se ha diseñado un CLB local (CLB_{PCME}) que calcula la potencia de operación de cada stack en función de su degradación acumulada.




Figura 2. Estructura de control del SGE.

3.2. Conjuntos borrosos

Los universos de discurso de cada variable borrosa han sido definidos teniendo en cuenta los límites seguros de operación que garantizan el correcto funcionamiento de la microrred, así como las especificaciones de los fabricantes. En Tabla 1 se recogen los límites inferiores y superiores de cada una de las variables borrosas de la Figura 2.

Tabla 1. Rango operativo de las variables borrosas

Variable	Límite inferior	Límite superior	Variable	Límite inferior	Límite superior
$C_{VE}(k)$	0,03 €/kWh	0,08 €/kWh	$P_{BAL}(k+1)$	-10 kW	10 kW
$C_{CE}(k)$	0,03 €/kWh	0,12 €/kWh	$P_{PCME}(k)$	0 kW	6 kW
$D_{EST1,2}(k)$	0 mV/celda	100 mV/celda	$EO_{EST1,2}(k)$	0 kW	3 kW
$NH(k)$	3 Nm ³	27 Nm ³	$SOC(k)$	50%	90%
$P_{BAL}(k)$	-10 kW	10 kW	$V_{BAT}(k)$	330 V	420 V

Donde:

$C_{VE}(k)$: precio de venta de energía a red (€/kWh).

$C_{CE}(k)$: precio de compra de energía a red (€/kWh).

$D_{EST1,2}(k)$: degradación de cada stack (mV/celda).

$NH(k)$: nivel de hidrógeno almacenado en el tanque (Nm^3).

$EO_{EST1,2}(k)$: estado de operación de cada stack (ON/OFF).

$SOC(k)$: estado de carga de batería (%).

$V_{BAT}(k)$: voltaje de batería (V).

Atendiendo al diseño de la Figura 2, se han definido 3 bases de reglas borrosas, una para cada controlador: CLB_E (situación de exceso de potencia en la microrred), CLB_D (situación de déficit de potencia en la microrred) y CLB_{PCME} (control de los stacks de la PCME). Las reglas de cada base se han definido mediante funciones de pertenencia trapezoidales y triangulares con un grado de pertenencia en el intervalo $[0,1]$.

Las bases de reglas han sido diseñadas en función del modo de funcionamiento requerido para el SGE: cuando hay exceso de potencia renovable en la microrred (CLB_E , Figura 4), éste se utiliza, en primera instancia, para recargar la batería (esto mantiene estable la tensión en el bus de CC) y, después, se balancea, en función del precio de venta de energía a la red eléctrica principal y las reservas de hidrógeno disponibles. Cuando la situación es de déficit de potencia renovable en la microrred (CLB_D , Figura 4), se prioriza garantizar el balance de potencia mediante recursos propios (primero mediante la energía almacenada en las baterías y, a continuación, mediante el hidrógeno almacenado en el tanque).

4. Resultados

En primer lugar, se ha tenido en cuenta un perfil de generación FV en la zona climática de Huelva (suroeste de España) basado en el valor medio de la generación anual y en el que el perfil de demanda se basa en el consumo típico de una familia, de acuerdo a los datos del Instituto para la Diversificación y el Ahorro Energético (IDAE). En Figura 3, se recoge el perfil de potencia de las diferentes variables de la microrred de la Figura 1: potencia renovable (PFV), potencia para calefacción, ventilación y aire acondicionado (PCVAC), potencia destinada a la recarga del vehículo eléctrico (PVE) y potencia para aplicaciones del hogar (PAH).

A partir de una simulación durante 791 días (coincidiendo con el tiempo en el que se el sistema de pila de combustible sufre la mayor degradación posible), se selecciona el primer tramo de operación (entre las horas 8 y 56) y el último tramo de operación (entre las horas 18.920 y 18.968), Figura 4. Por otra parte, para validar el comportamiento del SGE desarrollado (SGE-CLB), se compara en la Figura 5 la degradación de los dos stacks que conforman la PCME con la que tendrían al aplicar otros SGE propuestos en la literatura. En concreto, dos de naturaleza predictiva: SGE-MPC1 (García-Torres et. al., 2015), SGE-MPC2 (Valverde et. al., 2016), y otro basado en histéresis: SGE-HIST (Vivas et. al., 2017).






Figura 3. Perfil de potencia de las variables de generación y consumo de la microrred: PFV, PCVAC, PVE y PAH.



(a)



(b)

Figura 4. Variables de potencia de la microrred para el SGE desarrollado durante: a) primer tramo (horas 8 a 56); b) último tramo (horas 18.920 a 18.968).




Figura 5. Degradación de cada stack para diferentes SGE: basados en MPC (1 y 2), basado en histéresis (HIST) y el desarrollado en este trabajo basado en lógica borrosa (CLB).

Por último, en la Figura 6 se realiza una comparación del coste de operación de la microrred para el SGE propuesto con respecto al coste obtenido si el SGE aplicado fuera uno de los utilizados para configurar la Figura 5. Cuando hay conexión con la red eléctrica principal, coste > 0 significa compra de energía y coste < 0 significa venta de energía. Por conexión permanente a la red eléctrica ha de entenderse la conexión usual, esto es, que la microrred no existiera.




Figura 6. Coste de operación de la microrred para el SGE (LB), en comparación con los SGE confrontados.

5. Discusión

En primer lugar, como se recoge en las Figura 4(a) y (b), el comportamiento de la microrred varía entre las primeras horas de funcionamiento de la PCME y las últimas, pues debido a la degradación acumulada, la red eléctrica principal irá aportando cada vez más potencia para satisfacer la demanda. Por tanto, se hará un menor uso del sistema de hidrógeno a costa de un mayor protagonismo de la red eléctrica principal, lo cual, en consecuencia, originará un mayor coste.

Por otra parte, en cuanto a la degradación de los stacks de la PCME, Figura 5, se observa que el CLB diseñado, al calcular la distribución de potencia entre stacks en base a la

degradación acumulada, consigue que esta sea uniforme en ambos. Sin embargo, los SGE basados en histéresis (HIST) y MPC1, priorizan el uso de los recursos propios de la microrred para independizarla de la red principal, lo cual, además de originar una mayor degradación de los stacks, ésta no está balanceada.

En cuanto al MPC2, debido a que hace un uso más conservativo del SHAE, limita la degradación de los stacks, consiguiendo niveles similares al CLB desarrollado; sin embargo, la degradación de los stacks no es análoga, como así ocurre en el caso de la propuesta de los autores.

En cuanto al coste de operación de la microrred, Figura 6, la propuesta de SGE desarrollado en este trabajo (CLB), presenta un coste considerablemente menor al del resto de SGE analizados, lo cual se deriva de conseguir muy poca dependencia de la red eléctrica principal. Esto, obviamente, se pone mucho más de manifiesto si se analiza la situación usual de conexión permanente con la red eléctrica principal, en cuyo caso, la microrred, con el SGE basado en lógica borrosa desarrollado, produce un ahorro (energía que se dejaría de comprar a la red principal) de más de 3000 kWh, lo cual supone un ahorro de más de 3000 €.

Respecto al resto de SGE considerados, la propuesta de los autores consigue un ahorro de más de 500 kWh comparado con el HIST, de unos 180 kWh en comparación con el MPC1 y de unos 600 kWh para el caso del MPC2. En cuanto a los costes, salvo para el caso del MPC1, que supone un coste de unos -430 € (es decir, supone beneficios respecto a la compra y venta de electricidad a la red principal), el CLB genera también un mayor ahorro económico, cercano a 400 € comparado con el HIST y de más de 600 € comparado con el MPC2.

6. Conclusiones

Este artículo presenta un SGE basado en un CLB para una microrred basada en FER para uso residencial. El propósito es resolver un problema multiobjetivo cuya solución permita mejorar el comportamiento de la microrred desde un punto de vista técnico y económico. Para lograr dicho objetivo, el controlador desarrollado usa dos CLB (uno para los momentos de déficit de potencia renovable en la microrred y otro para los de superávit), así como un CLB local para la gestión de cada stack de una pila de combustible multi-stack. El controlador diseñado incorpora, en sus diferentes niveles, el conocimiento de los expertos en el manejo de microrredes del tipo a la presentada en este trabajo, lo cual se hace en forma de reglas borrosas, muy intuitivas y fácilmente interpretables.

Los resultados muestran que el controlador desarrollado mejora el comportamiento de la microrred en comparación con otros SGE publicados en la literatura. El SGE propuesto reduce la degradación de los stacks de la pila de combustible, consiguiendo además que éste (inevitable), sea uniforme en ambos. Además, consigue un importante ahorro energético (en términos de energía comprada de la red eléctrica principal), lo cual se traduce en un considerable ahorro económico.

En resumen, el SGE desarrollado, además de que se puede resolver de una forma más sencilla y con un lenguaje más intuitivo que otros modelos más complejos, supone mejores resultados en términos técnicos, económicos e incluso

ambientales (pues supone un ahorro de energía que se deja de comprar a la red principal, que sí lleva asociada una huella de carbono debido a que el mix eléctrico de la red principal no está compuesto únicamente por energías renovables; mientras que la energía producida por la microrred es completamente limpia y no conlleva emisiones de carbono asociadas) respecto a otras propuestas de SGE presentes en la literatura.

Acróminos

CLB	Control lógico borroso
CC	Corriente continua
EMS	Energy management system
FER	Fuentes de energía renovables
FLC	Fuzzy logic controller
MPC	Model predictive control
RES	Renewable energy sources
SGE	Sistemas de gestión energética
SHAE	Sistema híbrido de almacenamiento de energía

Símbolos

$C_{ES}(k)$	Precio de venta de energía a red (€/kWh)
$C_{EP}(k)$	Precio de compra de energía a red (€/kWh)
$DFC_{1,2}(k)$	Degradación de pila de combustible (mV/cell)
$HL(k)$	Nivel de hidrógeno almacenado en el tanque (Nm^3)
$P_{BAT}(k)$	Potencia de batería (W)
$P_{ELS}(k)$	Potencia consumida por electrolizador (W)
$P_{Grid}(k)$	Potencia de la red eléctrica principal (W)
$P_{GRIDIN}(k)$	Potencia suministrada por la red eléctrica principal (W)
$P_{GRIDOUT}(k)$	Potencia vertida a la red eléctrica principal (W)
$P_{H_2}(k)$	Potencia del sistema de hidrógeno (W)
$P_{LOAD}(k)$	Potencia demandada por la carga (W)
$P_{MSFC}(k)$	Potencia generada por el sistema modular de pila de combustible (W)
$P_{PV}(k)$	Potencia generada por los paneles PV (W)
$EO_{EST1,2}(k)$	Estado de operación de cada stack (ON/OFF).
$SOC(k)$	Estado de carga de batería (%)
$V_{BAT}(k)$	Voltaje de batería (V)

Agradecimientos

Esta investigación ha sido un resultado del proyecto “H₂ Integración & Control: Integración y Control de una planta piloto basada en hidrógeno en aplicaciones residenciales para el suministro de energía” Ref: PID2020-116616RB-C31, financiado por el Gobierno de España. También del proyecto “SALTES: Smartgrid con Arquitectura reconfigurable para ensayo de Técnicas de control y Prioridad de Almacenamiento de Energía” Ref: P20-00730, financiado por el Gobierno de Andalucía.


Referencias

- Abo-Elyousr, F. K., Guerrero, J. M., & Ramadan, H. S. (2021). Prospective hydrogen-based microgrid systems for optimal leverage via metaheuristic approaches. *Applied Energy*, 300, 117384. <https://doi.org/10.1016/J.APENERGY.2021.117384>
- Al-Sakkaf, S., Kassas, M., Khalid, M., & Abido, M. A. (2019). An Energy Management System for Residential Autonomous DC Microgrid Using Optimized Fuzzy Logic Controller Considering Economic Dispatch. *Energies* 2019, Vol. 12, Page 1457, 12(8), 1457. <https://doi.org/10.3390/EN12081457>
- Andújar, J. M., Barragán, A. J., Gegúndez, M. E., & Maestre, M. (2007). Control borroso multivariable basado en heurística. un caso práctico: grúa porta contenedores. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 4(2), 81–89. [https://doi.org/10.1016/S1697-7912\(07\)70212-1](https://doi.org/10.1016/S1697-7912(07)70212-1)
- Athari, M. H., & Ardehali, M. M. (2016). Operational performance of energy storage as function of electricity prices for on-grid hybrid renewable energy system by optimized fuzzy logic controller. *Renewable Energy*, 85, 890–902. <https://doi.org/10.1016/J.RENENE.2015.07.055>
- Barragan, A. J., Enrique, J. M., Segura, F., & Andújar, J. M. (2020). Iterative Fuzzy Modeling of Hydrogen Fuel Cells by the Extended Kalman Filter. *IEEE Access*, 8, 180280–180294. <https://doi.org/10.1109/ACCESS.2020.3013690>
- Bizon, N., Oproescu, M., & Raceanu, M. (2015). Efficient energy control strategies for a Standalone Renewable/Fuel Cell Hybrid Power Source. *Energy Conversion and Management*, 90, 93–110. <https://doi.org/10.1016/J.ENCONMAN.2014.11.002>
- Calderón, A. J., Vivas, F. J., Segura, F., & Andújar, J. M. (2020). Integration of a Multi-Stack Fuel Cell System in Microgrids: A Solution Based on Model Predictive Control. *Energies* 2020, Vol. 13, Page 4924, 13(18), 4924. <https://doi.org/10.3390/EN13184924>
- Freire, V. A., de Arruda, L. V. R., Bordons, C., & Marquez, J. J. (2020). Optimal Demand Response Management of a Residential Microgrid using Model Predictive Control. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2020.3045459>
- García-Torres, F., Bordons, C. (2015) Optimal Economical Schedule of Hydrogen-Based Microgrids With Hybrid Storage Using Model Predictive Control. *IEEE Transactions on Industrial Electronics* 62, 5195–5207. <https://doi.org/10.1109/TIE.2015.2412524>
- Herr, N., Nicod, J. M., Varnier, C., Jardin, L., Sorrentino, A., Hissel, D., & Péra, M. C. (2017). Decision process to manage useful life of multi-stacks fuel cell systems under service constraint. *Renewable Energy*, 105, 590–600. <https://doi.org/10.1016/J.RENENE.2017.01.001>
- Hu, J., Shan, Y., Guerrero, J. M., Ioinovici, A., Chan, K. W., & Rodriguez, J. (2021). Model predictive control of microgrids – An overview. *Renewable and Sustainable Energy Reviews*, 136, 110422. <https://doi.org/10.1016/J.RSER.2020.110422>
- Jafari, M., Malekjamshidi, Z., Lu, D. D. C., & Zhu, J. (2019). Development of a Fuzzy-Logic-Based Energy Management System for a Multiport Multioperation Mode Residential Smart Microgrid. *IEEE Transactions on Power Electronics*, 34(4), 3283–3301. <https://doi.org/10.1109/TPEL.2018.2850852>
- Keskin Arabul, F., Arabul, A. Y., Kumru, C. F., & Boynuegri, A. R. (2017). Providing energy management of a fuel cell–battery–wind turbine–solar panel hybrid off grid smart home system. *International Journal of Hydrogen Energy*, 42(43), 26906–26913. <https://doi.org/10.1016/J.IJHYDENE.2017.02.204>
- Mamdani, E. H. and S. Assilian (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine studies*, 7(1), 1–13. [https://doi.org/10.1016/S0020-7373\(75\)80002-2](https://doi.org/10.1016/S0020-7373(75)80002-2)
- Marx, N., Boulon, L., Gustin, F., Hissel, D., & Agbossou, K. (2014). A review of multi-stack and modular fuel cell systems: Interests, application areas and on-going research activities. *International Journal of Hydrogen Energy*, 39(23), 12101–12111. <https://doi.org/10.1016/J.IJHYDENE.2014.05.187>
- Nabipour, N., Qasem, S. N., & Jermisittiparsert, K. (2020). Type-3 fuzzy voltage management in PV/Hydrogen fuel cell/battery hybrid systems. *International Journal of Hydrogen Energy*, 45(56), 32478–32492. <https://doi.org/10.1016/J.IJHYDENE.2020.08.261>
- Ullah, K., Hafeez, G., Khan, I., Jan, S., & Javaid, N. (2021). A multi-objective energy optimization in smart grid with high penetration of renewable energy sources. *Applied Energy*, 299, 117104. <https://doi.org/10.1016/J.APENERGY.2021.117104>
- Valverde, L., Bordons, C., Rosa, F. (2016). Integration of fuel cell technologies in renewable-energy-based microgrids optimizing operational costs and durability. *IEEE Transactions on Industrial Electronics*, 63, 167–177. <https://doi.org/10.1109/TIE.2015.2465355>
- Vivas, F. J., De las Heras, A., Segura, F., & Andújar, J. M. (2018). A review of energy management strategies for renewable hybrid energy systems with hydrogen backup. *Renewable and Sustainable Energy Reviews*, 82, 126–155. <https://doi.org/10.1016/J.RSER.2017.09.014>
- Vivas, F. J., De las Heras, A., Segura, F., Andújar, J. M. (2017). H2RES2 simulator. A new solution for hydrogen hybridization with renewable energy sources-based systems. *International Journal of Hydrogen Energy*, 42, 13510–13531. <https://doi.org/10.1016/j.ijhydene.2017.02.139>
- Ziougou, C., Ipsakis, D., Elmasides, C., Stergiopoulos, F., Papadopoulou, S., Seferlis, P., & Voutetakis, S. (2011). Automation infrastructure and operation control strategy in a stand-alone power system based on renewable energy sources. *Journal of Power Sources*, 196(22), 9488–9499. <https://doi.org/10.1016/J.JPOWSOUR.2011.07.029>



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Aprendizaje por refuerzo profundo para la negociación en control predictivo distribuido cooperativo de sistemas multivariables

Aponte, O.E.^{1,*}, Vega, P.¹, Francisco, M.¹

¹ Departamento de Informática y Automática, Facultad de Ciencias, Universidad de Salamanca, Plaza de la Merced, s/n, 37008, Salamanca, España.

To cite this article: Aponte, O.E., Vega, P., Francisco, M. 2022. Deep reinforcement learning for negotiation in cooperative distributed predictive control of complex systems. XVII Simposio CEA de Control Inteligente.

Resumen

En este trabajo se propone una solución novedosa del uso de redes neuronales con aprendizaje por refuerzo, como una opción válida en la negociación de agentes de controladores jerárquicos distribuidos. El método propuesto se implementa en la capa superior de una arquitectura de control jerárquico constituido en sus niveles más bajos por un control distribuido basado en modelos locales y procesos de negociación con lógica difusa. La ventaja de la propuesta es que no requiere el uso de modelos en la negociación y facilita la minimización de cualquier índice de comportamiento dinámico y la especificación de restricciones. Concretamente, se utiliza un agente de gradiente de políticas (PG) del aprendizaje por refuerzo para el entrenamiento del proceso de consenso entre los agentes. El algoritmo se aplica con éxito a un sistema de nivel compuesto por ocho tanques interconectados muy difícil de controlar por su naturaleza no lineal y la alta interacción existente entre sus subsistemas.

Palabras clave: Redes neuronales, Aprendizaje por refuerzo, control distribuido predictivo basado en modelos, sistemas multiagente.

Deep reinforcement learning for negotiation in cooperative distributed predictive control of complex systems

Abstract

In this work, a novel solution of the use of neural networks with reinforcement learning is proposed, as a valid option in the negotiation of distributed hierarchical controller agents. The proposed method is implemented in the upper layer of a hierarchical control architecture constituted in its lower levels by a distributed control based on local models and fuzzy logic negotiation processes. The advantage of the proposal is that it does not require the use of models in the negotiation and facilitates the minimization of any dynamic behaviour index and the specification of constraints. Specifically, in this work, a reinforcement learning policy gradient (PG) algorithm is used to train the consensus process between agents. The resulting algorithm is successfully applied to a level system made up of eight interconnected tanks, which is very difficult to control due to its non-linear nature and the high level of interaction between its subsystems.

Keywords: Neural networks, Reinforcement learning, fuzzy logic, distributed model predictive control, multiagent systems

1. Introducción

Cuando los requisitos computacionales y de comunicación involucrados en un problema de control centralizado predictivo por modelo, en inglés "Model predictive control" (MPC), son inviables desde un punto de vista práctico, una posible solución es utilizar MPC distribuidos, en inglés "Distributed model predictive control" (DMPC), para dividir el problema en varios

más simples (Cembellín et al., 2019). Entre ellos los basados en sistemas multiagente y negociación son una alternativa útil que ha sido la empleada en este trabajo (Francisco et al., 2019; Masero et al., 2021). La tarea crítica para resolver el problema del consenso en sistemas multiagentes es diseñar protocolos de control distribuido basados en la información de cada agente y sus vecinos. Además, en el campo de control, es de vital importancia el uso de estrategias que permitan a los agentes cambiar

* Autor para correspondencia: idu17344@usal.es

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

sus decisiones en línea, de acuerdo con los cambios en el entorno o el comportamiento de otros agentes con el fin de lograr un acuerdo conjunto sobre un interés común.

Las técnicas adecuadas que se pueden aplicar en este contexto son las metodologías de redes neuronales basadas en el aprendizaje por refuerzo, en inglés Reinforcement Learning (RL), que ofrecen muchas ventajas y que han motivado el desarrollo de muchos algoritmos para la toma de decisiones y el control, proporcionando el estudio de todas las propiedades de estabilidad, convergencia y viabilidad que implica un problema de control (Sierra-García et al., 2022; Aponte et al., 2022). Precisamente, uno de los principales objetivos de este proyecto es proponer nuevas técnicas basadas en aprendizaje por refuerzo para resolver en los juegos multijugador en tiempo real los problemas que surgen en el control distribuido cooperativo.

El aprendizaje por refuerzo tiene como objetivo principal la capacitación de un agente para que complete una tarea en un entorno incierto, esta capacitación se lleva a cabo a través de un entrenamiento que consiste en la interacción agente-entorno. El agente aprende por medio de ensayo y error, enviando una acción al entorno, y recibiendo de este, un estado y recompensa, ambas, consecuencia de la acción (Sutton and Barto, 2018). El estado indica la influencia de la acción sobre el entorno, mientras que la recompensa califica a la acción.

El objetivo global de este trabajo es el desarrollo de una metodología (PG DMPC) de control multiagente que permita el uso de técnicas pertenecientes al campo del DMPC y el agente PG del aprendizaje por refuerzo para implementar los procesos de negociación entre agentes. Concretamente, se realiza en este trabajo una propuesta novedosa de aprendizaje por refuerzo en las capas superiores de la jerarquía de control y su aplicación a un sistema multivariable de control no lineal (Masero et al., 2021).

El resto del artículo está organizado de la siguiente manera. En la sección dos se describen los algoritmos de control, el método de negociación del que se parte y el método propuesto. La sección tres describe el agente de aprendizaje por refuerzo, la cuarta sección el caso de estudio. El quinto apartado contiene la implementación del método. En el sexto se presentan los resultados del entrenamiento y validación, en el séptimo apartado los resultados, y en octavo las conclusiones.

Notación: La secuencia de entrada de dimensión N_p en cada instante de tiempo t se define como $U(t) = [u(t), u(t+1), \dots, u(t+N_p-1)]^T$ y la secuencia óptima es $U^*(t) = [u^*(t), u^*(t+1), \dots, u^*(t+N_p-1)]^T$.

2. Formulación del problema

Estando el sistema compuesto por un conjunto $\mathcal{N} = \{1, 2, \dots, N\}$ de subsistemas acoplados a la entrada cuya evolución de estado es

$$x_i(t+1) = A_i x_i(t) + B_{ii} u_i(t) + w_i(t), \quad (1)$$

donde $t \in \mathbb{N}_0$ denota el instante de tiempo; $x_i \in \mathbb{R}^{q_i}$ y $u_i \in \mathbb{R}^{r_i}$ son, respectivamente, los vectores de estados y entradas de cada subsistema $i \in \mathcal{N}$, restringido en los conjuntos convexos que contienen el origen en su interior $\mathcal{X}_i = \{x_i \in \mathbb{R}^{q_i} : A_{x,i} x_i \leq b_{x,i}\}$ y $\mathcal{U}_i = \{u_i \in \mathbb{R}^{r_i} : A_{u,i} u_i \leq b_{u,i}\}$, respectivamente; y $A_i \in \mathbb{R}^{q_i \times q_i}$ y $B_{ii} \in \mathbb{R}^{q_i \times r_i}$ son matrices de dimensiones propias. El vector

de perturbaciones medibles $w_i \in \mathbb{R}^{q_i}$ representa el acoplamiento con otros subsistemas j perteneciente al conjunto de vecinos $\mathcal{N}_i = \{j \in \mathcal{N} \setminus \{i\} : B_{ij} \neq 0\}$, es decir,

$$w_i(t) = \sum_{j \in \mathcal{N}_i} B_{ij} u_j(t), \quad (2)$$

donde $u_j \in \mathbb{R}^{r_j}$ es el vector de entrada del subsistema $j \in \mathcal{N}_i$, y la matriz $B_{ij} \in \mathbb{R}^{q_i \times r_j}$ modela el acoplamiento de entrada entre i y j . Es más, w_i está acotado en un conjunto convexo $\mathcal{W} = \bigoplus_{j \in \mathcal{N}} B_{ij} \mathcal{U}_j$ debido a las limitaciones del sistema. El vecino afectado por la agente i se define como $\mathcal{M}_i = \{j \in \mathcal{N} \setminus \{i\} : B_{ji} \neq 0\}$. Desde el punto de vista global, la evolución general del sistema se puede definir como

$$x_N(t+1) = A_N x_N(t) + B_N u_N(t), \quad (3)$$

donde $A_N = [A_{ij}]_{i,j \in \mathcal{N}}$ y $B_N = [B_{ij}]_{i,j \in \mathcal{N}}$ son, respectivamente, las matrices de estados y entradas de todo el sistema.

Siendo el objetivo, obtener el vector de entrada U_N ponderado a través de negociación por pares empleando un coeficiente ϕ generado por una red neuronal profunda bajo el formato de aprendizaje por refuerzo.

En cada instante de tiempo t , la función de costo del subsistema $i \in \mathcal{N}$ se calcula con base en las trayectorias de sus estados y entradas sobre una ventana futura de longitud N_p (el llamado horizonte de predicción):

$$\begin{aligned} J_i(x_i(t), U_i(t), U_j(t)) \\ = \sum_{k=0}^{N_p-1} L_i(x_i(t+k), u_i(t+k)) + \\ F_i(x_i(t+N_p)), \end{aligned} \quad (4)$$

donde $L_i(\cdot)$ es la función de costes de estado, y $F_i(\cdot)$ la función de coste terminal, definidas como

$$\begin{aligned} L_i(x_i(t+k), u_i(t+k)) = \\ (x_i(t+k) - x_{r_i}(t+k))^T Q_i x_i(t+k) \\ + (u_i(t+k) - u_{r_i}(t+k))^T R_i (u_i(t+k) - u_{r_i}(t+k)), \\ F_i(x_i(t+N_p)) = (x_i(t+N_p) - x_{r_i}(t+N_p))^T \\ P_i (x_i(t+N_p) - x_{r_i}(t+N_p)), \end{aligned} \quad (5)$$

siendo Q_i una matriz definida semipositiva, y R_i, P_i siendo matrices definidas positivas. Siendo x_{r_i} y u_{r_i} , las referencias calculadas para obtener un error estacionario nulo según (Francisco et al., 2015).

3. Arquitectura de control

La comunicación entre los agentes se realiza mediante una red que se puede modelar como el grafo indirecto $\mathcal{G} = (\mathcal{N}, \mathcal{L})$ donde $\mathcal{N}$ es el conjunto de agentes y $\mathcal{L}$ es el conjunto de enlaces bidireccionales $\mathcal{L} \subseteq \mathcal{L}^N = \{\{i, j\} : \{i, j\} \subseteq \mathcal{N}, i \neq j\}$ (Maestre et al., 2011). Un enlace $l_{ij} \in \mathcal{L}$ conecta los agentes i y j dando un flujo de información bidireccional. Si dos agentes están conectados por un enlace de comunicación l_{ij} siguen un esquema cooperativo por pares para encontrar un consenso entre sus secuencias de control a través de un algoritmo multicapa de negociación de lógica difusa en la primera capa.

3.1. Capa de control de bajo nivel

La primera capa de control emplea un algoritmo DMPC para múltiples agentes (Masero et al., 2021). Las negociaciones con lógica difusa se realizan en pares teniendo en cuenta los acoplamientos con los subsistemas vecinos. Para ello, se emplea una secuencia desplazada de agente i , que es definida añadiendo $K_i x_i(t + N_p)$ a la secuencia elegida en el paso previo $U_i(t - 1)$:

$$U_i^s(t) = \begin{bmatrix} u_i(t+1|t-1) \\ u_i(t+2|t-1) \\ \vdots \\ u_i(t+N_p-1|t-1) \\ K_i x_i(t+N_p|t-1) \end{bmatrix} = \begin{bmatrix} u_i^s(t) \\ u_i^s(t+1) \\ \vdots \\ u_i^s(t+N_p-2) \\ u_i^s(t+N_p-1) \end{bmatrix}. \quad (6)$$

El algoritmo empleado, Algoritmo 1, es una extensión del esquema DMPC propuesto por (Maestre et al., 2011) para n subsistemas.

Algoritmo 1: Algoritmo DMPC.

Para cada paso de tiempo t :

1. En cada instante t cada agente i mide $y_i(t)$ y estima el estado inicial para la predicción del MPC.
2. El agente i calcula su trayectoria desplazada y la envía a sus vecinos.
3. Cada agente i minimiza su función de costo J_i teniendo en cuenta que su vecino j aplica su trayectoria desplazada. Los otros subsistemas vecinos siguen sus trayectorias de control actuales $U_j^s(t)$. Específicamente, el agente i resuelve:

$$U_i^*(t) = \arg \min_{U_i(t)} J_i(x_i(t), U_i(t), U_j^s(t), U_l^s(t)), \quad (7)$$

Sujetos a las siguientes restricciones sobre entradas, estados y restricción de estado terminal Ω_i :

$$x_i(t+k+1) = A_i x_i(t+k) + B_{ii} u_i(t+k) + B_{ij} u_j(t+k) + \sum_{l \in \mathcal{N} \setminus \{j\}} B_{il} u_l(t+k), \quad (8)$$

$$\begin{aligned} x_i(t) &= \tilde{x}_i(t), \quad i \in \mathcal{N}, \\ x_i(t+k) &\in \mathcal{X}_i, \quad k = 0, \dots, N_p - 1, \\ x_i(t+N_p) &\in \Omega_i, \\ u_i(t+k) &\in \mathcal{U}_i, \quad k = 0, \dots, N_p - 1, \\ u_j(t+k) &= u_j^s(t+k), \quad k = 0, \dots, N_p - 1, \\ u_l(t+k) &= u_l^s(t+k), \quad k = 0, \dots, N_p - 1, \end{aligned} \quad (9)$$

donde se establece Ω_i se impone como restricción de estado terminal del agente, detalles sobre el cálculo de Ω_i se pueden ver en (Masero et al., 2021).

4. El agente i optimiza nuevamente su costo $J_i(\cdot)$ manteniendo su secuencia de entrada óptima $U_i^*(t)$ fija para encontrar su secuencia de entrada vecina deseada $U_j^{w_i}(t)$. Aquí, también se considera que los subsistemas l siguen sus trayectorias actuales.

$$U_j^{w_i}(t) = \arg \min_{U_j(t)} J_i(x_i(t), U_i^*(t), U_j(t), U_l^s(t)), \quad (10)$$

5. Comunicación entre agentes: el agente i envía $U_j^{w_i}(t)$ al agente j y recibe $U_i^{w_j}(t)$.

3.2. Negociaciones difusas por pares

Al algoritmo DMPC le sigue la negociación difusa (Masero et al., 2021) para obtener una solución de control que garantice la estabilidad y disminuya el índice de desempeño. La negociación se realiza entre cada pareja de agentes $\{U_i^*(t), U_i^s(t), U_i^{w_j}(t)\}$ y $\{U_j^*(t), U_j^s(t), U_j^{w_i}(t)\}$. El sistema de inferencia difusa para la negociación genera la acción de control final $U_i^f(t)$ y $U_j^f(t)$ que llega a la segunda capa, teniendo en cuenta algunas restricciones operacionales y económicas.

3.3. Negociación RL por pares

El método propuesto se implementa en esta capa de la arquitectura de control, dado el agente i acoplado a través de entradas con sus vecinos y las dos de secuencias de control $\{U_i^{f_1}(t), U_i^{f_2}(t)\}$ obtenidas de dos negociaciones difusas por pares, esta última capa es la encargada de aplicar el proceso de negociación por pares empleando una red neuronal profunda bajo el método de aprendizaje por refuerzo.

La secuencia de control final $U_i^f(t)$ se calcula como la ponderación de las dos secuencias de control de las negociaciones difusas por pares de la capa anterior:

$$U_i^f(t) = U_i^{f_1}(t) \cdot \phi_i + U_i^{f_2}(t) \cdot (1 - \phi_i), \quad (11)$$

donde ϕ_i es el valor discreto de la salida de la red neuronal que otorga un peso a cada secuencia de la negociación par del agente i , con $\phi_i \in [0, 1]$. El valor de ϕ_i permite que en la negociación la secuencia final $U_i^f(t)$ pueda ser $U_i^{f_1}(t)$ o $U_i^{f_2}(t)$ o la ponderación de ambas secuencias.

4. Algoritmo del aprendizaje por refuerzo

La red aprende la negociación a través del método de aprendizaje por refuerzo en (Sutton and Barto, 2018), esta negociación permite la optimización de cualquier índice de comportamiento dinámico relacionado con la estabilidad, el rendimiento, la economía y el tratamiento de restricciones adicionales no contempladas en los niveles inferiores del sistema jerárquico de control.

En el aprendizaje por refuerzo la política determina qué acción a_t tomar en función de un estado s_t dado por el entorno. Los agentes basados en políticas parametrizan directamente la función de la política $\pi_\theta(\cdot)$ en referencia a los parámetros θ . El agente implementado es el de gradiente de política (PG) (Williams, 1992), que es un método de aprendizaje por refuerzo en línea y que no requiere del modelo. Un agente PG es un agente basado en políticas que utiliza el algoritmo REINFORCE para buscar una política óptima que maximice la recompensa acumulada esperada a largo plazo G_t .

La política utilizada por el agente PG implementado es una política estocástica discreta. La política π_θ estocástica genera una distribución categórica de probabilidad sobre las acciones $\pi_\theta(s_t|a_t) = \mathbb{P}[s_t|a_t]$, siendo $\mathbb{P}$ la función de probabilidad. Una distribución categórica es una distribución de probabilidad discreta que describe los posibles resultados de una variable aleatoria que puede tomar una de k , con $k > 0$, categorías posibles. Con la probabilidad de cada categoría especificada por separado $p_1, \dots, p_k$. Los parámetros que especifican las probabilidades de cada resultado posible están limitados a estar en el rango de 0 a

1, y todos deben sumar a 1, expresado como $p_i > 0, \sum p_i = 1$. Los agentes basados en políticas abordan la búsqueda de la política, Algoritmo 3, como un problema de optimización. En el agente PG la política es optimizada con el método de optimización de gradiente de políticas (comparte el nombre con el agente). Este método emplea el gradiente ascendente para encontrar los valores de los parámetros θ con los que se obtiene el máximo local de la función objetivo del agente PG, $\nabla_{\theta} \ln \pi(s_t; \theta) \cdot G_t$.

Algoritmo 3: Algoritmo de entrenamiento: REINFORCE.

1. Se inicializa la política $\pi(s; \theta)$ con valores aleatorios de θ .
2. En cada episodio de entrenamiento, se genera la experiencia del episodio siguiendo la política $\pi(s)$. El agente aplica acciones hasta que se alcanza el estado terminal s_T . La experiencia del episodio consiste en una secuencia $(s_0, a_0, r_1, s_1, \dots, s_{T-1}, a_{T-1}, r_T, s_T)$ donde, s_t es el estado, a_t es la acción aplicada dado un estado, s_{t+1} es el siguiente estado, y r_{t+1} es la recompensa recibida al pasar del estado s_t al s_{t+1} .
3. Para cada estado en la secuencia del episodio, con $t = 1, 2, \dots, T - 1$, se calcula recompensa acumulada esperada G_t , con $G_t = \sum_{c=t}^T \gamma^c r_c$.
4. Se calcula el gradiente para maximizar la recompensa acumulada esperada. $d\theta = \sum_{t=1}^{T-1} G_t \cdot \nabla_{\theta} \ln \pi(s_t; \theta)$
5. Se actualizan los parámetros de la política aplicando el gradiente, $\theta = \theta + \alpha d\theta$
Aquí, α es la tasa de aprendizaje de la política.
6. Se repite del punto 2 al 5 para cada episodio de entrenamiento hasta que el entrenamiento finaliza.

El REINFORCE se basa en trayectorias, donde el retorno de una trayectoria τ con $R(\tau)$ se calcula como la recompensa total de esa trayectoria: $R(\tau) = (G_t, G_{t+1}, \dots, G_{T-1})$, donde cada G_t es la recompensa que se espera acumular desde el instante t hasta $T-1$. La función de puntuación $\nabla_{\theta} \ln \pi(s_t; \theta)$ permite que se logre la optimización sin requerir del modelo dinámico del sistema, optimizando el gradiente del logaritmo de $\pi(s_t|a_t)$ que expresa la probabilidad de que el agente seleccione la acción a_t dado un estado s_t .

5. Caso de estudio

La planta de laboratorio sobre la que se han probado las estrategias de control planteadas en este trabajo está formada por ocho tanques acoplados figura (1). El sistema se divide en $N = 4$ subsistemas: los tanques 1 y 3 pertenecen al subsistema 1; los tanques 2 y 4 forman el subsistema 2; los tanques 5 y 7 forman parte del subsistema 3; y el resto tanques forman el subsistema 4. La planta es controlada por 4 bombas que proporcionan un caudal q_m con $m \in \{a, b, c, d\}$ ubicadas en los subsistemas 1, 2, 3 y 4 respectivamente.

Cada subsistema tiene asociado un agente. Cada agente es un controlador local DMPC que utiliza un modelo local en variables de estado y una función objetivo local, que calcula la señal para su subsistema y la señal para su subsistema vecino.




Figura 1: Sistema de 8 tanques interconectados.

h_n es el nivel del tanque $n \in \{1, 2, \dots, 8\}$, se define el punto de operación del nivel del tanque h_n^0 para $n \in \{1, 2, \dots, 8\}$ como $h_1^0 = 0,1, h_2^0 = 0,15, h_3^0 = 0,07, h_4^0 = 0,03, h_5^0 = 0,1, h_6^0 = 0,15, h_7^0 = 0,025, h_8^0 = 0,1$ (unidades: metros), y el punto de funcionamiento de tasa de flujo de las bombas q_m^0 para $m \in \{a, b, c, d\}$ como $q_a^0 = 0,142, q_b^0 = 0,421, q_c^0 = 0,421, q_d^0 = 0,140$ (unidades: m^3/h). El modelo de espacios de estado no lineal y de tiempo discreto es

$$\tilde{x}_N(t+1) = A_N \tilde{x}_N(t) + B_N \tilde{u}_N(t), \quad (12)$$

donde el vector de estados es $\tilde{x}_N = [h_1(t) - h_1^0, \dots, h_8(t) - h_8^0]^T$; el vector de entradas $\tilde{u}_N = [q_a(t) - q_a^0, \dots, q_d(t) - q_d^0]^T$; y A_N, B_N son las correspondientes matrices del sistema global. Similarmente, el sistema dinámico de cada subsistema $i \in \{1, 2, 3, 4\}$ son

$$\begin{aligned} \tilde{x}_i(t+1) &= A_i \tilde{x}_i(t) + B_{ii} \tilde{u}_i(t) + \tilde{w}_i(t), \\ \tilde{w}_i(t) &= \sum_{j \in N_i} B_{ij} \tilde{u}_j(t), \end{aligned} \quad (13)$$

donde $w_i(t)$ representa el acoplamiento con sus vecinos $j \in N_i$, y las correspondientes matrices A_i, B_{ii}, B_{ij} de los subsistemas se pueden ver en (Masero et al., 2021). Además, los vectores de estados y entradas están limitados por

$$\begin{aligned} -h_n^0 < \tilde{x}_n(t) &\leq 0,08, \quad -q_m^0 < \tilde{u}_m(t) \leq 0,04, \\ \forall n \in \{1, 2, \dots, 8\}, \forall m \in \{a, b, c, d\}. \end{aligned}$$

Las matrices $Q_N = \text{diag}(Q_i)_{i \in N}$ y $R_N = \text{diag}(R_i)_{i \in N}$ son, respectivamente, las correspondientes matrices de pesos constantes. Donde Q_i y R_i se pueden ver en (Masero et al., 2021). Además, la ganancia de retroalimentación local K_i y la matriz de ponderación del costo terminal P_i son definidas según Masero et al. (2021).

El objetivo de control es un problema de regulación en el que los niveles (h_1, h_2, h_5, h_6) deben alcanzar los niveles de referencia $(h_{r1}, h_{r2}, h_{r5}, h_{r6})$ considerando el costo operativo y satisfaciendo las restricciones operativas. Por lo tanto, es un problema de control multivariable con cuatro variables controladas (h_1, h_2, h_5, h_6) y cuatro variables manipuladas (q_a, q_b, q_c, q_d) .

6. Elementos del agente PG en negociación entre agentes

Estos elementos del agente PG son el entorno, el estado s_t , la acción discreta a_t , la recompensa r_{t+1} y la red neuronal profunda empleada como función de aproximación de la política (ver

manual de MATLAB, Reinforcement Learning Toolbox). El entorno formado por los subsistemas y su arquitectura de control, recibe la acción, y consecuencia de esta, le envía al agente un estado y una recompensa, descritas en las siguientes secciones.

6.1. Estado y acción

El estado que envía el entorno al agente está formada por 20 valores que son las cuatro secuencias de señales de la capa inferior que se negocian por pares con $N_p = 5$.

La negociación se realiza entre las secuencias de señales del agente 2, $\{U_2^{f1}, U_2^{f2}\}$, y entre las señales del agente 3, $\{U_3^{f1}, U_3^{f2}\}$, siendo el estado $s_t = \{U_2^{f1\tau}, U_2^{f2\tau}, U_3^{f1\tau}, U_3^{f2\tau}\}$.

La acción $a_t = \{\phi_1, \phi_2\}$ que pertenecen al intervalo $[0, 1]$. Siendo $\phi_i = 0,05 \cdot \gamma$ con $i \in \{1, 2\}$ y $\gamma \in \{1, 2, 3, \dots, 20\}$. Cada valor de ϕ_i otorga un peso específico a las señales continuas para obtener la señales definitivas discretizadas, $U_2^f(k)$ y $U_3^f(k)$, de los subsistemas 2 y 3:

$$U_2^f(t) = U_2^{f1}(t) \cdot \phi_1 + U_2^{f2}(t) \cdot (1 - \phi_1) \quad (14)$$

$$U_3^f(t) = U_3^{f1}(t) \cdot \phi_2 + U_3^{f2}(t) \cdot (1 - \phi_2) \quad (15)$$

6.2. Recompensa

Durante el entrenamiento el entorno emplea la recompensa r_{t+1} para indicarle al agente la calificación que otorga el entorno a la acción a_t , según el objetivo del entorno. La recompensa es un escalar que para el correcto aprendizaje debe contener información lo suficientemente representativa del objetivo del entorno, siendo el objetivo del entorno ajustar los niveles de los tanques (h_1, h_2, h_5, h_6) a cada uno de sus niveles referencia objetivo ($h_{r1}, h_{r2}, h_{r5}, h_{r6}$).

La función de recompensa $r_{t+1}(\cdot)$, ecuación (16), está en función de la diferencia al cuadrado entre el nivel actual de los tanques 1, 2, 5 y 6, y sus niveles de referencia objetivo, formalizadas por la siguiente expresión, ecuaciones (17). con $n \in \{1, 2, 5, 6\}$

$$r_{t+1}(e_n) = \begin{cases} 2000, & \text{Si } e_n < e_{b_n} \forall n \\ -1000, & \text{En caso contrario} \end{cases} \quad (16)$$

$$e_n = (h_n(t) - h_{rn}(t))^2. \quad (17)$$

La acción a_t dado un estado s_t determina $h_n(t+1)$. Para que durante el entrenamiento el agente obtenga el máximo valor de recompensa, cada e_n debe ser menor que su correspondiente e_{b_n} con $n \in \{1, 2, 5, 6\}$, de lo contrario la recompensa será -1000 . Los valores de e_{b_n} obtenidos de forma empírica son $e_{b_1} = 6,21 \cdot 10^{-8}$, $e_{b_2} = 1,5 \cdot 10^{-8}$, $e_{b_5} = 8,5 \cdot 10^{-9}$, $e_{b_6} = 1,8 \cdot 10^{-7}$.

Para evitar que la acción esté fuera de rango $[0, 1]$ se impone una penalización z_{t+1} que aumenta cuanto más lejos de este rango se encuentran los valores de la acción, como se muestra en la ecuación (18). Si $\phi_i \notin [0, 1]$ entonces $r_{t+1} = z_{t+1}$, donde $\phi_i = \{\phi_1, \phi_2\}$.

$$z_{t+1} = -3000 - ((|\phi_1| + |\phi_2|) \times 1000) \quad (18)$$

6.3. Red neuronal profunda

La red neuronal profunda, cuya estructura se muestra en la tabla 1, fue empleada como función de aproximación de la política. El algoritmo REINFORCE obtiene los pesos que configuran a la red para que devuelva una acción a_t que maximiza la recompensa esperada acumulada a largo plazo dado un estado s_t . La tasa de aprendizaje del agente, $\alpha = 0,001$, es un hiperparámetro que controla cuánto debe cambiar el modelo en respuesta al error estimado cada vez que se actualizan los pesos del modelo. Los canales de entrada de la red se corresponde con el estado, y la salida de la red es la acción con tantos elementos como el número de las posibles combinaciones de valores discretos.

Tabla 1: Red neuronal de la política.

Capas	Neuronas
FeatureInputLayer	20
FullyConnectedLayer	400
ReLULayer	400
FullyConnectedLayer	400
ReLULayer	400
FullyConnectedLayer	300
TanhLayer	300
ScalingLayer	300
FullyConnectedLayer	465

7. Resultados

7.1. Entrenamiento

Los resultados de la simulación se han obtenido utilizando la Reinforcement Learning Toolbox de MATLAB. El entrenamiento consistió en 1000 episodios de 100 pasos t cada episodio, Donde la recompensa total en cada episodio ep_s es la suma de las recompensas de 100 pasos, $ep_s = \sum_{t=1}^{100} r_t$ con $s = 1, 2, \dots, 1000$. El periodo de muestreo utilizado por los controladores predictivos en los niveles más bajos fue $T = 5$. Las condiciones de entrenamiento fueron: $h_{rn} = h_n^0 + 0,02 \cdot h_n^0$ y el punto de partida seleccionado de forma aleatoria al principio de cada episodio del intervalo siguiente $[h_n^0 - h_n^0 \cdot 0,01, h_n^0 + h_n^0 \cdot 0,01]$.




Figura 2: Entrenamiento agente PG.

El gráfico de entrenamiento figura 2. muestra la suma de las recompensas obtenidas en todos los pasos de cada episodio de

entrenamiento. La suma pequeña de los valores de las recompensas corresponde a una alta presencia de penalizaciones. A medida que la política converge hacia la política óptima estas penalizaciones son menos recurrentes, por lo que la suma de las recompensas tomará valores más altos.

7.2. Validación

Para validar los resultados se realizó una simulación de 100 segundos, con el mismo h_{rn} utilizado en el entrenamiento y con h_n^0 como punto de partida. Los resultados del agente propuesto (PG DMPC) son comparados con el DMPC con lógica difusa (FL DMPC) (Masero et al., 2021) y el MPC centralizado, considerando los siguientes índices de desempeño:

- $Pred_{Total} = \sum_i J_i(\cdot)$, la suma de los errores de predicción de los tanques 1, 2, 5 y 6, más el esfuerzo de control de las bombas, con $i \in$ a todos los subsistemas $\{1, 2, 3, 4\}$.
- $ISE_{Total} = \sum_n ISE_n$, la suma de las integrales de los errores cuadráticos de los niveles de los tanques n , siendo cada $ISE_n = \int_0^{100} (h_n(t) - h_{rn}(t))^2 dt$.
- $Er_{Total}(t) = \sum_n (h_n(t) - h_{rn}(t))^2$, la suma de las diferencias al cuadrado de los niveles de los tanques n ,
- $EB_{Total}(t) = \sum_m PE_m(t)$, suma de las energías de bombeo m , para cada bomba m , como la suma del promedio de la energía de bombeo sobre el horizonte de predicción, siendo proporcional a los flujos de agua proporcionadas por las bombas:

$$EB_m(t) = \frac{0,04}{3600N_p} \sum_{k=1}^{N_p} q_m(t+k) \quad (19)$$

Como muestra la tabla 2. el control centralizado MPC es siempre el controlador con los valores de $Pred_{Total}$, ISE_{Total} , Er_{Total} y EB_{Total} más pequeños debido a la disponibilidad de información completa de la planta para las predicciones dado que utiliza un modelo global de la planta. Por otro lado, los controladores distribuidos (PG DMPC y FL DMPC) que utilizan los mismos modelos locales proporcionan, como cabía esperar, resultados parecidos.

Tabla 2: Comparación entre las técnicas consideradas

	PG DMPC	FL DMPC	Centralizado MPC
$Pred_{Total}$	0.032750	0.032615	0.019584
ISE_{Total}	0.043036	0.042962	0.030126
Er_{Total}	0.009407	0.009392	0.006825
EB_{Total}	0.006466	0.006467	0.006462

El PG DMPC emplea como criterio en la negociación sólo el error de ajuste de los niveles en forma de recompensa, mientras que el FL DMPC emplea más criterios, reglas difusas, dando al control mayor flexibilidad para un ajuste más preciso. No obstante, el algoritmo propuesto permite a futuro usar otros criterios a través de la recompensa, y además, a pesar de utilizar valores discretos presenta un buen ajuste de los niveles.

8. Conclusiones

Los resultados del PG DMPC tienen calidad suficiente para considerar al método una alternativa con coste computacional menor al control centralizado, y además, PG DMPC no requiere en su implementación de la complejidad que va implícita en un control centralizado. La metodología propuesta podría ser implementada en todas las capas de la arquitectura de control sin tener que formular los modelos locales del sistema, necesarios en un control centralizado que involucra mayor coste computacional.

9. Agradecimientos

Este trabajo ha sido realizado gracias al apoyo del proyecto PID2019-105434RB-C31 del programa Estatal de proyectos de investigación y del proyecto de la Fundación Samuel Solórzano FS/11-2021.


Referencias

- Aponte, O., Vega, P., Francisco, M., 2022. Avances en informática y automática. decimoquinto workshop.
- Cembellín, A., Francisco, M., Vega, P. I., 2019. Control predictivo centralizado y distribuido de una red de recogida de aguas residuales. In: XL Jornadas de Automática. Universidade da Coruña, Servizo de Publicacións, pp. 178–185.
- Francisco, M., Mezquita, Y., Revollar, S., Vega, P., De Paz, J. F., 2019. Multi-agent distributed model predictive control with fuzzy negotiation. Expert Systems with Applications 129, 68–83.
- Francisco, M., Skogestad, S., Vega, P., 2015. Model predictive control for the self-optimized operation in wastewater treatment plants: Analysis of dynamic issues. Computers & Chemical Engineering 82, 259–272.
- Maestre, J. M., Muñoz, D., Camacho, E. F., 2011. Distributed model predictive control based on a cooperative game. Optimal Control Applications and Methods 32 (2), 153–176.
- Masero, E., Francisco, M., Maestre, J., Revollar, S., Vega, P., 2021. Hierarchical distributed model predictive control based on fuzzy negotiation. Expert Systems with Applications, 176 (114836), 1–13.
- Sierra-García, J. E., Santos, M., Pandit, R., 2022. Wind turbine pitch reinforcement learning control improved by pid regulator and learning observer. Engineering Applications of Artificial Intelligence 111, 104769.
- Sutton, R. S., Barto, A. G., 2018. Reinforcement learning: An introduction. MIT press.
- Williams, R. J., 1992. Simple statistical gradient-following algorithms for connectionist reinforcement learning. Machine learning 8 (3), 229–256.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Sistema automático para recomendación de ejercicios personalizados en la atención del cáncer de mama mediante tecnologías móviles y aprendizaje automático.

Moreno, S.^a, Banos, O.^a, Pomares, H.^a, Damas, M.^{a,*}

^a Departamento de Arquitectura y Tecnología de Computadores, Universidad de Granada, C/Periodista Daniel Saucedo Aranda s/n, 18014, Granada, España.

To cite this article: Moreno, S., Banos, O., Pomares, H., Damas, M. 2022. A tom ti s stem or person lise e er ise re ommend tion in re st n er re sing mo ile te nologies nd tom ti le rning. XVII Simposio CEA de Control Inteligente.

Resumen

Aliviar las secuelas del cáncer en general, y en particular del cáncer de mama, es uno de los mayores retos de nuestros tiempos, y precisamente el ejercicio terapéutico se plantea como una solución para paliar los efectos secundarios del cáncer y su tratamiento a corto y largo plazo. No obstante, para que las intervenciones del ejercicio físico sean más efectivas estas deben estar adaptadas a cada paciente según sus capacidades y necesidades de entrenamiento específicas. Dicha adaptación al entrenamiento utilizando tecnologías de salud móvil (mSalud) ya se ha llevado a cabo con éxito en entornos deportivos, y en este trabajo se plantea una aproximación similar para pacientes con cáncer de mama, donde se pretende ajustar de forma individual las dosis de entrenamiento a las necesidades de cada paciente. Para ello, se ha diseñado y desarrollado un sistema completo de mSalud que ha permitido extraer un conjunto de datos longitudinal con mediciones de la carga del ejercicio de pacientes de cáncer de mama. A partir de dichos datos se están utilizando técnicas de ciencia de datos y aprendizaje automático para extraer los diferentes estados de recuperación de las pacientes a lo largo de una intervención en ejercicio físico, lo cual nos permitirá plantear un sistema de ayuda a la toma de decisiones para prescribir dosis individualizadas de ejercicio terapéutico.

Palabras clave: cáncer de mama, mSalud, ejercicio terapéutico, ciencia de datos, sistema de ayuda a la toma de decisiones.

Automatic system for personalised exercise recommendation in breast cancer care using mobile technologies and machine learning

Abstract

Alleviating the sequelae of cancer in general, and breast cancer in particular, is one of the greatest challenges of our times, and therapeutic exercise is precisely one solution to alleviate the side effects of cancer and its treatment in the short and long term. However, in order to make exercise interventions more effective, they must be adapted to each patient according to their specific training needs and abilities. Such adaptation to training using mobile health technologies (mHealth) has already been successfully carried out in sports settings, and this work proposes a similar approach for breast cancer patients, where the aim is to individually adjust the training doses to the needs of each patient. To this end, a complete mHealth system has been designed and developed to extract a longitudinal dataset of exercise load measurements from breast cancer patients. To leverage these data, data science and machine learning techniques are being used to extract the different states of recovery of patients throughout a physical exercise intervention, which will allow us to propose a decision support system to prescribe individualized doses of therapeutic exercise.

Keywords: breast cancer, mHealth, therapeutic exercise, data science, decision-support system.

1. Introducción

El ejercicio terapéutico (ET) plantea un medio para paliar los efectos secundarios a corto y largo plazo del cáncer y su tratamiento (Ballard-Barbash et al., 2012; Schmid & Leitzmann, 2014). Sin embargo, la personalización de las intervenciones del ET todavía presenta un desafío. Las estrategias de personalización que se utilizan normalmente en las intervenciones del ET a menudo se basan en el autocontrol de los pacientes y se adhieren a las pautas de recomendación de ejercicios (Campbell et al., 2019). Esto da como resultado la asignación de la misma cantidad de prescripción de ejercicio para cada paciente.

Las tecnologías móviles aplicadas a la salud (mSalud) pueden mejorar la personalización del ET al proporcionar datos objetivos, comparables y cuantificables sobre la salud y el desempeño de cada paciente durante la intervención (Kelly & Shahrokni, 2016; Beg et al., 2017).

La carga de entrenamiento interna (CEI) es el estrés fisiológico y psicológico individual y relativo que sienten los pacientes debido al entrenamiento y al resto de actividades de su vida diaria (Bourdon et al., 2017; Halson, 2014). El control de la variabilidad de la frecuencia cardíaca (VFC) y el bienestar autoinformado se utilizan normalmente como medidas de CEI para controlar la adaptación al entrenamiento (Buchheit, 2014; Hooper & Mackinnon, 1995).

En este trabajo se presenta un enfoque de agrupamiento para estudiar la adaptación al entrenamiento de pacientes con cáncer de mama durante la intervención del ET, con el objetivo de identificar los perfiles de recuperación de los pacientes y poder plantear un sistema automático de recomendación de ejercicios terapéuticos personalizados, tal como se muestra en la figura 1.

2. Materiales y métodos

2.1. Conjunto de datos

Se han recolectado datos de CEI de 23 pacientes con cáncer de mama durante la intervención del ET, obteniendo el conjunto de datos ATOPE+Breast, que está disponible en abierto para la comunidad científica en Zenodo (Moreno-Gutiérrez et al., 2022). Los datos de CEI se recopilaban utilizando el sistema ATOPE+ mHealth (Moreno-Gutiérrez et al., 2021).

Los datos de CEI consisten en medidas de bienestar autoinformado (recuperación, angustia, fatiga, satisfacción del sueño) y VFC (en el dominio de tiempo y la frecuencia). Los pacientes registraron su CEI todas las mañanas en las mismas condiciones de medición para evaluar sus necesidades de entrenamiento. Además, el conjunto de datos ATOPE+Breast incluye datos de actividad física (AF) y sueño de un Fitbit Inspire HR, así como anotaciones manuales de las sesiones de ejercicio (ver figura 2).

2.2. Análisis de los datos

Se ha usado principalmente el algoritmo de k-medias para extraer los grupos que permiten observar las diferentes preparaciones a la hora de realizar ejercicio terapéutico para cada participante en todas las medidas diarias.





Figura 1: Arquitectura del sistema completo diseñado (en azul módulos aún en desarrollo).






Figura 3: Agrupamiento con K-medias para las características de VFC seleccionadas ($k=4$).

La figura 4 presenta los resultados de la agrupación para las características autoinformadas y $k=3$. De acuerdo con el criterio de los expertos médicos durante el análisis, los grupos encontrados pueden interpretarse de la siguiente manera:

- Grupo 0 (azul): bienestar regular autodeclarado.
- Grupo 1 (naranja): bienestar autodeclarado malo.
- Grupo 2 (verde): bienestar autodeclarado bueno.




Figura 4: Agrupamiento con K-medias para las características de bienestar autoinformadas seleccionadas ($k=3$).

Los distintos grupos encontrados en los resultados casan con los distintos estados de adaptación al entrenamiento encontrados en la literatura (Buchheit et al., 2014). Teniendo en cuenta estos grupos y usando técnicas de aprendizaje automática se puede construir un sistema de ayudar a la toma de decisiones para los expertos, tal como se ha indicado en la figura 1 y en el que estamos trabajando actualmente.

4. Conclusión

En este trabajo se ha presentado un análisis para la identificación de perfiles de recuperación en pacientes con cáncer de mama durante el ejercicio terapéutico, utilizando para ello los datos recolectados por un sistema de m-salud (ATOPE+) desarrollado previamente por nuestro equipo. Los grupos encontrados utilizando técnicas de ciencia de datos pueden ayudar a la toma de decisiones diaria en la prescripción

de dosis de entrenamiento personalizadas al estar adecuadas al estado de la paciente. El código desarrollado hasta ahora está disponible para la comunidad científica en GitHub (<https://github.com/salvador-moreno/atope-breast-clustering-analysis>).

La inclusión de modelos de predicción y evaluación del riesgo asistirían mejor a los expertos a la hora de prescribir ejercicio. Además, una estrategia de aprendizaje por refuerzo podría terminar de ayudar a la individualización del ejercicio tras una definición exhaustiva de las métricas a optimizar durante una intervención de ejercicio terapéutico.

La metodología presentada aquí podría utilizarse también en otras poblaciones, como pacientes con otros tipos de cáncer u otras condiciones de tipo crónico, como cardiovasculares o neurológicas.

Agradecimientos

Este trabajo ha sido realizado parcialmente gracias al apoyo del Ministerio de Educación, Cultura y Deporte a través del programa de Formación de Profesorado Universitario (FPU16/04201); los fondos de investigación del Instituto de Salud Carlos III (PI18/01840M); y el Ministerio de Educación, Ciencia y Universidades (PGC2018-098813-B-C31 y RTI2018-101674-B-I00).


Referencias

- Ballard-Barbash, R., Friedenreich, C. M., Courneya, K. S., Siddiqi, S. M., McTiernan, A., & Alfano, C. M. (2012). Physical Activity, Biomarkers, and Disease Outcomes in Cancer Survivors: A Systematic Review. *JNCI Journal of the National Cancer Institute*, 104(11), 815–840.
- Beg, M. S., Gupta, A., Stewart, T., & Rethorst, C. D. (2017). Promise of Wearable Physical Activity Monitors in Oncology Practice. *Journal of Oncology Practice*, 13(2), 82–89.
- Bourdon, P. C., Cardinale, M., Murray, A., Gastin, P., Kellmann, M., Varley, M. C., Cable, N. T. (2017). Monitoring Athlete Training Loads: Consensus Statement. *International Journal of Sports Physiology and Performance*, 12(Suppl 2), S2161–S2170.
- Buchheit, M. (2014). Monitoring training status with HR measures: Do all roads lead to Rome. *Frontiers in physiology*, 5, 73.
- Campbell, K. L., Winters-Stone, K. M., Wiskemann, J., May, A. M., Schwartz, A. L., Courneya, K. S., Schmitz, K. H. (2019). Exercise Guidelines for Cancer Survivors: Consensus Statement from International Multidisciplinary Roundtable. *Medicine and Science in Sports and Exercise*, 51(11), 2375–2390.
- Halsen, S. L. (2014). Monitoring training load to understand fatigue in athletes. *Sports Medicine*, 44 Suppl 2, S139–S147.
- Hooper, S. L. & Mackinnon, L. T. (1995). Monitoring overtraining in athletes. *Recommendations. Sports Medicine*, 20(5), 321–327.
- Kelly, C. M. & Shahrokni, A. (2016). Moving beyond Karnofsky and ECOG Performance Status Assessments with New Technologies. *Journal of Oncology*, 2016, 1–13.
- Moreno-Gutiérrez, S., Postigo-Martin, P., Damas, M., Pomares, H., Banos, O., Arroyo-Morales, M., & Cantarero-Villanueva, I. (2021). ATOPE+: An mHealth System to Support Personalized Therapeutic Exercise Interventions in Patients With Cancer. *IEEE Access*, 9, 16878–16898. DOI: <https://doi.org/10.1109/ACCESS.2021.3049398>
- Moreno-Gutiérrez, S., Postigo-Martin, P., Damas, M., Banos, O., Pomares, H., Arroyo-Morales, M., & Cantarero-Villanueva, I. (2022). ATOPE+Breast, Continuous Monitoring of Training Load in Patients with Breast Cancer during Therapeutic Exercise Intervention. *Zenodo, Dataset*. DOI: <https://doi.org/10.5281/zenodo.6322773>
- Schmid, D. & Leitzmann, M. F. (2014). Association between physical activity and mortality among breast cancer and colorectal cancer survivors: A systematic review and metaanalysis. *Annals of Oncology*, 25(7), 1293–1311.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Classification of red grapes according to their state of ripeness using a low-cost multispectral device

Noguera, M.^{*}, Millan, B., Barragán, A.J., Martínez, M.A., Segura, F., Andújar, J.M.

Centro de Investigación en Tecnología, Energía y Sostenibilidad (CITES). Universidad de Huelva. La Rábida, Palos de la Frontera, 21819 Huelva, España.

To cite this article: Noguera, M., Millan, B., Barragán, A.J., Martínez, M.A., Segura, F., Andújar, J.M. 2022. Classification of red grapes according to their state of ripeness using a low-cost multispectral device. XVII Simposio CEA de Control Inteligente.

Abstract

The present work aims to evaluate a low-cost multispectral device for non-destructive grape ripening status assessment. The proposed device is based on a multispectral sensor, with a spectral response of 18 channels in a range from 410 to 940 nm. The experimental validation was carried out in a commercial vineyard in Rociana del Condado, Huelva. The proposed device was used to analyze 80 grape samples under laboratory conditions. After being processed with the proposed device the grape samples were analyzed with standard chemical methods to generate ground truth values of ripening status indicators (solid soluble content, and acidity). The 18-reflectance data corresponding to the spectral channels of the employed sensor, were used as input variables for developing artificial neural network models to classify the berries samples based on the mentioned ripeness indicators. The obtained results were promising, which paves the way for the implementation of a portable grape ripening appraisal system affordable for grape growers.

Keywords: AS7265x, multispectral, low-cost, grape, ripening, and artificial neural network.

Clasificación de los niveles de maduración de uva tinta mediante un sensor multiespectral de bajo coste

Resumen

El objetivo del presente trabajo fue evaluar la idoneidad de un sensor multiespectral de bajo costo para la determinación del estado de maduración de uvas tintas. El dispositivo propuesto se basa en un sensor multiespectral, con 18 bandas de detección en el rango entre los 410 y los 940 nm. La recogida de muestras se llevó a cabo en un viñedo comercial situado en Rociana del Condado, Huelva. El dispositivo propuesto se utilizó para adquirir la respuesta espectral de 80 racimos de uva en condiciones de laboratorio. Tras esto, cada una de las muestras fue analizada mediante métodos estándar de laboratorio para obtener indicadores objetivos de su estado de maduración (sólidos solubles totales y acidez). Los 18 valores de reflectancia ofrecidos por el sensor fueron usados como datos de entrada para entrenar redes neuronales artificiales para la clasificación de las muestras de uva en función de los parámetros objetivo. Los resultados obtenidos fueron prometedores, lo cual allana el camino hacia la implementación de un sistema para la monitorización del estado de maduración de uvas asequible para los vinicultores.

Palabras clave: AS7265x, multispectral, bajo costo, uva, maduración, y redes neuronales artificiales.

1. Introducción

There are numerous ripeness variables (total soluble solids, acidity, pH, etc) currently used in the winemaking industry for determining the optimum harvest date. The post-harvest status of these parameters is a strong determinant of the features of

the wine to be developed. For example, total soluble solids accumulation in the berries is a prerequisite for the subsequent alcohol content after fermentation in the wine. These variables can be modulated by the grower through cultural practices such as the irrigation regimes, pruning, etc (Hidalgo Togores, 2006; López et al., 2007). Thus, monitoring the ripening of grape berries at several timings during 3–4 weeks prior to harvest

becomes more important as it helps wine growers to make the best management decision.

Traditionally, the assessment of ripeness variables has been done by means of chemical methods. However, these kinds of methodologies require laboratory equipment, expertise personal, and the sample collection in the field and its carry to the laboratory. All of this, make it an elevated cost and limits the number of sample points that can be taken into account. Thus, two main concerns accompany these methods. On the one hand, the representativeness of the berry sample from a given vineyard crop in a given date, and the number of sample dates that can be done between the veraison and the harvest. On the other hand, the time gap between the sample collection and the access to the information limits the decision making of the growers. To overcome these issues, the use of non-invasive sensors in the field, to assess grape composition parameters is a matter of great interest in recent years for the wine industry.

Under this context, spectroscopy have demonstrated to be a powerful, non-invasive technique that is being increasingly applied in the food industry thanks to the development of cheaper, faster, and more accurate sensors (Li et al., 2018; Verrelst et al., 2019). It has come to the market as a rapid and affordable technology to replace the manual classification or other tedious wet chemistry analyses. Some of the near infrared (NIR) applications already implemented in the industry include on-line quality control systems or multi-function sensors to monitor product properties at once. In the wine industry, so far, several works on the application of NIR spectroscopy to wine and grapes have already been carried out with promising results (Fernández-Navales et al., 2019; Garde-Cerdán et al., 2018; González-Caballero et al., 2012; Larraín et al., 2008; Urraca et al., 2016). However, most of these publications are centred in hyperspectral systems, which are expensive, being inaccessible for most growers and winemakers. Furthermore, in many cases, because of its operability, they can be used just in laboratory conditions.

This work presents a custom build low-cost multispectral device, designed to be portable. The proposed device was evaluated for the classification of grape berries based in ripeness variables (total soluble solids and acidity) in a non-destructive way by means of measurements taken under laboratory conditions.

2. Materials and methods

2.1. Spectral System

The proposed device included an AS7265x development board, based on the AS7265x smart spectral sensor family (AMS, AG, Austria). This sensor is composed by 3 chips, having each of them 6 independent on-device optical filters whose spectral response is defined in a range from 410nm to 940nm, with full width at half maximum (FWHM) of 20nm. The combination of the three sensors results in an 18-channel multispectral sensor. As light source, an array of three IR broadband emitter (OSLON P1616 SFH 4737, OSRAM, Germany), was used. This component is developed specifically for spectroscopy applications, because of its stable emission range. The controller of the whole device is a low-cost development platform, specifically an Arduino MKR-Zero

board (Arduino LLC, Italy). Once the device is turned on it generate a new data file to store the measurements. Then, it waits for a user input (pressing of the trigger button) to capture a sample spectrum. When capturing is triggered, the Arduino board sends the command to the sensor, and turns on the LEDs (with a software selectable current) and gathers data. Then, the acquired data and interesting information, such as file names, are stored in a SD-card for further analysis. The controller board can be connected to a PC for configuring internal parameters of the device (exposure time, gain, lighting time, and led current) by means of a custom software. In order to help and guide the user during the measurement, the developed device includes a display, specifically a 0.96 inch OLED panel with a resolution of 128 by 64 pixels. The availability of an integrated display avoids the use of a computer in the field or some other external device to verify the status of the device and its proper operation, also delivering real-time data. The system is powered by a 2s LiPo (Lithium-ion Polymer) battery connected to the device controller board. The device enclosure was designed using Freecad 0.16 and manufactured with a 3D printer using biodegradable polylactic acid (PLA) 3D printer filament. Three different parts were designed: a handle that holds the trigger button, a dome that holds the light source and integrate a light diffusion film (OptSaver L-9960, Kimoto LDT, Switzerland) placed in front of the sensor to homogenising the illumination, and finally the body of the device which include two different parts (front and back) to provide a perfect enclosure and holds the rest of the components. Figure 1 shows the developed multispectral device. All device elements are housed inside the developed casing, except the battery, which is installed outside to avoid temperature interferences with the sensor that could affect the precision of the measurement, as well as to simplify its field replacement.




Figure 1. Custom build multispectral device.

2.2. Experimental set up

In order to evaluate the potential of the proposed multispectral device to classify grape berries based on its ripening status, an experiment was carried out. The first step was a sample collection in a vineyard under the “Condado de Huelva” appellation (Bodegas Contreras Ruiz, S.L, in Rociana del Condado, Huelva). This vineyard is cultivated with red variety (Syrah). The experimental field have a heterogeneous distribution regarding the composition and the structure of the soil. This is reflected in the physiology of the plants, with

zones where the ripening is delayed. Thus, to access to an enough variability in terms of maturation, the sample collection was carried out randomly along the entire experimental field, on a date close to the harvest date (according to the criterium of the grower). A set of 80 grape cluster were collected and immediately packaged and labelled for its transport to laboratory.

The second phase of the experiment was taken under laboratory conditions. Each grape sample was processed with the proposed multispectral device. An acquisition chamber was used to isolate the spectral measurement procedure to minimize signal noise. The capture signal was done by facing the dome of the device with the upper side of the clusters and making two captures per sample, being the average reflectance of the two spectra considered as representative data of each sample. Once every 15 samples a capture of a known reflectance surface (53%) was taken, to calibrate the samples reflectance to prevent eventual errors due to variations of the light source. The 18 reflectance signals of the known reflectance surface were used as reference for normalizing the samples reflectance in the 18 bands acquired by the proposed device.

2.3. Reference Analyses

Once the spectral signal of the samples was acquired, they were subjected to destructive, chemical methods to obtain objective indicators of their actual ripening status. In this work, soluble solid content and acidity were defined as target parameters since they are widely accepted by the winery industry. Each grape cluster was shelled. Then, 50 grapes per cluster were randomly selected, which were squeezed to obtain the wort. The wort was used to determine the soluble solid content (Brix°) by means of a digital refractometer (HI96801, Hanna instruments, Spain). On the other hand, the wort was also used to assessed grape acidity (g/l sulfuric acid) with an automatic acidity titralyser (LDS1155500, Dujardin-Salleron, France).

2.4. Reference Parameter Modeling by Means of Multispectral Data

Orange 3 was used for data processing and ANN training. This is an open-source tool for data visualization, pre-processing and modelling. The whole data set was discretized to split each reference parameter (soluble solid content, and acidity) into two intervals, so that they each contain approximately the same number of instances. Then, the corrected reflectance of the 18 spectral bands captured by the sensor were used as input variables to train two artificial neural networks (ANN) aimed to classify the berries samples based on each ripeness indicator considered. For this purpose, a multi-layer perceptron (MLP) algorithm with backpropagation was used. The architecture of the neural network employed was composed of a hidden layer with six neurons, eighteen inputs and one output (one model per target parameter). Identity was used as activation function for the hidden layer, and L-BFGS-B as Solver for weight optimization. Figure 2 shows the workflow of the models. Leave-one-out was used as validation method. It holds out one instance at a time, inducing the model from all others and then classifying the held-out

instances. This method is obviously very stable, and reliable so the most suitable for data set with reduced volume.




Figure 2. Simulation workflow of model in Orange 3 data mining tool.

3. Results

Table 1 shows the performance of the proposed artificial neural network models in the classification of grapes samples based on their status related to solid soluble content and Acidity respectively. Here are collected several statistical parameters such as the precision (proportion of true positives among instances classified as positive), the recall (proportion of true positives among all positive instances in the data), and the F1 (a weighted harmonic mean of precision and recall). The performance of the neural network was similar for the two ripeness variables considered and satisfactory in both cases, with F1 values approximately of 0.70.

	F1	Precision	Recall
Soluble solid content (Brix°)	0.70	0.70	0.70
Acidity (g/l sulfuric acid)	0.67	0.68	0.67

Table 1. Performance statistics of the proposed artificial neural network models.

The tables 2 represent the confusion matrix resulting of the leave one out test of the neural networks intended to classify the grape samples based on soluble solid content and acidity status respectively. The confusion matrix gives the proportion of instances between the predicted and actual class.

Table 2. Confusion matrix resulting of the leave one out test of the neural networks intended to classify the grape samples based on soluble solid content and acidity status.

Soluble solid content (Brix°)	Actual	Predicted			
		< 16.4	< 16.4	> 16.4	
			73 %	32.6 %	41
			> 16.4	27 %	67.4 %
		37	43	80	

Acidity (g/l sulfuric acid)	Actual	Predicted			
		< 4.68	< 4.68	> 4.68	
			64.4 %	28.6 %	39
			> 4.68	35.6 %	71.4 %
		45	35	80	

4. Conclusions

The objective of this work was to evaluate the suitability of a custom build multispectral device for grape berries ripening assessment. The 18 reflectance values captured by the sensor were used as input to train artificial neural network models aimed to classify grapes berries according to ripeness variables (soluble solid content and acidity) acquired by chemical methods. The satisfactory results showed by both models suggests a correlation between the spectral signature acquired by the sensor and the status of both parameters in the fruit. The good performance showed by the proposed device along with its low-cost and easy to use paves the way for the implementation of a grape berries quality appraisal system affordable for winegrowers. Further, cost saving will allow the sensors to be installed on a permanent basis, continuously monitoring the ripening process in different locations of the orchard, covering its spatial variability. Continuous monitoring of fruit quality conditions would allow adjustment of the moment of harvest according to objective standards instead of subjective criteria such as a visual judgment. This will allow to harvest wineberries in an optimum quality state, assuring the best raw material for wineries and the best economic returns for winegrowers.

Acknowledgements

This work was supported by grant PID2020-119217RA-I00 funded by MCIN/AEI/ 10.13039/ 501100011033, and grant IJC2019-040114-I funded by MCIN/AEI/ 10.13039/501100011033.


References

- Fernández-Navales, J., Garde-Cerdán, T., Tardaguila, J., Gutiérrez-Gamboa, G., Pérez-Álvarez, E.P., Diago, M.P., 2019. Assessment of amino acids and total soluble solids in intact grape berries using contactless Vis and NIR spectroscopy during ripening. *Talanta* 199, 244–253. <https://doi.org/10.1016/j.talanta.2019.02.037>
- Garde-Cerdán, T., Gutiérrez-Gamboa, G., Fernández-Navales, J., Pérez-Álvarez, E.P., Diago, M.P., 2018. Towards the definition of optimal grape harvest time in Grenache grapevines: Nitrogenous maturity. *Sci. Hortic. (Amsterdam)*. 239, 9–16. <https://doi.org/10.1016/j.scienta.2018.05.014>
- González-Caballero, V., Sánchez, M.T., Fernández-Navales, J., López, M.I., Pérez-Marín, D., 2012. On-Vine Monitoring of Grape Ripening Using Near-Infrared Spectroscopy. *Food Anal. Methods* 5, 1377–1385. <https://doi.org/10.1007/s12161-012-9389-3>
- Hidalgo Togores, J., 2006. La calidad del vino desde el viñedo - José Hidalgo Togores - Google Libros. Mundi-Prensa Libros S.A., Madrid.
- Larraín, M., Guesalaga, A.R., Agosin, E., 2008. A multipurpose portable instrument for determining ripeness in wine grapes using NIR spectroscopy. *IEEE Trans. Instrum. Meas.* 57, 294–302. <https://doi.org/10.1109/TIM.2007.910098>
- Li, B., Lecourt, J., Bishop, G., 2018. Advances in Non-Destructive Early Assessment of Fruit Ripeness towards Defining Optimal Time of Harvest and Yield Prediction—A Review. *Plants* 2018, Vol. 7, Page 3 7, 3. <https://doi.org/10.3390/PLANTS7010003>
- López, M.I., Sánchez, M.T., Díaz, A., Ramírez, P., Morales, J., 2007. Influence of a deficit irrigation regime during ripening on berry composition in grapevines (*Vitis vinifera* L.) grown in semi-arid areas. *Int. J. Food Sci. Nutr.* 58, 491–507. <https://doi.org/10.1080/09637480701311801>
- Urraca, R., Sanz-García, A., Tardaguila, J., Diago, M.P., 2016. Estimation of total soluble solids in grape berries using a hand-held NIR spectrometer under field conditions. *J. Sci. Food Agric.* 96, 3007–3016. <https://doi.org/10.1002/jsfa.7470>
- Verrelst, J., Malenovsky, Z., Van der Tol, C., Camps-Valls, G., Gastellu-Etchegorry, J.P., Lewis, P., North, P., Moreno, J., 2019. Quantifying Vegetation Biophysical Variables from Imaging Spectroscopy Data: A Review on Retrieval Methods. *Surv. Geophys.* <https://doi.org/10.1007/s10712-018-9478-y>



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Data aggregator implemented through industrial gateway IOT 2050 for smart microgrid

Folgado, F.J.^{a,*}, González, I.^a, Fernández, J.F.^a, Orellana, D.^a, Calderón, A.J.^a

^a *Departamento de Ingeniería Eléctrica, Electrónica y Automática, Escuela de Ingenierías Industriales, Universidad de Extremadura. Avenida de Elvas s/n, 06006 Badajoz, España.*

To cite this article: Folgado, F.J., González, I., Fernández, J.F., Orellana, D., Calderón, A.J. 2022. Data aggregator implemented through industrial gateway IOT 2050 for smart microgrid. XVII Simposio CEA de Control Inteligente.

Abstract

This paper describes the operation and implementation of a Data Aggregator based on an Industrial Gateway (DAIG) for the storage and transmission of information from an experimental Smart microgrid hybridised with green hydrogen. This DAIG consists of a Siemens IOT 2050, a commercial device that combines physical characteristics such as robustness and open-source software. To achieve this objective, each subsystem involved in the microgrid has a set of sensors and a Data Acquisition Device (DAD) to obtain the relevant logical magnitudes of its operation. The IOT 2050 serves as a centralised system, communicating via Modbus TCP/IP with each DAD and storing the data read in a local database by means of a Python script. Finally, as an example of the application of the designed infrastructure, an IoT software is implemented to visualise the data stored in the DAIG.

Keywords: Microgrid, Industrial gateway, IoT, Database, Modbus TCP/IP.

1. Introduction

In the last decades, the increase in energy demand and the consumption of conventional energy resources, such as fossil fuels, have encouraged the development of technologies for the use of renewable energy resources (RES). In this context, a microgrid or smart microgrid is defined as an electrical system composed of electrical generators and loads of reduced power, whose objective is to satisfy the energy demand partially or totally by means of RES. The term ‘smart’ is used to refer to a microgrid whose management and control is carried out autonomously through devices responsible for these functions, such as programmable logic controllers (PLC).

These systems usually use solar energy and wind energy as the main source of electricity generation, due to the fact that the technologies involved with these RES are widely developed and implemented. On the other hand, hydrogen is being a key factor in the development of new technologies associated with microgrids use. Among its unique properties, the energetic capacity of hydrogen stands out, for which reason it is used in applications in multiple fields, such as the automotive industry (He et al., 2020) or in electrical systems such as microgrids (González et al., 2017).

The generation of hydrogen is solved by means of electrolyzers. The principle of operation of these devices consists of the electrolysis process, whereby an input

compound is separated into its fundamental elements. Electrolyzers are grouped into alkaline, solid acid and Proton Exchange Membrane (PEM). PEM electrolyzers (PEMEL) are widely used in applications combined with renewable energy sources to obtain hydrogen from water, often referred to as green hydrogen (Noussan et al., 2021).

The operation of microgrids is characterised by the interaction between its elements, as well as the large number of devices involved, including the respective sensors and actuators associated with each device to control its behaviour and track its status. As a result, a complex system is obtained where the amount of its components and its high flow of information stand out. These attributes make it imperative to perform the tasks of acquisition, storage, transmission, and analytics of data involved in the operation of the microgrid.

As an example of this need, a number of works dedicated to microgrid data management have been collected in the literature. In (Abdulhussein et al., 2022) the use of ThinkSpeak is described as an applied environment for data storage and real-time analysis of the behaviour of a microgrid whose components are simulated using MATLAB/Simulink. Hosseinzadeh et al. (Hosseinzadeh et al., 2021) performs real-time data acquisition of the operation of a microgrid through a client-server structure via Open Platform Communications (OPC), using LabVIEW as OPC client and transmitting data to a database configured in MySQL. The work of (González et

al., 2017) shows the management of a smart microgrid hybridised with hydrogen, in which a PLC is used as a data acquisition device, together with an OPC client-server structure for data transmission and LabVIEW stores the information. In (Vargas-Salgado et al., 2019) data acquisition is solved by means of a network of Arduino boards, intercommunicated via Wireless Fidelity (WiFi) to a central Arduino. This main Arduino board collects all the information and transfers it to a Raspberry through a serial connection and a Python script. The data received is stored in duplicate in a local database and another hosted on the Web via MySQL.

This paper describes a Data Aggregator based on an Industrial Gateway (DAIG) to accomplish the functions of storage and transmission of information of an experimental hydrogen-hybridised smart microgrid. To this purpose, the device IOT 2050 manufactured by Siemens is used to deploy the DAIG.

The structure of the manuscript is as follows. The second section describes the experimental microgrid and its components, contextualising the operation of the DAIG within the system. Section 3 deals with the principle of operation of the DAIG and its implementation. Section 4 shows an example of DAIG application, through the display of the microgrid data using IoT visualisation software. Finally, a series of conclusions about the work carried out are detailed.

2. Experimental Smart Microgrid

As mentioned above, the principle of operation of a microgrid is based on the interaction between its generation and consumption components or subsystems. In the particular case of the microgrid used in this work, both electrical and hydrogen generation/consumption equipment are installed. An array of interconnected photovoltaic (PV) panels is used as the Electrical Generation (EG) system. A Programmable Electronic Load (PEL) is used as the Electrical Consumption (EC) system to simulate the demand. A water-powered PEMEL performs the Hydrogen Generation (HG) function. The Hydrogen Consumption (HC) task is carried out by a fuel cell, which converts the input hydrogen flow into electric current.

As an additional function, the smart microgrid implements dedicated energy storage equipment. On the one hand, the Electrical Energy storage (EES) is carried out by means of a lithium-ion battery. This EES stabilises the Low Voltage DC (LVDC) bus to which all the aforementioned subsystems are connected. On the other hand, the hydrogen flow generated by HG is collected in a Hydrogen Energy Storage (HES) through metal hydride tanks.

Figure 1 shows the subsystems involved in the operation of the experimental smart microgrid, as well as the relationship between them through the LVDC bus, which facilitates the energy exchange between the components.




Figure 1: Block diagram of smart microgrid: Subsystems and interaction.

3. Operation principle of DAIG

The microgrid described in the previous section is accompanied by a set of sensors to collect the main parameters of the operation of the subsystems. The sensors are physically connected to a Data Acquisition Device (DAD), which translates the signals coming from the sensors into logical magnitudes. These DAD communicate via Ethernet using the Modbus TCP/IP protocol to the DAIG materialised by the Siemens IOT 2050 device.

Modbus was created by Modicon in 1979 for data transmission between PLC and it rapidly became a de facto standard due to its simplicity and open feature (González et al., 2021). The TCP (Transmission Control Protocol) version is based on a client/server structure running on Ethernet. In this regard, it is considered as ideal interface for facilities which involve a multiplicity of devices and software linked together over TCP/IP communication networks (Sanchez-Herrera et al., 2020).

Through this device and communication infrastructure, all data concerning the operation of the microgrid can be aggregated in a single device, the DAIG. As a result, the IOT 2050 serves as a central data storage and access point for further applications. The diagram in Figure 2 depicts the infrastructure designed to achieve this goal, showing the data flow and the communication protocol used.




Figure 2: Infrastructure designed for real-time data accumulation in the DAIG.

Regarding the IOT 2050, its functions are programmed by means of a Python script that is executed in a loop. First, Modbus TCP/IP communication with the DAD is established by defining the IOT 2050 as a client within the client/server structure of this protocol. Next, the magnitudes of each subsystem contained in the memory registers of each DAD are read. Then, the data transmission is completed and the Modbus communication is stopped. Finally, the gathered information is stored in a local database through a write request in SQL (Search Query Language) command. Figure 3 shows a flowchart that summarises the actions carried out by the IOT 2050.




Figure 3: Flowchart of the internal operation of the IOT 2050.

Thanks to the cyclical execution of this internal process, the smart microgrid operation data is obtained in real time. This requires constant consumption of computational resources by the device. With regard to the Siemens IOT 2050, its technical characteristics, certified by the manufacturer, made it suitable for this work, with high performance at hardware level and a software characterised by its open-source nature. In addition, the device has been designed to work under industrial conditions, where dust, vibrations and high-frequency noise predominate. All these features make the IOT 2050 a robust and reliable device in harsh environments, which in the case of the application of this work, ensures optimal operation of the equipment. Figure 4 shows the physical appearance of the IOT 2050 installed in the smart microgrid.




Figure 4: Physical appearance of the IOT 2050 installed in the smart microgrid.

4. DAIG application case: data display through IoT visualisation software

The data collected by the described DAIG can be used for multiple purposes, such as data visualisation, the analysis of the operating trend of the equipment to make a prognosis, or the development of digital replicas or digital twins to build simulated systems whose operation accurately represents the physical system. With regard to this work, the DAIG is applied as a data visualisation system, allowing the user to observe the behaviour of the magnitudes of the system over a period of time, with the aim of understanding and controlling the operation of the smart microgrid. For this purpose, the Grafana software has been implemented within the Siemens IOT 2050 device.

Grafana is a software dedicated to the visualisation of time series by means of database queries. Its operation is characterised by simultaneous access to multiple data sources, such as MariaDB or MySQL. The nature of these databases can be very different, and also, be located in different devices outside the main device running Grafana. Figure 5 describes this peculiar feature of Grafana, indicating the simultaneous access to four different devices with different databases in each one.




Figure 5: Working principle of Grafana: access to multiple devices with different databases.

At a visual level, Grafana is based on screens or dashboards composed of graphic elements that display information to the user, such as graphs or indicators. These elements make it possible to visualise the evolution of a specific magnitude of

the smart microgrid, both in real time and for a selected period of time. As an example of operation, Figure 6 shows the current consumed and the voltage from the HG subsystem for a certain time interval.




Figure 6: HG voltage and current display in Grafana.

At the same time, the IOT 2050 provides information about its internal operation, such as the percentage of RAM used, memory consumed or processes executed. Among these parameters, the CPU temperature stands out as a key factor in the performance of the device. Therefore, the temperature is regulated by means of a fan installed in the heat sink in order to dissipate the heat generated by its nominal operation. Figure 7 shows the CPU temperature for a given period of time, where it can be seen that this magnitude does not exceed 60 °C.




Figure 7: IOT 2050 CPU temperature display in Grafana.

5. Conclusions

This paper has presented a DAIG dedicated to the storage and transmission of data from an experimental smart microgrid hybridised with green hydrogen. For this purpose, the Siemens IOT 2050 device has been used, which combines the robustness and reliability of a commercial device at hardware level, together with its open-source nature at software level. With regard to the operation of the DAIG, its capacity to

centralise data from the microgrid subsystems through Modbus TCP/IP communication with the DAD stands out. For this purpose, all the functions of the IOT 2050 are executed by means of a Python script, in charge of establishing the Modbus communication, as well as reading the data coming from the DAD and storing in the local database. In this work, the visualisation of the data accumulated by means of the IoT software, which runs on the IOT 2050 itself, is illustrated as an application example.

Future research guidelines deal with the assessment of the continuous long-term operation of the DAIG, as well as the implementation of new features for further applications.

Acknowledgments

This project was co-financed by European Regional Development Funds FEDER and by the Junta de Extremadura (IB18041).


References

- Abdulhussein, K., Sumarmad, A., Sulaiman, N., Izzri, N., Wahab, A., Hizam, H. 2022. Microgrid Energy Management System Based on Fuzzy Logic and Monitoring Platform for Data Analysis.
- González, I., Calderón, A.J., Andújar, J.M. 2017. Novel Remote Monitoring Platform for RES-Hydrogen Based Smart Microgrid. *Energy Conversion and Management* vol. 148pp. 489–505. <https://doi.org/10.1016/j.enconman.2017.06.031>.
- González, I., Calderón, A.J., Portalo, J.M. 2021. Innovative Multi-Layered Architecture for Heterogeneous Automation and Monitoring Systems: Application Case of a Photovoltaic Smart Microgrid. *Sustainability (Switzerland)* vol. 13 (4), pp. 1–24. <https://doi.org/10.3390/su13042234>.
- He, H., Wang, X., Chen, J., Wang, Y.-X. 2020. Regenerative Fuel Cell-Battery-Supercapacitor Hybrid Power System Modeling and Improved Rule-Based Energy Management for Vehicle Application. *Journal of Energy Engineering* vol. 146 (6), pp. 04020060. [https://doi.org/10.1061/\(asce\)ey.1943-7897.0000708](https://doi.org/10.1061/(asce)ey.1943-7897.0000708).
- Hosseinzadeh, N., Maashri, A. Al, Tarhuni, N., Elhaffar, A., Al-Hinai, A. 2021. A Real-Time Monitoring Platform for Distributed Energy Resources in a Microgrid—Pilot Study in Oman. *Electronics (Switzerland)* vol. 10 (15), . <https://doi.org/10.3390/electronics10151803>.
- Noussan, M., Raimondi, P.P., Scita, R., Hafner, M. 2021. The Role of Green and Blue Hydrogen in the Energy Transition—a Technological and Geopolitical Perspective. *Sustainability (Switzerland)*. MDPI AG. <https://doi.org/10.3390/su13010298>.
- Sanchez-Herrera, R., Marquez, M.A., Andujar, J.M. 2020. Easy and Secure Handling of Sensors and Actuators as Cloud-Based Service. *IEEE Access* vol. 8pp. 10433–42. <https://doi.org/10.1109/ACCESS.2020.2965639>.
- Vargas-Salgado, C., Aguila-Leon, J., Chiñas-Palacios, C., Hurtado-Perez, E. 2019. Low-Cost Web-Based Supervisory Control and Data Acquisition System for a Microgrid Testbed: A Case Study in Design and Implementation for Academic and Research Applications. *Heliyon* vol. 5 (9), . <https://doi.org/10.1016/j.heliyon.2019.e02474>.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Metodología de reducción del tiempo de ajuste de controladores PID autoajustables basado en hiperesferas

Michelena, A.^{a,b,*}, Zayas-Gato, F.^b, Jove, E.^{a,b}, Quintián, H.^b, Casteleiro-Roca, J.L.^b, Calvo-Rolle, J.L.^{a,b}

^aUniversidad de A Coruña, CITIC. Campus de Elviña, s/n, 15008, A Coruña, España.

^bUniversidad de A Coruña, CTC. Departamento de Ingeniería Industrial. Avda. 19 de febrero s/n, 15405, Ferrol, A Coruña, España.

To cite this article: Michelena, A., Zayas-Gato, F., Jove, E., Quintián, H., Casteleiro-Roca, J.L., Calvo-Rolle, J.L. 2022. Metodología de reducción del tiempo de ajuste de controladores PID autoajustables basado en hiperesferas. XVII Simposio CEA de Control Inteligente.

Resumen

Hoy en día, los controladores adaptativos son ampliamente utilizados en el control de una gran variedad de procesos industriales. En ese tipo de controladores destacan los reguladores PID autoajustables, por ser una solución robusta y de fácil implementación. Sin embargo, este tipo de controladores suelen caracterizarse por tener elevados tiempos de estabilización debido al proceso de identificación que ejecutan en paralelo. Por ello, en el presente trabajo de investigación se presenta un método basado en el uso de hiperesferas y centroides para reducir los tiempos de ajuste y mejorar el rendimiento del lazo de control en los algoritmos PID autoajustables.

Palabras clave: Controlador PID, Centroides, PID autoajustable, Identificación online, RLS

Methodology for reducing tuning time in self-tuning PID controllers based on hyperspheres

Abstract

Nowadays, adaptive controllers are widely used to control a wide variety of industrial processes. In this kind of controllers self-tuning PID highlight for being a robust and easy implementation solution. However, this type of controllers are usually characterized by large settling times, due to the identification process they execute in parallel. Therefore, this research work presents a method based on hyperspheres and centroids to reduce settling times and improve control loop performance in self-tuning PID algorithms.

Keywords: PID controller, Centroids, Self-tuning PID, Online identification, RLS

1. Introducción

En la actualidad, los controladores PID (Proporcional-Integral-Derivativo) son ampliamente empleados en procesos industriales por su alta robustez y fácil implementación. Se estima que más del 90 % de los procesos continuos emplean estos reguladores como elemento de control (Zayas-Gato et al., 2020). Pese a sus facilidades de integración en múltiples sistemas, para conseguir un buen rendimiento de este tipo de controladores, y para optimizar el proceso de control, es necesario el ajuste óptimo de sus parámetros de funcionamiento: ganancia proporcional, integral y derivativa.

Tradicionalmente, el ajuste de las constantes del PID se realizaba de forma manual y empírica empleando diferentes méto-

dos y criterios de sintonía. En sistemas lineales o en aquellos sistemas no lineales pero que operan en un mismo punto de operación, este ajuste manual resulta un proceso válido. Sin embargo, cuando se trata de sistemas no lineales, en los que las dependencias funcionales cambian al variar el punto de operación, el ajuste manual no resulta útil, ya que deben realizarse diferentes procesos de sintonización para cada punto de trabajo.

Por otro lado, la mayoría de los sistemas industriales sufren variaciones temporales, debido al desgaste de sus componentes, etc. Por esta razón, para mantener un buen rendimiento del controlador, es necesario el reajuste de los parámetros del PID después de un determinado tiempo de funcionamiento. Por todo ello, y con el objetivo de solventar los problemas expuestos anteriormente, se desarrollaron técnicas y algoritmos adaptati-

* Autor para correspondencia: alvaro.michelena@udc.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

vos, como los PID's autoajustables (Bobál et al., 2005), que, de forma automática, y a partir de los pesos de la función de transferencia del sistema, son capaces de ajustar las constantes del regulador. Por ello, estos controladores requieren de un sistema de identificación con el que obtener los valores (pesos) de la función de transferencia que describe la dinámica del sistema.

En cuanto al proceso de identificación uno de los métodos mayormente empleados es el método de mínimos cuadrados recursivos (RLS por sus siglas en inglés, Recursive Least Squares), el cual destaca por ser un método de identificación en tiempo real (Islam and Bernstein, 2019). El método de identificación RLS junto con el empleo de PID autoajustables son una combinación frecuente ya que llegan a conseguir un buen rendimiento. Sin embargo, el elevado tiempo de convergencia del proceso de identificación del RLS, el cual se inicializa con valores aleatorios de la función de transferencia, provoca elevados tiempos de establecimiento y acciones de control no deseadas al inicio del proceso.

Para reducir los tiempos de estabilización, se propusieron diferentes métodos, como el Gain Scheduling (Rugh and Shamma, 2000). Sin embargo, este método puede no considerarse adaptativo puesto que no puede adaptarse a las variaciones temporales del sistema.

Teniendo en cuenta lo anteriormente expuesto, en el presente artículo se presenta un método basado en hiperesferas generadas con cada uno de los parámetros de transferencia para un punto de operación, con las que obtener sus centroides para inicializar el proceso de identificación y reducir el tiempo de establecimiento de los PID's autoajustables. Así mismo el valor de los centroides también sirve para sintonizar el controlador.

El presente artículo se estructura de la siguiente manera: después de la presente sección, el caso de estudio y los métodos empleados son expuestos. La sección 3 recoge una detallada descripción de la propuesta planteada, mientras que en la sección 4 se describen los resultados. Por último, la sección 5 recoge las conclusiones y trabajos futuros.

2. Materiales y métodos

En la presente sección se describe tanto la planta sobre la que se ha desarrollado la investigación, como los métodos empleados que intervienen en la solución propuesta.

2.1. Planta de control de nivel

El laboratorio de Optimización y Control de la Escuela Politécnica de Ingeniería de Ferrol (EPIF) de la Universidad de A Coruña (UDC), cuenta con diversas plantas o maquetas que simulan los procesos industriales más comunes. Una de estas maquetas es la planta de control de nivel Figura 1.

La planta de control de nivel está conformada por dos tanques dispuestos a diferentes alturas. El tanque inferior sirve de depósito de agua y para alimentar a la bomba centrífuga, que es la encargada de bombear el agua al depósito superior, en donde se realiza el control de nivel. Para ello, este depósito dispone de un sensor de ultrasonidos en su parte superior con el que medir el porcentaje de líquido almacenado.

La bomba centrífuga está controlado por un variador de frecuencia que se encarga de fijar la velocidad del motor, y de esta manera controlar el caudal de agua impulsado.

Por otro lado, la descarga de agua entre el depósito superior e inferior se realiza a través de un tubo que dispone de una llave de paso manual y una servopilotada, con la que regular también el caudal de salida del depósito superior.




Figura 1: Planta de control de nivel

Tanto para el proceso de adquisición de señales, como para la ejecución de los algoritmos de control, se emplea una placa BeagleBone Black junto con una pequeña placa de acondicionamiento de señales con la que adaptar las tensiones de trabajo del sistema con las de la propia BeagleBone. En la Figura 2 se recoge un esquema de la planta junto a los dispositivos de control y adquisición de datos.




Figura 2: Esquema de la planta de control de nivel

Este sistema es el idóneo para desarrollar los diferentes experimentos planteados y comprobar la validez de la propuesta desarrollada, puesto que el sistema de control de nivel corresponde con un sistema no lineal y variante en el tiempo.

2.1.1. Mínimos cuadrados recursivos (RLS)

El método de Mínimos Cuadrados Recursivos (RLS) es uno de los métodos de identificación paramétrica más empleados,

por su simplicidad y rapidez frente a otros métodos de identificación, lo que le permite trabajar en tiempo real (online) sobre una gran cantidad de aplicaciones (Liu and Li, 2016; Shen et al., 2020; Li et al., 2016).

El objetivo del método RLS es la obtención de un conjunto de parámetros (pesos de la función de transferencia) que, aplicados a la ecuación lineal de partida, sean capaces de predecir, junto con los valores de entrada, el valor de salida del sistema con un error mínimo. La iteración de este proceso se basa en la optimización de la función de coste, en este caso, en la minimización del error de predicción.

El RLS es un algoritmo recursivo, por lo que el sistema tiene en cuenta de la misma manera todos los datos de entradas y salidas almacenados. Por ello, con el objetivo de detectar variaciones del sistema a lo largo del tiempo, resulta fundamental dar mayor importancia, a las últimas mediciones obtenidas (valor de entradas y salidas) ya que son las señales que mejor representan la dinámica actual del sistema. Por ello este algoritmo integra un factor de olvido, λ , usualmente con valores $\lambda \in [0,8, 1]$ (Zhang et al., 2013), que sirve para controlar la “memoria” del algoritmo. El valor de memoria es inversamente proporcional al valor de λ , es decir, cuanto menor sea su valor mayor será la memoria del algoritmo y viceversa. Así mismo, cuanto menor es la “memoria” del algoritmo mayor es su sensibilidad, lo que puede producir errores de identificación a causa del ruido. Por contra, valores altos de λ provocan que el proceso de identificación se vuelva más robusto pero más lento, pudiéndose presentar deficiencias a la hora de detectar variaciones en el sistema de estudio (Ciochina et al., 2009).

2.1.2. PIDs autoajustables

Los reguladores PID autoajustables son un tipo de controlador PID que no necesita un ajuste previo de sus constantes de funcionamiento K_p , T_i y T_d , sino que estas se calculan de forma automática en función de los pesos de la función de transferencia del sistema a controlar.

En la actualidad hay una gran variedad de PIDs autoajustables basados en diferentes teorías o técnicas. En la presente investigación se emplearán 2 métodos distintos de autoajuste para comprobar la funcionalidad de la propuesta desarrollada. Estos métodos son: PID autoajustable basado en margen de fase prefijado y PID autoajustable basado en asignación por polos.

- PID autoajustable basado en margen de fase prefijado: que como su propio nombre indica se basa en fijar el margen de fase del sistema a 60° (Behar and Iranzo, 2003; Vargas Tamani, 2013).
- PID autoajustable basado en asignación por polos: que busca modificar el sistema en cadena cerrada fijando un polo triple en la zona de estabilidad de z^{-1} (Behar and Iranzo, 2003).

3. Propuesta planteada

En general, el método diseñado se ejecuta sobre un lazo de control que incluye tres componentes diferentes: controlador PID autoajustable, algoritmo de identificación RLS y el método basado en hipersferas propuesto. El esquema del lazo de control completo se presenta en la Figura 3.

Teniendo en cuenta el lazo de control presentado en la Figura 3, el módulo RLS de identificación se encarga de obtener unos parámetros de la función de transferencia cada determinado tiempo (tiempo de muestreo). En este caso, el algoritmo RLS identificará los parámetros para una función de segundo orden con retardo, ya que es la función de transferencia que mejor se ajusta a la mayoría de los sistemas, Ecuación 1.




Figura 3: Esquema de la propuesta planteada

$$G_p(z^{-1}) = \frac{b_0 z^{-k}}{1 - a_0 z^{-1} - a_1 z^{-2}} \quad (1)$$

Los parámetros identificados son incorporados al módulo de hipersferas que almacena los datos y que, en función del punto de operación seleccionado y de las hipersferas almacenadas, obtiene unos nuevos parámetros semilla, que son enviados al PID autoajustable para adaptarse a la dinámica del sistema y generar una nueva señal de control.

3.1. Módulo propuesto basado en hipersferas

Con el objetivo de mejorar la comprensión de la propuesta planteada, la explicación se divide en dos subsecciones.

Ejecución inicial. En esta primera etapa, el problema se divide en puntos de operación específicos de nivel de llenado del depósito desde el 10 % hasta el 90 %, en incrementos del 10 %. Para cada uno de estos puntos de operación específicos se esperó hasta alcanzar el estado estacionario, y así obtener los mejores parámetros del controlador PID mediante RLS. Una vez alcanzado el estado estacionario se almacenan 200 muestras para la obtención de la hipersfera asociada a ese punto de operación. A partir de estas hipersferas se pueden calcular sus correspondientes centroides.

En la Figura 4 se muestra un ejemplo de hipersferas en $\mathbb{R}^3$ para 3 puntos de funcionamiento distintos.

La ejecución inicial únicamente tiene que ser ejecutada una sola vez y acaba cuando se obtienen las hipersferas para todos los puntos de funcionamiento seleccionados.

Ejecución en operación. Una vez ejecutado el procedimiento inicial y con el sistema en funcionamiento, si se fija un valor de consigna de un punto de funcionamiento de la etapa inicial, entonces, los pesos de la función de transferencia y, en consecuencia, los parámetros del controlador se obtienen calculando el centroide de la hipersfera asociada a ese punto de trabajo. Por otro lado, si se requiere un valor de consigna diferente, entonces para inicializar el algoritmo RLS se utiliza el valor del centroide de la hipersfera más cercana almacenada. Cuando

se alcanza el estado estacionario es necesario crear una nueva nube de datos relacionada con ese punto de funcionamiento.

El método propuesto actualiza las hiperesferas para cada tiempo de muestro, teniendo en cuenta que cada hiperesfera está conformada por las últimas 200 muestras obtenidas para un determinado punto de operación. De esta manera se consigue una adaptabilidad total de la propuesta.




Figura 4: Ejemplo hiperesferas en sistemas no lineales

4. Descripción de los experimentos realizados y resultados obtenidos

Para comprobar la funcionalidad de la propuesta diseñada, se realizaron diferentes experimentos sobre la planta de nivel descrita. El método se probó con los dos controladores recogidos en el Apartado 2.1.2 y para diferentes valores de consigna.

En primer lugar, la propuesta del centroide se probó implementando el PID autoajustable de margen de fase prefijado. En la Figura 5 se compara el rendimiento del lazo de control con la propuesta del centroide, gráfico superior, y el rendimiento del PID sin la propuesta, gráfico inferior.




Figura 5: Resultados obtenidos con el PID autoajustable basado en margen de fase prefijado

Como se puede observar en la Figura 5, la propuesta planteada reduce el tiempo de estabilización en una media de 20 segundos en comparación con el lazo de control sin la propuesta basada en hiperesferas. Además, el empleo de esta junto con el cálculo de los centroides reduce la sobreoscilación de la señal de control y de la señal de salida del sistema. Esto es especialmente notable en valores superiores al 40 % del nivel del tanque.

En la Figura 6, se muestran los resultados al aplicar el método propuesto junto con el PID autoajustable basado en asignación de polos.




Figura 6: Resultados obtenidos con el PID autoajustable basado en asignación de polos

Como se puede observar en la Figura 6, y al igual que ocurre en el caso del PID autoajustable basado en margen de fase prefijado, al aplicar la propuesta sobre el lazo de control, se consigue una reducción en el tiempo de estabilización de hasta 50 segundos, así como una señal de control mucho más suave, sobretodo en los valores más altos del nivel de llenado.

5. Conclusiones y trabajos futuros

En el presente trabajo se presenta un método adaptativo basado en el empleo de hiperesferas y el cálculo de centroides con el que reducir el tiempo de establecimiento y mejorar el rendimiento de los PID autoajustables. La funcionalidad del método se comprobó con dos algoritmos diferentes de PID autoajustable: PID autoajustable con asignación de polos y PID autoajustable con margen de fase preestablecido. Con ambos PID, la integración del método propuesto redujo el tiempo de establecimiento entre 20 y 50 segundos. Así mismo se consiguió mejorar y suavizar la señal de control generada.

Por otro lado, el método propuesto, supone una solución de fácil implementación que puede trabajar con algoritmos tradicionales robustos, por lo que el conocimiento de estos algoritmos se utiliza en la solución propuesta. Además, debido a su simplicidad, el método propuesto no necesita muchos recursos computacionales y espacio de memoria por lo que puede ser ejecutado en una gran variedad de sistemas embebidos.

En cuanto a los trabajos futuros, destacar que esta investigación se encuentra en una fase muy incipiente. Se comprobará la funcionalidad del método con otros algoritmos de autoajuste para comprobar su rendimiento. Además, se estudiará la posibilidad de detectar anomalías mediante el cálculo de la distancia entre el centroide calculado y el punto obtenido por el algoritmo de identificación. Por último, se plantearán otras contribuciones con las que reducir los tiempos de establecimiento y mejorar el rendimiento de estos algoritmos y se compararán con la presentada en este artículo.

Agradecimientos

Este trabajo ha sido realizado gracias al apoyo del Centro de Investigación en Tecnologías de la Información y las Co-

municaciones (CITIC), como Centro de Investigación del Sistema Universitario de Galicia, financiado por la Consellería de Educación, Universidade e Formación Profesional de la Xunta de Galicia a través del Fondo Europeo de Desarrollo Regional (FEDER) y la Secretaría Xeral de Universidades (Ref. ED431G 2019/01).


Referencias

- Behar, A. A., Iranzo, M. M., 2003. Identificación y control adaptativo. Pearson Educación.
- Bobál, V., Böhm, J., Fessl, J., Macháček, J., 2005. Self-tuning PID Controllers. Springer.
- Ciochina, S., Paleologu, C., Benesty, J., Enescu, A. A., 2009. On the influence of the forgetting factor of the rls adaptive filter in system identification. In: 2009 International Symposium on Signals, Circuits and Systems. IEEE, pp. 1–4.
- Islam, S. A. U., Bernstein, D. S., 2019. Recursive least squares for real-time implementation [lecture notes]. IEEE Control Systems Magazine 39 (3), 82–85.
- Li, Z., Nikolaidis, T., Nalianda, D., 2016. Recursive least squares for online dynamic identification on gas turbine engines. Journal of Guidance, Control, and Dynamics 39 (11), 2594–2601.
- Liu, Z., Li, C., 2016. Recursive least squares for censored regression. IEEE Transactions on Signal Processing 65 (6), 1565–1579.
- Rugh, W. J., Shamma, J. S., 2000. Research on gain scheduling. Automatica 36 (10), 1401–1425.
- Shen, T., Ren, W., Han, M., 2020. Quantized generalized maximum correntropy criterion based kernel recursive least squares for online time series prediction. Engineering Applications of Artificial Intelligence 95, 103797.
- Vargas Tamani, B. E., 2013. Controlador pid autoajustable basado en un margen de fase prefijado.
- Zayas-Gato, F., Quintián, H., Jove, E., Casteleiro-Roca, J.-L., Calvo-Rolle, J. L., 2020. Diseño de controladores PID. Universidade da Coruña, Servicio de Publicacións.
- Zhang, H., Gong, S.-j., Dong, Z.-z., 2013. On-line parameter identification of induction motor based on rls algorithm. In: 2013 International Conference on Electrical Machines and Systems (ICEMS). IEEE, pp. 2132–2137.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Modelado de series temporales mediante echo state networks para aplicaciones de analítica visual

Díaz, I.^{a,*}, Enguita, J. M.^a, García, D.^a, Cuadrado, A.A.^a, González, A.^a, Domínguez, M.^b

^aÁrea de Ingeniería de Sistemas y Automática, Universidad de Oviedo, Edificio Torres Quevedo (Departamental Oeste), bloque 2 Campus Universitario, 33204 Gijón, España (Spain)

^bEscuela de Ingenierías, Campus de Vegazana, León, España (Spain)

To cite this article: Díaz, I., Enguita, J.M., García D. Cuadrado, A.A., González A. Domínguez, M. 2022. "Modelado de series temporales mediante echo state networks para aplicaciones de analítica visual". XVII Simposio CEA de Control Inteligente.

Resumen

En este artículo se presenta un trabajo en curso dentro del proyecto *Herramientas de analítica visual para el estudio de problemas complejos en ingeniería y biomedicina* (PID2020-115401GB-I00), para la representación de series temporales en aplicaciones de analítica visual. Se parte de una técnica propuesta recientemente, que es utilizada para la caracterización de series temporales de procesos mediante *Echo State Networks* (ESN), y se propone a partir de ella un método de visualización basado en reducción de la dimensionalidad, que puede ser empleado para el análisis exploratorio de procesos con dinámica, así como para la monitorización de la condición. El método propuesto se aplica a un conjunto de datos sintético y a un conjunto de datos reales de vibración de un motor de inducción sometido a desequilibrios mecánicos y eléctricos graduales.

Palabras clave: Modelado de series temporales, monitorización de la condición, redes neuronales en control de procesos, monitorización de salud y diagnóstico.

Time Series Modeling by means of Echo State Networks for Visual Analysis Applications

Abstract

This paper presents a work in progress within the project *Visual analytics tools for the study of complex problems in engineering and biomedicine* (PID2020-115401GB-I00), for the representation of time series in visual analytics applications. We start from a recently proposed technique, which is used for the characterization of process time series by means of *Echo State Networks* (ESN), and propose a visualization method based on dimensionality reduction, which can be used for the exploratory analysis of processes with dynamics, as well as for condition monitoring. The proposed method is applied to a synthetic data set and to a real vibration data set of an induction motor subjected to gradual mechanical and electrical unbalance.

Keywords: Time series modelling, condition monitoring, neural networks in process control, health monitoring and diagnosis.

1. Introducción

El modelado y caracterización de series temporales constituye un área de gran interés en numerosos problemas de ciencia e ingeniería. En general, las series temporales son respuestas de un proceso o sistema que portan información relacionada con la naturaleza y condición de funcionamiento del mismo. Por tanto, su modelado, caracterización y representación son de gran interés en aplicaciones de analítica de datos de procesos y sistemas con dinámica, para el descubrimiento de conocimiento útil

que permita su optimización, mejora de la eficiencia, o para la determinación de la condición de funcionamiento, detección y diagnóstico de fallos.

Muchos de los enfoques para la caracterización de la dinámica se basan en la elaboración de modelos del proceso, o partes de él, a partir de señales de excitación y de respuesta, que pueden ser utilizados como gemelos digitales de las partes del proceso modeladas en esquemas de redundancia analítica para la detección y diagnóstico de fallos, o para generar visua-

*Autor para correspondencia: idiaz@uniovi.es

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

lizaciones de datos mediante simulación en distintos escenarios que permitan al usuario interpretar el comportamiento del proceso y obtener conocimiento útil del mismo.

Sin embargo, a menudo la única información disponible para la determinación del estado dinámico del proceso viene dada en términos de series temporales generadas por uno o más sensores del proceso. Existen numerosos enfoques en la literatura para la comparación y caracterización de series temporales. Los más habituales se basan en el cálculo de descriptores frecuenciales, tales como energías en bandas en frecuencia, usando técnicas de Fourier (FFT); otros enfoques clásicos se basan en la obtención de modelos generativos lineales de la serie temporal, tales como los autorregresivos (AR). Aunque estas técnicas son efectivas y han sido (y son) muy empleadas, se basan en modelos lineales y tienen una capacidad limitada para describir series complejas. Más recientemente han surgido numerosos enfoques basados en técnicas de *deep learning*, tales como el uso de capas convolucionales 1D (Ismail Fawaz et al., 2019; Zhao et al., 2017); también se ha planteado con éxito la caracterización de series temporales mediante imágenes (Wang and Oates, 2015), que permiten usar posteriormente redes convolucionales 2D, muy eficientes en clasificación de imágenes. La alternativa a las arquitecturas convolucionales es el empleo de redes recurrentes (especialmente las redes *Long-Short Term Memory*, LSTM (Hochreiter and Schmidhuber, 1997; Ismail Fawaz et al., 2019) o las *Gated Recurrent Units* (GRU) (Cho et al., 2014)), algoritmos no lineales recursivos con estados internos, que pueden ser integrados como capas en arquitecturas *deep learning*, y cuyos parámetros pueden ser entrenados mediante *Back Propagation Through Time* (BPTT).

Aunque las técnicas *deep learning* descritas son muy eficaces en tareas de clasificación y predicción de series temporales, en general implican arquitecturas complejas y con muchos parámetros, lo que hace difícil diseñarlas y lento entrenarlas. En (Jaeger, 2001), Jaeger propuso las *Echo State Networks* (ESN), enmarcadas en el paradigma *reservoir computing*, con un enfoque diferente: generar una expansión no lineal de la serie en cientos de modos transitorios mediante un modelo no lineal recursivo con pesos semialeatorios (fijos, no entrenados); posteriormente, se pueden combinar estos modos transitorios para estimar la salida (que puede ser una estimación, predicción o clase) utilizando técnicas de regresión estándar. Las ESN producen resultados competitivos –en algunos problemas, hasta tres ordenes de magnitud superiores a otras técnicas (Jaeger and Haas, 2004)– con arquitecturas profundas, pero su entrenamiento es casi inmediato (una regresión lineal), haciéndolas muy versátiles para algoritmos adaptativos, o incluso para formar arquitecturas tipo *ensemble* o profundas (Gallicchio et al., 2018).

En este artículo se presentan resultados preliminares de un método para la visualización de series temporales basado en el modelado mediante ESN, del que se puede obtener un vector de características representativo de la serie temporal, y posterior reducción de la dimensión en un espacio latente de baja dimensión (2D) que permite una representación visual de las series

temporales útil para el análisis exploratorio de los distintos estados dinámicos del proceso, así como para la monitorización de la condición. El método propuesto se aplica a un conjunto de datos sintético y a un conjunto de datos reales de vibración de un motor de inducción sometido a desequilibrios mecánicos y eléctricos graduales.

2. Metodos y técnicas

2.1. Echo State Networks

Las *Echo State Networks* (ESN) (Jaeger, 2001; Jaeger and Haas, 2004) son un tipo de red neuronal recurrente que, en su forma básica, permite modelar sistemas no lineales mediante aprendizaje supervisado. El modelo general en espacio de estados de un sistema dinámico no lineal, produce un vector de salidas $\mathbf{y}(k) \in \mathbb{R}^q$ a partir de un vector de entradas $\mathbf{u}(k) \in \mathbb{R}^p$ y de un vector de estados $\mathbf{x}(k) \in \mathbb{R}^n$ mediante un sistema de ecuaciones diferenciales de primer orden, de acuerdo con la siguiente expresión:

$$\begin{aligned}\mathbf{x}(k+1) &= f(\mathbf{x}(k), \mathbf{u}(k)) \\ \mathbf{y}(k) &= g(\mathbf{x}(k), \mathbf{u}(k))\end{aligned}\quad (1)$$

donde las funciones f y g son, en general, no lineales. Las ESN (Jaeger, 2001, 2007; Lukoševičius and Jaeger, 2009) son un caso particular de (1), basado en el concepto de *expansión no lineal* (Lukoševičius and Jaeger, 2009), en el que se considera un vector de estados $\mathbf{x}(k) \in \mathbb{R}^n$, de muy alta dimensión, un modelo no lineal en la ecuación de estado y un modelo lineal de la salida a partir del estado ¹:

$$\begin{aligned}\mathbf{x}(k) &= \sigma(\mathbf{W}_{res}\mathbf{x}(k-1) + \mathbf{W}_{in}\mathbf{u}(k)) \\ \mathbf{y}(k) &= \mathbf{W}_{out}\mathbf{x}(k)\end{aligned}\quad (2)$$

El modelo (2) es un caso particular de (1) que tiene como parámetros la matriz de reservorio $\mathbf{W}_{res} \in \mathbb{R}^{n \times n}$, una matriz de entradas $\mathbf{W}_{in} \in \mathbb{R}^{n \times p}$ y una matriz de salidas $\mathbf{W}_{out} \in \mathbb{R}^{q \times n}$, en el que se utiliza una función no lineal $\sigma()$ típicamente sigmoideal en la ecuación de estado, donde las matrices $\mathbf{W}_{res}$, $\mathbf{W}_{in}$ son generadas a partir de valores aleatorios, con algunas modificaciones que permitan llevar al sistema al borde de la estabilidad.

2.2. Recolección de estados del reservorio

Aplicándolo recursivamente, el modelo (2) permite generar, a partir de una secuencia de entrada o excitación $\{\mathbf{u}(k)\}$ una secuencia de vectores de estado, $\{\mathbf{x}(k)\}$ de dimensión n que, para el caso de N muestras, pueden agruparse en una matriz:

$$\mathbf{X} = (\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(N)) \in \mathbb{R}^{n \times N}$$

Las filas de la matriz $\mathbf{X}$ contienen la evolución temporal de cada uno de los n estados de $\mathbf{x}(k)$, constituyendo un *reservorio* de n modos dinámicos transitorios $x_i(k)$, que con una adecuada elección de los parámetros $\mathbf{W}_{res}$, $\mathbf{W}_{in}$ contiene una gran riqueza y variedad de comportamientos dinámicos. En la aplicación más habitual de las ESN, el modelado no lineal de sistemas dinámicos, los n modos dinámicos del reservorio se combinan

¹Se indica aquí la versión original. Existen numerosas variantes en la literatura que incorporan, por ejemplo, término de *bias* añadido a $\mathbf{u}(k)$, efecto directo de $\mathbf{u}(k)$ en la salida, término de feedback (inclusión de $\mathbf{y}(k)$) en la ecuación de estado, aplicación de un filtro pasabajos a los estados, uso de modelos de regresión no lineal para obtener $\mathbf{y}(k)$ a partir de $\mathbf{x}(k)$, etc. En Lukoševičius (2012) puede encontrarse una descripción detallada de muchas de esas variantes.

linealmente para estimar la salida. Definiendo la matriz de salidas $\mathbf{Y} = (\mathbf{y}(1), \mathbf{y}(2), \dots, \mathbf{y}(N)) \in \mathbb{R}^{q \times N}$ la ecuación de salidas de (2) conduce a un problema de regresión lineal $\mathbf{Y} = \mathbf{W}_{out}\mathbf{X}$ que puede resolverse usando técnicas de mínimos cuadrados estándar —suelen utilizarse técnicas con regularización, tales como *ridge regression* o *lasso*—, o mediante técnicas de regresión no lineal —ej. redes neuronales, regresión de vectores de soporte, etc.

2.3. Caracterización de series temporales

Sin embargo, el uso de las ESN para la caracterización de series temporales es menos frecuente. Aunque en el análisis de series temporales no existe una excitación de forma explícita, es posible aprovechar la capacidad del modelo ESN de generar un reservorio con enorme riqueza en dinámica para caracterizar series temporales. Dada una serie temporal $\mathbf{s}(k)$, en (Bianchi et al., 2020) se propone generar un reservorio utilizando la propia serie temporal como excitación, a la que se ha añadido un filtro de primer orden (*leaky-integrator*) (4) como se sugiere en (Lukoševičius, 2012):

$$\tilde{\mathbf{x}}(k) = \sigma(\mathbf{W}_{res}\mathbf{x}(k-1) + \mathbf{W}_{in}\mathbf{s}(k)) \quad (3)$$

$$\mathbf{x}(k) = (1 - \alpha)\mathbf{x}(k-1) + \alpha\tilde{\mathbf{x}}(k) \quad (4)$$

El reservorio resultante, contiene n modos transitorios no lineales generados a partir de la excitación $\mathbf{s}(k)$, donde el vector de estados $\mathbf{x}(k)$ puede verse como un conjunto expandido de descriptores de la dinámica de la serie en el instante k . Puede deducirse que la relación entre dos vectores de estados consecutivos, $\mathbf{x}(k)$ y $\mathbf{x}(k+1)$, depende de la naturaleza de la excitación, que en este caso es la serie temporal. Así, los parámetros de un modelo lineal $\mathbf{A}$, que permita predecir $\mathbf{x}(k+1)$ a partir de $\mathbf{x}(k)$ constituyen una caracterización aproximada de la serie en torno a la muestra k :

$$\mathbf{x}(k+1) \approx \mathbf{A}\mathbf{x}(k) \quad (5)$$

El modelo lineal $\mathbf{A}$ es un modelo generativo, que permite predecir el siguiente estado dinámico del reservorio que produciría la serie temporal, a partir del actual. El modelo, además, se basa en todos los modos dinámicos generados por el modelo no lineal (3), y por tanto constituye una caracterización detallada de la serie temporal $\mathbf{y}(k)$.

Asumiendo que la dinámica de la serie temporal es invariante a lo largo de una ventana de datos de longitud L , el modelo $\mathbf{A}$ puede estimarse para dicha ventana, utilizando técnicas estándar de regresión multivariable (ej. *ridge regression*) para predecir $\mathbf{x}(k+1)$ a partir de $\mathbf{x}(k)$. Siendo

$$\mathbf{X} = [\mathbf{x}(k), \dots, \mathbf{x}(k+L-1)] \quad (6)$$

$$\mathbf{Y} = [\mathbf{x}(k+1), \dots, \mathbf{x}(k+L)] \quad (7)$$

la matriz $\mathbf{A}$ que minimiza $\|\mathbf{x}(k+1) - \mathbf{A}\mathbf{x}(k)\|^2 + \lambda\|\mathbf{A}\|^2$, se puede estimar mediante

$$\mathbf{A} = (\mathbf{X}\mathbf{X}^T + \lambda\mathbf{I})^{-1}\mathbf{X}\mathbf{Y}^T \quad (8)$$

donde λ es el regularizador de Tikhonov. Aunque $\mathbf{A}$ tiene un número elevado de parámetros (n^2), se propone en este trabajo

una descomposición en valores singulares (SVD) de la matriz $\mathbf{A}$

$$\mathbf{A} = \mathbf{U}\Sigma\mathbf{V} = \sigma_1\mathbf{u}_1\mathbf{v}_1^T + \dots + \sigma_n\mathbf{u}_n\mathbf{v}_n^T \quad (9)$$

Los valores singulares $\sigma_1, \sigma_2, \dots, \sigma_n$ representan los pesos de los modos principales de $\mathbf{A}$ y pueden utilizarse como descriptores de la serie temporal.

2.4. Aplicación en series temporales variantes

El método descrito en apartados anteriores presupone que la serie temporal $\mathbf{s}(k)$, aunque posea una dinámica no lineal, es invariante en el tiempo. Un procedimiento básico para abordar la caracterización de sistemas cambiantes es el *enventanado*². Para los resultados de este trabajo, el método propuesto se aplica a las series analizadas, en ventanas de tamaño L , con desplazamientos D entre ellas,

$$\begin{aligned} &\mathbf{x}(k), \mathbf{x}(k+1), \dots, \mathbf{x}(k+L-1) \\ &\mathbf{x}(k+D), \mathbf{x}(k+1+D), \dots, \mathbf{x}(k+L-1+D) \\ &\vdots \end{aligned}$$

2.5. Visualización de las series en espacios latentes

El procedimiento anterior permite caracterizar la serie temporal para una ventana de tamaño L en torno a un instante k , mediante un vector de valores singulares $\sigma(k) = (\sigma_1, \sigma_2, \dots, \sigma_n)^T$ del modelo lineal $\mathbf{A}$. Así, podemos hablar de un *espacio de series temporales* $\mathcal{S}$, de dimensión n , integrado por los vectores de valores singulares, cada uno de los cuales representa una serie temporal.

En aplicaciones de analítica visual resulta de enorme interés poder representar visualmente las series temporales de una forma intuitiva y que permita de una manera natural la interacción para operaciones de análisis. Un enfoque muy utilizado en analítica visual consiste en el uso de un mapeo de reducción de la dimensión $\varphi: \mathcal{S} \subset \mathbb{R}^n \rightarrow \mathcal{L} \subset \mathbb{R}^2$ para representar en un *espacio latente* $\mathcal{L}$ de dimensión 2 —y por tanto fácilmente visualizable—, las series temporales de forma que series similares (con similares valores singulares) aparezcan juntas, y series diferentes aparezcan lejos en la representación. Aunque existen numerosas técnicas para estimar el mapeo φ a partir de datos —por ejemplo, *t-Stochastic Neighbor Embedding* (t-SNE) (Van der Maaten and Hinton, 2008) o el *Uniform Manifold Approximation and Projection for Dimension Reduction* (UMAP) (McInnes et al., 2018), ambas muy relevantes en los últimos años—, en los resultados presentados en este trabajo se utiliza el análisis de componentes principales (PCA) (Hotelling, 1933; Jolliffe, 2002), que permite ilustrar de forma sencilla el potencial de representatividad del método propuesto.

²El uso de ventanas deslizantes es la base de una de las técnicas más populares de análisis tiempo-frecuencia, la *Short Time Fourier Transform*, STFT, utilizada para la representación de espectrogramas.




Figura 1: Izquierda arriba: secuencia de 4 series temporales (vistas de detalle arriba). Izquierda medio y abajo, valores singulares. Derecha: proyección en el espacio latente de las series temporales (PCA de sus valores singulares).

3. Experimentos

En esta sección se aplican los métodos y técnicas descritos en la sección 2 en dos casos de estudio: un primer caso con series temporales, generadas sintéticamente; y un caso con datos reales de vibración de un motor de inducción, sometido a distintas condiciones de funcionamiento mediante desequilibrios mecánicos y eléctricos en distintos grados.

En cuanto a la parametrización, se utilizó el modelo ESN descrito en Lukoševičius (2012)³.

3.1. Datos sintéticos

Para el primer caso se generó, de forma sintética, una serie temporal con 4 tramos de dinámicas diferentes mediante combinaciones de señales senoidales y cuadradas a distintas frecuencias, de las que resultan series temporales con dinámicas complejas. Se aplicaron los métodos y técnicas descritos en la sección 2, que incluyen la caracterización de series temporales mediante ESN expuesta en 2.3, con una longitud de ventana de $L = 1000$ y un desplazamiento $D = 100$ entre ventanas. Para cada ventana se obtuvo el modelo lineal (5), empleando mínimos cuadrados según (8), para un valor de $\lambda = 10$. Los resultados se pueden ver en la Figura 1. La figura muestra la serie temporal, y debajo de ella la evolución de los mayores valores singulares, $\sigma_1, \sigma_2, \dots, \sigma_6$, de la matriz $\mathbf{A}$, calculados para

las ventanas que recorren la serie temporal. Como es esperable, los valores singulares tienen transitorios en los cambios de un tramo de la serie a otro, al coincidir ambos en una misma ventana. Sin embargo, se aprecia que en los intervalos en los que la ventana ocupa íntegramente cada uno de los 4 tramos de la serie, los valores singulares muestran combinaciones diferentes y estables para las distintas series, revelando una capacidad de diferenciación clara de las dinámicas.

3.2. Vibraciones en un motor de inducción

La técnica se experimentó también con datos reales de un motor de inducción —datos abiertos, publicados por el grupo GSDPI, disponibles en (Díaz Blanco et al., 2019). Concretamente, se analizó la serie temporal de vibraciones (acelerómetro ubicado en el estátor, orientado en la dirección x), de un motor de inducción de 4 kW, de dos pares de polos y 1500 rpm, sometido a distintos estados de funcionamiento, consistentes en combinaciones de asimetría mecánica (masa excéntrica en la polea) y desequilibrio eléctrico (carga resistiva variable en una de las fases). En particular, se consideraron los siguientes estados de funcionamiento:

- 1: asimetría mecánica (masa excéntrica en polea)
- 2: asimetría eléctrica y mecánica
- 3: normal
- 4: asimetría eléctrica (10 ohm)

³Se utilizaron los siguientes parámetros —ver (Lukoševičius, 2012)—, ajustados empíricamente: se tomaron $n = 300$ estados; los pesos de $\mathbf{W}_{res}$ y de $\mathbf{W}_{in}$ fueron generados aleatoriamente con una distribución uniforme; el 99 % de los elementos de $\mathbf{W}_{res}$ fueron puestos a cero (*sparsity* = 0,01), y finalmente la matriz resultante fue reescalada para un radio espectral $\rho = 1,1$ (valor del mayor valor propio [polo] del reservorio). El valor de α del filtro se fijó en 0,025 (polo en $z = 0,975$).




Figura 2: Izquierda arriba: serie temporal de vibraciones del motor atravesando distintas condiciones. Izquierda centro y abajo: valores singulares del modelo. Derecha: la proyección PCA de los valores singulares define un mapa visual de las series temporales, reflejando los distintos estados de operación del motor.

- 5: asimetría eléctrica (15 ohm)
- 6: asimetría eléctrica (20 ohm)
- 7: asimetría eléctrica (5 ohm)
- 8: asimetría eléctrica variable (0-20-0 ohm)
- 9: asimetría eléctrica variable (0-20 ohm)

Los resultados se muestran en la Figura 2. En la parte superior y a la izquierda se pueden observar detalles de la serie temporal en las distintas condiciones del motor. Más abajo, también a la izquierda, en azul, puede verse la evolución de los 6 mayores valores singulares. Puede comprobarse que los valores singulares son consistentes con los grados de asimetría inducidos. En particular, se aprecia la capacidad de recoger las variaciones graduales en los ensayos 8 y 9, así como con los niveles de desequilibrio eléctrico de 5, 10, 15, 20 Ω cuyas intensidades son coherentes con los cambios mostrados en los dos valores singulares más importantes, $\sigma_1(k)$, $\sigma_2(k)$.

En el espacio latente, generado mediante una proyección de análisis de componentes principales (*Principal Component Analysis*, PCA) (Jolliffe, 2002; Hotelling, 1933) de los vectores de valores singulares, las series temporales correspondientes a los distintos estados cumplen el principio de similitud, de forma que puntos cercanos representan estados y series temporales similares. El resultado es un *mapa de estados dinámicos*, que resulta interpretable al estar los estados organizados espacialmente con arreglo a la dinámica.

4. Conclusiones

En este trabajo se ha propuesto una técnica para la caracterización y visualización de series temporales, basada en *echo state networks*. La idea, basada en (Bianchi et al., 2020), se basa en generar mediante el modelo generativo no lineal de la ESN un reservorio con un número elevado de estados dinámicos, utilizando la serie temporal a analizar como excitación; a partir de los estados del reservorio, la serie temporal es caracterizada mediante los parámetros de un modelo lineal que predice el vector de estados una muestra hacia adelante. Finalmente, dicho modelo se representa de forma reducida mediante un vector con sus valores singulares.

De cara al uso en aplicaciones de analítica visual para el descubrimiento de conocimiento relacionado con la dinámica de procesos y sistemas, se propone en este trabajo una reducción de la dimensionalidad de los vectores de valores singulares y la visualización de las proyecciones en el espacio latente. Dado que la caracterización empleada explota el concepto de expansión no lineal descrito en (Lukoševičius and Jaeger, 2009), es capaz de captar aspectos dinámicos complejos de la serie temporal, lo que permite que la diferenciación entre series temporales con geometrías complejas sea precisa.

La metodología (caracterización, proyección y visualización) se aplicó en dos experimentos: uno con datos sintéticos y otro con datos reales de vibraciones de un motor de inducción

en distintas condiciones de funcionamiento consistentes en desequilibrios inducidos de tipo mecánico y eléctrico. En ambos casos, aunque las series temporales analizadas son complejas, la capacidad mostrada por la metodología para captar, caracterizar y visualizar las dinámicas mostrada por la ESN ha sido satisfactoria.

Los resultados obtenidos son prometedores y abren vías interesantes para futuro trabajo. Algunas posibilidades son la combinación con otras técnicas de reducción de la dimensión (tales como t-SNE o UMAP, mencionados anteriormente), la caracterización de estados recursiva –dato a dato, por *streaming*– para la monitorización de la condición en tiempo real de procesos, o la integración de esta representación en interfaces de analítica visual avanzada.

5. Reconocimientos

Esta publicación es parte del proyecto de I+D+i PID2020-115401GB-I00, financiado por MCIN/AEI/10.13039/501100011033/


Referencias

- Bianchi, F. M., Scardapane, S., Løkse, S., Jenssen, R., 2020. Reservoir computing approaches for representation and classification of multivariate time series. *IEEE transactions on neural networks and learning systems* 32 (5), 2169–2179.
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., Bengio, Y., 2014. Learning phrase representations using rnn encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*.
- Díaz Blanco, I., Cuadrado Vega, A. A., González Muñoz, A., García Pérez, D., 2019. Datacann: datos de vibración y corriente de un motor de inducción. <https://digibuo.uniovi.es/dspace/handle/10651/53461>.
- Gallicchio, C., Micheli, A., Pedrelli, L., 2018. Design of deep echo state networks. *Neural Networks* 108, 33–47.
- Hochreiter, S., Schmidhuber, J., 1997. Long short-term memory. *Neural computation* 9 (8), 1735–1780.
- Hotelling, H., 1933. Analysis of a complex of statistical variables into principal components. *Journal of educational psychology* 24 (6), 417.
- Ismail Fawaz, H., Forestier, G., Weber, J., Idoumghar, L., Muller, P.-A., 2019. Deep learning for time series classification: a review. *Data mining and knowledge discovery* 33 (4), 917–963.
- Jaeger, H., 2001. The “echo state” approach to analysing and training recurrent neural networks-with an erratum note. Bonn, Germany: German National Research Center for Information Technology GMD Technical Report 148 (34), 13.
- Jaeger, H., 2007. Echo state network. *Scholarpedia* 2 (9), 2330.
- Jaeger, H., Haas, H., 2004. Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication. *science*.
- Jolliffe, I. T., 2002. Principal component analysis for special types of data. Springer.
- Lukoševičius, M., 2012. A practical guide to applying echo state networks. In: *Neural networks: Tricks of the trade*. Springer, pp. 659–686.
- Lukoševičius, M., Jaeger, H., 2009. Reservoir computing approaches to recurrent neural network training. *Computer Science Review* 3 (3), 127–149.
- McInnes, L., Healy, J., Melville, J., 2018. Umap: Uniform manifold approximation and projection for dimension reduction. *arXiv preprint arXiv:1802.03426*.
- Van der Maaten, L., Hinton, G., 2008. Visualizing data using t-sne. *Journal of machine learning research* 9 (11).
- Wang, Z., Oates, T., 2015. Imaging time-series to improve classification and imputation. In: *Twenty-Fourth International Joint Conference on Artificial Intelligence*.
- Zhao, B., Lu, H., Chen, S., Liu, J., Wu, D., 2017. Convolutional neural networks for time series classification. *Journal of Systems Engineering and Electronics* 28 (1), 162–169.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Estimación del gradiente para optimización del control de enfriadoras

Arahal, M.R.^{a,*}, Satué, M.G.^a, Ortega, M.G.^a

^aDepartamento de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos, s/n, 41092, Sevilla, España.

To cite this article: Arahal, M.R., Satué, M.G., Ortega, M.G. 2022. Gradient estimation for optimized control of chillers. XVII Simposio CEA de Control Inteligente.

Resumen

El control predictivo basado en modelo se ha usado en plantas de refrigeración como medio para obtener un reparto de carga entre enfriadoras que minimiza el consumo garantizando que la producción de frío se ajusta a la demanda prevista. El principal problema de este método es que se requiere un modelo preciso de la planta. Los modelos usados habitualmente contienen parámetros que pueden ser difíciles de medir. Por este motivo el modelo usado para control puede diferir substancialmente de los datos observados. En este contexto la técnica de control sin sesgo permite corregir el efecto de diversos factores como perturbaciones y errores de modelado. Para usar esta técnica se precisa una estimación del gradiente de la función objetivo con respecto a las acciones de control. En este trabajo en curso se pretende aprovechar las técnicas de control inteligente para obtener mejores estimaciones del gradiente.

Palabras clave: Control inteligente, Control predictivo, Enfriadora, Estimación, Planta de refrigeración

Gradient estimation for optimized control of chillers

Abstract

Model based predictive control has been used in cooling plants as a means of solving the chiller loading problem in an optimal manner while satisfying a given cooling demand. The main drawback of this method is the need for an accurate plant model. Most models include adjustable parameters that are difficult to identify. As a result, there are mismatches between plant and plant model. In this context, the offset-free techniques have been proposed to counter the effect of disturbances and modelling errors. A gradient estimation is needed. This paper presents some work in progress aiming at using techniques from intelligent control to attain better gradient estimations.

Keywords: Intelligent control, Predictive control, Chiller, Estimation, Cooling plant

1. Introducción

Las plantas industriales de producción de frío usan más de una enfriadora conectada en paralelo. Esto es así por diversas razones. La principal suele ser la capacidad de seguir operando si una enfriadora se avería (Dossat, 1961). Otra, menos evidente, es que el rendimiento de un conjunto de máquinas es mejor que el de una sola (de mayor tamaño) (Deng et al., 2014). Por este motivo han surgido estudios acerca de cómo dividir la demanda de frío entre las distintas enfriadoras que constituyen la planta. Este problema recibe el nombre de OCL (Optimal Chi-

ller Loading) (Chang, 2004). Los autores han avanzado en esta línea incluyendo el efecto de los transitorios en el reparto de carga (Arahal et al., 2021b).

Por otro lado, el control predictivo basado en modelo (CPBM) permite considerar el coste de producción de frío directamente y usarlo como función objetivo de manera que el reparto de carga entre enfriadoras se obtiene en línea, considerando en cada momento el estado real de la planta (Satué et al., 2022). Téngase en cuenta que en el OCL, se usan predicciones tanto de la demanda de frío como de las condiciones ambientales (temperatura, humedad, radiación) y de otro tipo (por

*Autor para correspondencia: arahal@us.es

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

ejemplo la ocupación de un edificio o la producción prevista en una planta industrial). Estas predicciones no son perfectas y por tanto pueden influir en un reparto de carga mejorable. En el caso de usar CPBM las predicciones pueden afinarse cada cierto tiempo, disminuyendo el impacto de los errores (Arahal et al., 2021a).

Sin embargo, el CPBM requiere un modelo preciso de la planta. Los modelos usados habitualmente contienen parámetros que pueden ser difíciles de medir. Por este motivo el modelo usado para control puede diferir substancialmente de los datos observados. En este contexto la técnica de control sin sesgo permite corregir el efecto de diversos factores como perturbaciones y errores de modelado. Para usar esta técnica se precisa una estimación del gradiente de la función objetivo con respecto a las acciones de control. En este trabajo en curso se pretende aprovechar las técnicas de control inteligente para obtener mejores estimaciones del gradiente.

2. El problema del reparto

En la figura 1 se muestra el diagrama de una planta de producción de frío en la que se usan varias enfriadoras en paralelo. El reparto de la carga entre las enfriadoras (OCL) es especialmente relevante en el caso de que las enfriadoras tienen distintas curvas características pues en ese caso el problema no es convexo (Salari and Askarzadeh, 2015). Se han propuesto diversos métodos para resolver el OCL, considerando la carga parcial (PLR) de cada máquina enfriadora como variable de decisión. Por ejemplo en (Chang, 2005) se usan algoritmos genéticos.




Figura 1: Diagrama de una instalación de producción de frío con 3 enfriadoras y almacenamiento térmico.

El reparto puede obtenerse también mediante el uso de un sistema de control. El objetivo primario de dicho sistema es servir la demanda actual manteniendo las variables intermedias (caudales, temperaturas, etc.) dentro de límites (Bejarano et al., 2018). Como resultado se obtiene un reparto aunque de forma indirecta y no optimizada.

Un caso especial lo constituye el CPBM, donde el modelo de la planta se usa para obtener las acciones de control que permiten combinar los objetivos de bajo nivel (demanda y variables intermedias) con consideraciones de nivel superior como es el caso de la optimización económica. El CPBM se ha aplicado a diferentes tipos de sistemas relacionados con enfriadoras como por ejemplo (Castilla et al., 2011; Candanedo et al., 2013; Álvarez et al., 2013).

El aspecto económico es tenido en cuenta por el CPBM calculando el consumo eléctrico asociado a la producción de una cierta demanda de frío $\dot{Q}_L$. Este consumo depende de la temperatura de salida de cada enfriadora T^o y del flujo másico $\dot{m}$. Para una planta con N enfriadoras el consumo viene dado por

$$E = \left(\sum_{i=1}^N P_i + P_s + P_e \right) \cdot T_H \quad (1)$$

siendo P_i el consumo eléctrico para la enfriadora i , P_s el consumo de la bomba del circuito secundario y P_e el consumo extra debido a transitorios. El tiempo T_H define un cierto horizonte temporal para el problema de optimización, el cual se define mediante

$$\begin{aligned} \min_{\mathbf{x}} \quad & \sum_{t=1}^T E(\mathbf{x}) \\ \text{s.t.} \quad & \dot{Q}(\mathbf{x}) = \dot{Q}_L \\ & x_l \leq \mathbf{x} \leq x_u \\ & g_l \leq G(\mathbf{x}) \leq g_u, \end{aligned} \quad (2)$$

siendo $\mathbf{x}$ el vector de variables de decisión que definen el estado de cada enfriadora ($i = 1, \dots, N$) para cada periodo temporal $t = 1$ to $t = T$. De este modo

$$\mathbf{x} = (\dot{m}_s|_1^T, \dot{m}_1|_1^T, T_1^o|_1^T, \dots, \dot{m}_N|_1^T, T_N^o|_1^T)^T \quad (3)$$

siendo $\dot{m}_s$ el flujo másico en el circuito secundario. Las restricciones consideradas son las siguientes:

- $\dot{Q}(\mathbf{x}) = \dot{Q}_L$ implica que la demanda es satisfecha en cada periodo.
- $x_l \leq \mathbf{x} \leq x_u$ asegura los límites de variables intermedias.
- $g_l \leq G(\mathbf{x}) \leq g_u$ permite imponer restricciones más complejas como por ejemplo el salto de temperatura en cada enfriadora y el consumo máximo.

El problema reflejado en (2) es un problema de optimización multivariable en el que $\dim \mathbf{x} = T \cdot (2N + 1)$ siendo T el número de periodos considerados. En la mayoría de los casos se toma entre 8 y 24 horas.

2.1. Control predictivo

La técnica de CPBM se aplica con facilidad al problema planteado. Esto permite lidiar con varios aspectos del problema como altas inercias, perturbaciones y la necesidad de optimizar Killian and Kozek (2016). La acción de control u es un vector que contiene las variables manipulables. El vector y se forma con medidas tomadas de la planta, como temperaturas. La técnica CPBM considera una ventana deslizante en tiempo discreto que va desde el instante actual k hasta $k + H$, siendo H el horizonte. Las acciones de control a aplicar se agrupan en el vector $U = (u(k), \dots, u(k + H))$ y se seleccionan mediante optimización de una cierta función de coste J . En la función de coste se agrupan términos que penalizan desviaciones de las salidas predichas por el modelo $\hat{Y}(U) = (\hat{y}(k + 1), \dots, \hat{y}(k + H + 1))$ respecto a las referencias Y^* y el esfuerzo o coste asociado a las acciones de control. De este modo se construye:

$$J = \|Y^* - \hat{Y}(U)\|^2 + \lambda \|\Delta U\|^2 \quad (4)$$

donde λ es un parámetro ajustable que permite dar mayor peso relativo al coste asociado a las acciones de control. La minimización de J produce una secuencia U^* de la cual se usa solamente el primer elemento. En los instantes de muestreo sucesivos se repite todo el procedimiento siguiendo la idea de horizonte deslizante.

3. Estimación del gradiente y control inteligente

El llamado control predictivo económico (CPE) une la idea de CPBM con la idea de optimización en tiempo real (OTR) de manera que se consigue un objetivo económico (normalmente reducción de costes). Para evitar los problemas asociados a las imprecisiones del modelo de la planta y a la existencia de perturbaciones, se ha propuesto el concepto de CPE sin sesgo (Vaccari and Pannocchia, 2016). Esta idea se ha aplicado a diversos problemas de control con el propósito de obtener optimalidad en presencia de errores de modelado. Sin embargo, el CPE sin sesgo supone conocimiento de los gradientes estáticos de la planta con respecto a las entradas. Este requisito no es fácil de obtener en el caso de plantas de producción de frío debido a los problemas ya mencionados. Por tanto se suele acudir a estimar dichos gradientes.

Las técnicas de estimación de gradiente se dividen en dos clases: técnicas que usan datos de estado estacionario y las que usan datos dinámicos. En cada grupo se han presentado diferentes variantes para lidiar con algunos de los problemas que se presentan. Entre ellos cabe mencionar los siguientes

3.1. Método de Broyden

El método de Broyden es un cálculo recurrente para estimar gradientes usando valores actuales y pasados obtenidos de mediciones en línea en la planta (Broyden, 1993). El método no precisa la adición de señales de excitación. Matemáticamente equivale a la técnica de la secante usada para estimar una derivada parcial de primer orden.

El método ha sido aplicado al cálculo de gradientes para control óptimo (Roberts, 2000) y en otros contextos, en particular en CPE sin sesgo (Rodríguez-Blanco et al., 2018).

Uno de los principales problemas del método es el asociado al número de condición de las matrices usadas para la adaptación del gradiente cuando los cambios en las entradas son pequeños. Para evitar estos problemas frecuentemente se añade una capa de monitorización que evita la actualización para cambios pequeños en las entradas. Esto elimina el problema numérico, pero puede llevar a situaciones en las que la planta opera en estados no óptimos.

Como parte del trabajo en curso los autores están estudiando el desarrollo de otros mecanismos de supervisión que mejoren la actualización del gradiente en situaciones de estado estacionario evitando el problema de la falta de optimalidad. Los autores estiman que estas ideas tienen una gran proyección y son en la actualidad investigadas en otros ámbitos de aplicación por investigadores de prestigio (Berenguel, 2022).

4. Conclusiones

Las técnicas de control inteligente en el contexto de la optimización del control de plantas de producción de frío pueden

ofrecer mejores estimaciones del gradiente. Ha de tenerse en cuenta que los problemas que aparecen en este contexto son similares a los problemas que habitualmente se tratan en el control inteligente: no linealidades, excitación no persistente, tratamiento de datos con incertidumbre y alta dimensión. El trabajo en curso aquí propuesto no está cerrado ni agotado, al contrario existen muchas técnicas que merecen atención. El estudio de las ventajas e inconvenientes puede dar como resultado nuevos esquemas con prestaciones elevadas.

Agradecimientos

Este trabajo ha sido realizado en el seno del Proyecto RTI2018-101897-B-I00 by FEDER/Ministerio de Ciencia e Innovación, Agencia Estatal de Investigación.


Referencias

- Álvarez, J., Redondo, J., Camponogara, E., Normey-Rico, J., Berenguel, M., Ortigosa, P., 2013. Optimizing building comfort temperature regulation via model predictive control. *Energy and Buildings* 57, 361–372.
- Arahal, M. R., Ortega, M. G., Satué, M. G., 2021a. Chiller load forecasting using hyper-gaussian nets. *Energies* 14 (12).
URL: <https://www.mdpi.com/1996-1073/14/12/3479>
DOI: 10.3390/en14123479
- Arahal, M. R., Satué, M. G., Ortega, M. G., 2021b. Optimal chiller loading including transients. *Energy and Buildings* 253, 111527.
- Bejarano, G., Alfaya, J. A., Rodríguez, D., Morilla, F., Ortega, M. G., 2018. Benchmark for pid control of refrigeration systems based on vapour compression. *IFAC-PapersOnLine* 51 (4), 497–502.
- Berenguel, P. O., 2022. Modelado y control del proceso de producción de microalgas mediante estrategias de aprendizaje automático. V Jornadas de Doctorado en Informática 131, 131.
- Broyden, C., 1993. Block conjugate gradient methods. *Optimization methods and Software* 2 (1), 1–17.
- Candanedo, J., Dehkordi, V., Stylianou, M., 2013. Model-based predictive control of an ice storage device in a building cooling system. *Applied Energy* 111, 1032–1045.
- Castilla, M., Álvarez, J., Berenguel, M., Rodríguez, F., Guzmán, J., Pérez, M., 2011. A comparison of thermal comfort predictive control strategies. *Energy and buildings* 43 (10), 2737–2746.
- Chang, Y.-C., 2004. A novel energy conservation method optimal chiller loading. *Electric Power Systems Research* 69 (2-3), 221–226.
- Chang, Y.-C., 2005. Genetic algorithm based optimal chiller loading for energy conservation. *Applied Thermal Engineering* 25 (17-18), 2800–2815.
- Deng, K., Sun, Y., Li, S., Lu, Y., Brouwer, J., Mehta, P. G., Zhou, M., Chakraborty, A., 2014. Model predictive control of central chiller plant with thermal energy storage via dynamic programming and mixed-integer linear programming. *IEEE Transactions on Automation Science and Engineering* 12 (2), 565–579.
- Dossat, R. J., 1961. Principles of refrigeration. John Wiley & Son.
- Killian, M., Kozek, M., 2016. Ten questions concerning model predictive control for energy efficient buildings. *Building and Environment* 105, 403–412.
- Lo, C.-C., Tsai, S.-H., Lin, B.-S., 2016. Economic dispatch of chiller plant by improved ripple bee swarm optimization algorithm for saving energy. *Applied Thermal Engineering* 100, 1140–1148.
- Roberts, P., 2000. Broyden derivative approximation in ISOPE optimising and optimal control algorithms. *IFAC Proceedings Volumes* 33 (16), 293–298.
- Rodríguez-Blanco, T., Sarabia, D., de Prada, C., 2018. Optimización en tiempo real utilizando la metodología de adaptación de modificadores. *Revista Iberoamericana de Automática e Informática industrial* 15 (2), 133–144.
- Salari, E., Askarzadeh, A., 2015. A new solution for loading optimization of multi-chiller systems by general algebraic modeling system. *Applied Thermal Engineering* 84, 429–436.
- Satué, M. G., Arahal, M. R., Acedo, L. F., Ortega, M. G., 2022. Economic versus energetic model predictive control of a cold production plant with thermal energy storage. *Applied Thermal Engineering* 210, 118309.
- Vaccari, M., Pannocchia, G., 2016. A modifier-adaptation strategy towards offset-free economic mpc. *Processes* 5 (1), 2.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



PV panel monitoring system for cell temperature analysis and comparison by embedded models

González, I.^{a,*}, Folgado, F.J.^a, Orellana, D.^a, Calderón, D.^a, Calderón, A.J.^a

^a Departamento de Ingeniería Eléctrica, Electrónica y Automática, Escuela de Ingenierías Industriales, Universidad de Extremadura. Avenida de Elvas s/n, 06006 Badajoz, España.

To cite this article: González, I., Folgado, F.J., Orellana, D., Calderón, D., Calderón, A.J. 2022. PV panel monitoring system for cell temperature analysis and comparison by embedded models. XVII Simposio CEA de Control Inteligente.

Abstract

In recent decades, the use of renewable energy sources and the development of related technologies have been boosted due to the energy and environmental paradigm, with photovoltaic (PV) panels being one of the most implemented and optimised to date. The behaviour of panel operation is dependent on multiple parameters such as irradiance, wind speed or operating temperature. This paper presents a monitoring system based on IoT software focused on the study of the cell temperature (CT) of PV panels, highlighting the importance of this variable in the current generation and the equipment overall performance. For this purpose, a dashboard is implemented in Grafana to visualise the evolution of the CT and the associated variables. The implemented dashboard includes embedded models for the simulation of CT, in order to compare real and simulation data. This comparison determines the most suitable model to the real dynamics and could facilitate the development of intelligent control strategies for the panel.

Keywords: Renewable energy, Photovoltaic, Grafana, IoT, Monitoring system.

1. Introduction

In recent years, the worsening of the environmental scenario due to the increase in pollutant emissions has encouraged the development and implementation of technologies for the use of renewable energy sources (RES) (Sayed et al., 2021; Tsilingiridis et al., 2011; Shakya et al., 2022). Some of these, such as solar, wind and hydro, have become fully integrated into the socio-economic fabric, forming part of the compendium of energy sources used on a daily basis to satisfy the population's energy demand. In particular, the technologies associated with photovoltaic (PV) energy have prospered notably, serving as a key part of the energy generation system in a multitude of contexts, such as industrial (Catalbas et al., 2021) or residential (Panagiotidou et al., 2021).

PV panels are made up of a set of interconnected cells with the capacity to generate electricity by means of the photoelectric effect of the materials of which they are composed. These devices are widely studied and integrated in applications together with other secondary generation systems based on RES, such as hydrogen generators (Gutiérrez-Martín et al., 2021), or applied for energy storage by means of batteries (Mulleriyawage and Shen, 2020). To

optimise the operation of these devices, detailed control of the parameters that condition their behaviour, such as voltage, generated current or irradiance, is required. One of these key parameters is cell temperature (CT), whose relationship with the power dissipation affects the performance of the cells. Due to its importance, there are models in the literature for estimating this variable based on conditions indicated by the panel manufacturer (Alonso García and Balenzategui, 2004; Migan, 2013), practical models (Araneo et al., 2014; Kamuyu et al., 2018; Ross, 1976) as well as models based on energy balance equations (Appelbaum and Maor, 2020).

To carry out the study of these models, a series of sensors and a system to manage the operation of the physical device and data acquisition are required. The current paradigm of IoT technologies provides users with highly versatile tools, such as Grafana. This software is used in many areas as a monitoring system (Gimeno-Sales et al., 2020; González et al., 2022).

This work describes a Grafana-based monitoring system for PV panels. This system is dedicated to the study of the real temperature of the cells and its comparison with a set of models selected from the literature. The goal is to understand the effects associated with this parameter and to select the most suitable model for the operation of the installed panels.

The structure of the rest of the manuscript is as follows. The second section describes the operation of the PV panel and the selected CT models for the monitoring system. Section 3 deals with Grafana and the implementation of the system. Finally, a series of conclusions about the work carried out are detailed.

2. PV panels operation and cell temperature models

The operation of PV panels can be explained as an interaction of two processes. Firstly, the electrical generation is due to the photoelectric effect of the cell materials. On the other hand, there is an energy dissipation effect in the form of heat due to this generation process. This energy loss is greater the higher the temperature of the cell.

Equivalent Circuit Models (ECM) are based on an electrical diagram whose components are associated with physical effects of device operation. For the case of PV panels, these models are widely used, such as in (Amiry et al., 2018; Sarikh et al., 2020; González et al., 2021). More specifically, the single diode model is commonly used to estimate the electrical generation of a PV cell. Figure 1 shows the diagram of the single diode ECM for a PV cell.




Figure 1: Electrical Circuit Model of a PV cell.

The circuit consists of a single diode connected in parallel with a photo-generated current source I_{ph} , a series resistance R_s to represent voltage drops and internal losses, and a shunt resistance R_{SH} to consider the leakage currents. The relationship between these electrical components defines Eq.(1) for the current generation I for a PV module of N_s cells in series.

$$I = I_{ph} - I_0 \left[\exp \left(\frac{V + IR_s}{nN_s V_{TH}} \right) - 1 \right] - \frac{V + IR_s}{R_{SH}} \quad (1)$$

Where I_0 is the saturation current of the diode, V is the output voltage, n the diode ideality factor and V_{TH} is the thermal equivalent voltage. The last parameter is described in Eq.(2) and depends on the electric charge q , the Boltzmann constant K and the cell temperature T_c .

$$V_{TH} = KT_c/q \quad (2)$$

As shown in Eq.(1) and Eq.(2), the single diode model is dependent on the operating CT, whose variations have a direct impact on the current generation and overall panel efficiency. Therefore, it is critical to monitor the evolution of this variable through models that predict its value in order to optimise the operation of the PV panels.

The models for determining the operating temperature T_c included in the monitoring system consider environmental parameters such as ambient temperature T_a , irradiance G or wind speed V_w .

In (Alonso García and Balenzategui, 2004; Migan, 2013) the Eq.(3) called Nominal Operating Cell Temperature (NOCT) is used, where the nominal conditions indicated by

the manufacturer ($T = 25^\circ\text{C}$, $G = 800 \text{ W/m}^2$) are applied as a reference to determine the CT.

$$T_c = (T_a + NOCT) \times \frac{G}{800} \quad (3)$$

The work described in (Ross, 1976) expresses the operating temperature by Eq.(4), where the irradiance is varied by a constant.

$$T_c = T_a + 0.035G \quad (4)$$

The model developed in (Migan, 2013) defines Eq.(5), where the effect associated with temperature dissipation due to wind is included by implementing the wind speed parameter.

$$T_c = T_a + \frac{0.32}{8.91 + 2V_w} G \quad (5)$$

The models listed above have been selected for their simplicity and ease of implementation. Moreover, they have been widely applied and validated in previous literature. These characteristics make them ideal for integration into the monitoring system.

3. Grafana and implementation

Grafana is an IoT software dedicated to the monitoring of information through a graphical interface based on dashboards composed of visual elements such as graphs, historical data or numerical indicators. Derived from its IoT nature, Grafana offers an extensive catalogue of add-ons and plug-ins, providing the platform with versatility and customisation to undertake the design of interfaces that meet the user's needs.

The performance of Grafana is based on its interaction with one or more data sources, allowing both real-time operation and the representation of data over a specific time range. Figure 2 illustrates this principle of operation.




Figure 2: Interaction between data sources and Grafana.

For the case of the system described in this work, a data acquisition system (DAQ) is used to gather measurements associated with the sensors installed close to the PV panels. The DAQ system then sends the information to a Raspberry Pi which stores it in a database and displays it on a dashboard in Grafana. The monitoring system and all the components involved are represented in Figure 3, as well as the interactions between each of them.




Figure 3: Monitoring system and components involved.

Within Grafana, a dashboard is designed to represent the time evolution of the parameters acquired from the physical system and to simulate the CT models described in section 2. For this purpose, the interface hosts three graphs which are programmed by means of Search Query Language (SQL) to visualise the information stored in the data source. In the case of the models, these are embedded in the interface through SQL code in one of the graphs. In this way, Grafana performs the simulation process of the models from the data stored in data sources. Figure 4 depicts the process carried out by the monitoring system to implement the model expressions.




Figure 4: Model simulation process.

To show the potential of the designed monitoring system, Figure 5 represents the data evolution of the stored parameters and the resulting model values for a time range of 15 hours.

This figure shows the graphical aspect of the interface, consisting of a total of three graphs, each with a specific purpose. First, there is a comparative graph of the values associated with the models described in section 2 and the measurement obtained from the sensor placed in the panels. Next, an independent graph for irradiance and another for wind speed are presented. These last two panels allow us to understand the nature of the variations in the models.

Looking more closely at the first of these graphs, four curves can be distinguished: the green curve refers to the model based on NOCT used in (Alonso García and Balenzategui, 2004; Migan, 2013). The orange curve

represents the results obtained by the model of (Ross, 1976). The cyan curve represents the behaviour described in (Migan, 2013). Finally, the red line describes the evolution of the actual temperature measured on the panels by the sensors. Figure 6 shows in detail the development of these curves over time.

The information presented by the dashboard plots allows to determine the behaviour of the models in comparison with the real dynamics shown by the panel cells. The results obtained by the model based on NOCT and (Ross, 1976) coincide with relative accuracy with the experimental values. Peculiarly, the model described in (Ross, 1976) presents fluctuations associated with point variations in irradiance, as can be seen in Figure 5. These sudden changes in irradiance are due to slight shading caused by clouds. On the other hand, it is worth noting the behaviour of the model of (Migan, 2013), whose constant and pronounced fluctuations are due to the continuous variations in wind speed, as can be seen in the graph of this parameter in Figure 5.

These abrupt variations are caused by the fact that the selected models allow estimating the instantaneous value of the CT, without considering the time factor or previous values. Therefore, although their approximations are close to the real cell dynamics, a sudden variation of their input parameters results in an instantaneous fluctuation of the model.

As a counterpart to this behaviour, experimental measurements show a temperature evolution without abrupt variations. This effect is due to the actual dynamics of the cells, whose operating temperature evolves more smoothly due to thermodynamic parameters such as resistivity or thermal conductivity. These parameters limit the rate at which the cell transports heat, thus limiting the rate of fluctuation of the operating temperature.




Figure 5: Monitoring system in operation.




Figure 6: Comparative temperature graph.

4. Conclusions

This paper has presented a Grafana-based monitoring system for PV panels, focusing on the study of the operating CT. For this purpose, the system has embedded models in the dashboard for analysis and comparison of experimental values and simulation results. Grafana provides a graphical environment for the management of the information acquired from the panels while providing versatility due to its customisation and ease of use. The most accurate CT model could be used to apply intelligent control strategies.

Future work will address the implementation of new graphic elements that facilitate the interpretation of the data represented on the dashboard. At the same time, new models will be included to enrich the study derived from the comparison between experimental data and model simulations.

Acknowledgments

This project was co-financed by European Regional Development Funds FEDER and by the Junta de Extremadura (IB18041).

References

- Alonso García, M.C., J.L. Balenzategui. 2004. Estimation of Photovoltaic Module Yearly Temperature and Performance Based on Nominal Operation Cell Temperature Calculations. *Renewable Energy* vol. 29 (12), pp. 1997–2010. <https://doi.org/10.1016/j.renene.2004.03.010>.
- Amiry, H., M. Benhmida, R. Bendaoud, C. Hajjaj, S. Bounouar, S. Yadir, K. Raïs, M. Sidki. 2018. Design and Implementation of a Photovoltaic I-V Curve Tracer: Solar Modules Characterization under Real Operating Conditions. *Energy Conversion and Management* vol. 169 (May), pp. 206–16. <https://doi.org/10.1016/j.enconman.2018.05.046>.
- Appelbaum, J., T. Maor. 2020. Dependence of Pv Module Temperature on Incident Time-Dependent Solar Spectrum. *Applied Sciences (Switzerland)* vol. 10 (3), . <https://doi.org/10.3390/app10030914>.
- Araneo, R., U. Grasselli, S. Celozzi. 2014. Assessment of a Practical Model to Estimate the Cell Temperature of a Photovoltaic Module. *International Journal of Energy and Environmental Engineering* vol. 5 (1), . <https://doi.org/10.1007/s40095-014-0072-x>.
- Catalbas, M.C., B. Kocak, B. Yenipinar. 2021. Analysis of Photovoltaic-Green Roofs in OSTIM Industrial Zone. *International Journal of Hydrogen Energy* vol. 46 (27), pp. 14844–56. <https://doi.org/10.1016/j.ijhydene.2021.01.205>.
- Gimeno-Sales, F.J., S. Orts-Grau, A. Escribá-Aparisi, P. González-Altozano, I. Balbastre-Peralta, C.I. Martínez-Márquez, M. Gasque, S. Seguí-Chilet. 2020. Pv Monitoring System for a Water Pumping Scheme with a Lithium-Ion Battery Using Free Open-Source Software and Iot Technologies. *Sustainability (Switzerland)* vol. 12 (24), pp. 1–28. <https://doi.org/10.3390/su122410651>.
- González, I., A.J. Calderón, F.J. Folgado. 2022. IoT Real Time System for Monitoring Lithium-Ion Battery Long-Term Operation in Microgrids. *Journal of Energy Storage* vol. 51 (January), pp. 104596. <https://doi.org/10.1016/j.est.2022.104596>.
- González, I., J.M. Portalo, A.J. Calderón. 2021. Configurable IoT Open-Source Hardware and Software I-V Curve Tracer for Photovoltaic Generators. *Sensors* vol. 21 (22), . <https://doi.org/10.3390/s21227650>.
- Gutiérrez-Martín, F., L. Amodio, M. Pagano. 2021. Hydrogen Production by Water Electrolysis and Off-Grid Solar PV. *International Journal of Hydrogen Energy* vol. 46 (57), pp. 29038–48. <https://doi.org/10.1016/j.ijhydene.2020.09.098>.
- Kamuyu, W.C.L., J.R. Lim, C.S. Won, H.K. Ahn. 2018. Prediction Model of Photovoltaic Module Temperature for Power Performance of Floating PVs. *Energies* vol. 11 (2), . <https://doi.org/10.3390/en11020447>.
- Migan, G.-A. 2013. Project Report 2013 MVK160 Heat and Mass Transfer Study of the Operating Temperature of a PV Module.
- Mulleriyawage, U.G.K., W.X. Shen. 2020. Optimally Sizing of Battery Energy Storage Capacity by Operational Optimization of Residential PV-Battery Systems: An Australian Household Case Study. *Renewable Energy* vol. 160pp. 852–64. <https://doi.org/10.1016/j.renene.2020.07.022>.
- Panagiotidou, M., L. Aye, B. Rismanchi. 2021. Optimisation of Multi-Residential Building Retrofit, Cost-Optimal and Net-Zero Emission Targets. *Energy and Buildings* vol. 252pp. 111385. <https://doi.org/10.1016/j.enbuild.2021.111385>.
- Ross, J. 1976. INTERFACE DESIGN CONSIDERATIONS FOR TERRESTRIAL SOLAR CELL MODULES;;: R. G. Ross, ~r+Jet Propulsion Laboratory Pasadena, California, 801–6.

- Sarikh, S., M. Raoufi, A. Bennouna, A. Benlarabi, B. Ikken. 2020. Implementation of a Plug and Play I-V Curve Tracer Dedicated to Characterization and Diagnosis of PV Modules under Real Operating Conditions. *Energy Conversion and Management* vol. 209 (February), pp. 112613. <https://doi.org/10.1016/j.enconman.2020.112613>.
- Sayed, E.T., T. Wilberforce, K. Elsaid, M.K.H. Rabaia, M.A. Abdelkareem, K.J. Chae, A.G. Olabi. 2021. A Critical Review on Environmental Impacts of Renewable Energy Systems and Mitigation Strategies: Wind, Hydro, Biomass and Geothermal. *Science of the Total Environment* vol. 766pp. 144505. <https://doi.org/10.1016/j.scitotenv.2020.144505>.
- Shakya, S.R., I. Bajracharya, R.A. Vaidya, P. Bhawe, A. Sharma, M. Rupakheti, T.R. Bajracharya. 2022. Estimation of Air Pollutant Emissions from Captive Diesel Generators and Its Mitigation Potential through Microgrid and Solar Energy. *Energy Reports* vol. 8pp. 3251–62. <https://doi.org/10.1016/j.egyr.2022.02.084>.
- Tsiliniridis, G., C. Sidiropoulos, A. Pentaliotis. 2011. Reduction of Air Pollutant Emissions Using Renewable Energy Sources for Power Generation in Cyprus. *Renewable Energy* vol. 36 (12), pp. 3292–96. <https://doi.org/10.1016/j.renene.2011.04.030>.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Aplicación del filtro de Kalman en el procesamiento de medidas muy ruidosas, un caso práctico: banco de potencia para motocicletas con capacidad de análisis aerodinámico

Ríos, J.^{a,*}, Del Pino, J.^a, Barragán, J.^a, Andujar, J. M.^a, Semião, J.^b, Oliveira, L.^c

^a Departamento de Ingeniería Electrónica, Sistemas Informáticos y Automática, Universidad de Huelva, Escuela Técnica Superior de Ingeniería, Campus de El Carmen, Av. De las Fuerzas Armadas s/n, 21071 Huelva, España.

^b INESC-ID / ISE-Ualg (Instituto Superior de Engenharia da Universidade do Algarve), Campus da Penha, 8005-139 Faro, Portugal.

^c CISE / ISE-UAlg (Instituto Superior de Engenharia da Universidade do Algarve), Campus da Penha, 8005-139 Faro, Portugal.

To cite this article: Ríos, J., Del Pino, J., Barragán, J., Andujar, J. M., Semião, J., Oliveira, L. 2022. Application of the Kalman filter in the processing of very noisy measurements, a case study: motorcycle dyno with aerodynamic analysis capability. XVII Simposio CEA de Control Inteligente.

Resumen

En este trabajo se presenta una aplicación del filtro de Kalman para tratar medidas altamente ruidosas de cara a su empleo en un sistema de control. En concreto, el sistema con el que se ha trabajado es un banco de potencia para motocicletas al que se ha añadido un ventilador de gran potencia capaz de generar una corriente de aire a una velocidad igual a la que está desarrollando la motocicleta sobre el rodillo, permitiendo así la realización de estudios aerodinámicos. Las variables a medir se ven fuertemente afectadas por ruido generado por el inversor que alimenta el ventilador, por las interferencias provocadas por los pulsos de la bobina de alta tensión de la motocicleta o por las turbulencias de la corriente de aire en el caso del sensor de velocidad del aire. Además, teniendo en cuenta que varias de las señales a medir son pulsos que deben computarse en cada intervalo de control, también van a producirse errores que pueden considerarse ruidos del proceso. El filtro de Kalman, empleado para tratar las medidas y algunas de las variables calculadas en el algoritmo consiguen reducir el ruido de todas las variables a valores aceptables que permiten la realización de las acciones de control y trazado de curvas de potencia y par de la motocicleta.

Palabras clave: Estimación y filtrado, Filtrado y suavizado, Métodos bayesianos, Identificación recursiva, Técnicas de filtrado de Kalman en el control de automóviles.

Application of the Kalman filter in the processing of very noisy measurements, a case study: motorcycle dyno with aerodynamic analysis capability

Abstract

This paper presents an application of the Kalman filter to handle high noise measurements for use in a control system. Specifically, the system used is a motorcycle dyno to which a high power fan has been added, capable of generating an air current at a speed equal to the speed that the motorcycle is running on the roller, thus allowing aerodynamic studies to be carried out. The variables to be measured are strongly affected by noise generated by the inverter that supplies the fan, by the interferences caused by the pulses of the motorcycle's high voltage coil or by the turbulences of the air current in the case of the air speed sensor. In addition, considering that several of the signals to be measured are pulses to be computed at each control interval, errors that can be considered process noise will also occur. The Kalman filter, used to handle the measurements and some of the variables computed in the algorithm, manages to reduce the noise of all the variables to acceptable values that allow performing the control actions and plotting the power and torque curves of the motorcycle.

*Autor para correspondencia: rios@uhu.es

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

Keywords: Estimation and filtering, Filtering and smoothing, Bayesian methods, Recursive identification, Kalman filtering techniques in automotive control.

1. Introducción

Uno de los aspectos clave a la hora de implementar un sistema de control es el de los sistemas de medida. A menudo, las señales a medir se ven afectadas por ruidos que, no tratados adecuadamente, podrían impedir el correcto funcionamiento del sistema de control. El de los ruidos es un problema tratado ampliamente desde diversas perspectivas. Desde el punto de vista de la instrumentación, hay numerosas técnicas que permiten minimizar los ruidos de medida, como son el empleo de cables específicos para la aplicación, transmisión mediante canales de instrumentación adecuados, configuraciones propias para tratamiento de señal, filtrados, etc., sin embargo, no siempre son una respuesta completa ante un problema de ruidos. Por otro lado, si la implementación del sistema de control es discreta, lo más habitual hoy día, el proceso de muestreo introducirá una nueva fuente de ruidos independiente del proceso de medida.

Como es sabido, el filtro de Kalman (Kalman, 1960) (Kalman, 1963) es un algoritmo recursivo que permite obtener una estimación de una variable cuando se cuenta con medidas discretas de la misma a lo largo del tiempo, teniendo una gran aplicación en sistemas dinámicos de naturaleza estocástica observados con sensores ruidosos. En este trabajo se presenta una aplicación de control sobre un sistema con medidas altamente ruidosas en la que se emplea el filtro de Kalman para minimizar el efecto de los ruidos, tanto de los contenidos en las medidas como de los provocados por el carácter discreto de algoritmo de control (Li, 2015).

2. Descripción del sistema

2.1. Descripción general

El sistema que se pretende controlar es un banco de potencia para motocicletas con ampliación para análisis aerodinámico. El banco de potencia es un dispositivo que permite obtener las curvas de par y de potencia desarrolladas por un vehículo, en este caso, una motocicleta. Para ello cuenta con un rodillo de inercia, con un momento de inercia conocido, que es movido por la rueda motriz. El rodillo tiene adosada una corona dentada que, mediante el empleo de un sensor inductivo permite conocer la velocidad de giro, computando el nº de pulsos que ocurren en cierta cantidad de tiempo y calculando la velocidad en función del radio del rodillo.




Figura 1: Rodillo de inercia y sensor inductivo.

Por otro lado, mediante una pinza capacitiva sobre el cable de la bujía, se captan los pulsos generados por la bobina de alta tensión de la motocicleta, que corresponden a las explosiones en la cámara de combustión. Si se trata de un motor de cuatro tiempos, por cada dos revoluciones del motor se produce una explosión, por lo que el cómputo de las explosiones en un intervalo de tiempo conocido permite calcular las revoluciones a las que gira el motor.

Mediante el muestreo de la velocidad, conocido el momento de inercia del rodillo, puede calcularse el par y potencia que desarrolla el motor, datos que representados frente al régimen de giro componen las curvas de potencia y par, cuyo trazado es el objetivo final de un banco de potencia.

El banco tradicional no permite el estudio de aspectos aerodinámicos, ya que no se produce movimiento real del vehículo. Una ampliación de estos bancos consiste en la adición de un ventilador de gran potencia accionado mediante un inversor de frecuencia regulable.



Figura 2: Ventilador con velocidad regulable.

Mediante un sensor de tipo Pitot se mide la velocidad de la corriente de aire generada por el ventilador, que se comparará con la velocidad generada por la motocicleta. La obtenida será la señal de error para un controlador de tipo PI cuya salida gobierna la frecuencia del inversor que alimenta al ventilador.




Figura 3: Esquema general del sistema.

Como complemento, el sistema cuenta con una sonda Lambda para monitorizar la proporción aire/gasolina que entra en la cámara de combustión (mediante el análisis de los gases de escape), lo que permite hacer modificaciones en los mapas de encendido con la seguridad de que se mantiene la estequiometría de la mezcla o en su defecto, un margen de seguridad adecuado.

De las cuatro variables a medir, dos de ellas son magnitudes continuas (velocidad del aire y λ) mientras que las otras dos son pulsos a contar. Como sistema de adquisición de datos se ha empleado una placa Arduino Uno, que cuenta con entradas analógicas con convertidores de 10 bits y dos entradas digitales que pueden gestionarse mediante interrupciones, lo que las hace adecuadas para la cuenta de eventos. Además, mediante una salida digital modulada en PWM se puede generar la señal de gobierno del inversor que alimenta al ventilador.

La aplicación que realiza el algoritmo de control y el trazado de las curvas de par y potencia se ha implementado sobre un PC y programado mediante *LabView* de *National Instruments*.

2.2. Ruidos y no linealidades en las medidas


Durante el análisis de sistemas se encontraron dificultades en el procesamiento de las medidas, como se ha comentado previamente, debido sobre todo a los ruidos. En la sonda Lambda y el tubo Pitot aparecen interferencias introducidas por el inversor que alimenta al ventilador y por los pulsos de la bobina de ignición de la motocicleta. Además, la medida del tubo Pitot resultó ser intrínsecamente ruidosa, por las turbulencias propias de la corriente de aire al colisionar sobre el sensor, y no lineal en su relación medida/velocidad, por lo que hubo que buscar una aproximación polinómica que se ajustó mediante el método de mínimos cuadrados.

Las medidas de velocidad del rodillo de inercia y de los pulsos de ignición de la bujía son, por su propia naturaleza, bastante inmunes a los ruidos, siempre que se asegure una buena relación señal/ruido, sin embargo, introducen errores por el proceso de muestreo. Para minimizar estos errores es conveniente muestrear de forma que se produzcan muchos pulsos por cada iteración, es decir, definir un periodo de iteración varios órdenes de magnitud superior al periodo con el que ocurren esos pulsos. Para señales de frecuencias relativamente bajas como las que intervienen en este sistema resulta en una baja velocidad de refresco de la medida que dificulta una representación adecuada de las variables. Es por tanto imprescindible trabajar con periodos de muestreo relativamente pequeños que suponen la cuenta de pocos pulsos por iteración. Así, el que en una iteración respecto a otra consecutiva aparezca una diferencia de un solo pulso, aunque el valor de la variable no haya cambiado, supondrá una diferencia en la medida porcentualmente alta en una iteración respecto a la otra.

2.3. Reducción de ruidos

Para la reducción del ruido de las diferentes medidas se ha empleado el algoritmo del filtro de Kalman discreto unidimensional, implementándose una batería de 4 filtros, una

por cada variable medida. No obstante, fue necesario añadir un quinto filtro para la estimación de una quinta variable calculada en el propio algoritmo. En efecto, la aceleración, necesaria para el cálculo del par desarrollado por la motocicleta, se calcula mediante la estimación de la derivada de la velocidad angular del rodillo, la cual, a su vez, se calcula en función del nº de dientes que el sensor inductivo ha detectado en cada periodo de iteración. Pese a filtrar la medida del número de dientes, el cálculo de la aceleración resultó ser una variable bastante ruidosa, debido a la alta sensibilidad respecto a los errores cometidos en la estimación de éstos.



Medida ruidosa y filtrada




Figura 4: Medidas de la velocidad del aire. Eliminación de ruido y aproximaciones polinómicas.




Figura 5: Batería de 5 filtros de Kalman.

3. Pruebas y resultados

Las pruebas iniciales sobre el sistema, sin la inclusión del algoritmo del filtro de Kalman, demostraron la imposibilidad de llevar a cabo la acción de control sobre el variador de velocidad y el trazado de curvas de par y potencia desarrollados por el vehículo, objetivo final del sistema.

Los primeros análisis que desvelaron la fuerte carga de ruido presentes en las medidas sugirieron la necesidad de emplear alguna solución “software”, ya que el apantallamiento y otras soluciones tradicionales no fueron suficientes. La implementación del filtro de Kalman en las medidas fue un avance significativo en la reducción de ruido, véase, por ejemplo, el resultado obtenido para la medida de la velocidad del viento mostrado en la Figura 4. No obstante, el cálculo de la aceleración a partir de las medidas de velocidad de dos iteraciones consecutivas seguía siendo una señal ruidosa que imposibilitaba el trazado de las curvas. El empleo del quinto filtro de Kalman para esta variable terminó de solucionar el problema.




Figura 6: Resultado sin filtro (izquierda) y con filtro (derecha) en la variable aceleración. Comparación de resultados ante una situación de aceleración en condiciones similares.

La Figura 6 muestra las curvas de par y potencia que se obtuvieron ante una aceleración. Puede apreciarse como antes de la inclusión del quinto filtro los ruidos generados en el cálculo de la aceleración impedían un trazado “limpio” de las curvas (curvas de la izquierda) así como el resultado final (curva de la derecha).

4. Conclusiones

En este trabajo se ha presentado una aplicación práctica del filtro de Kalman en un sistema de control fuertemente afectado por ruido. Se ha comprobado la bonanza de este algoritmo, no sólo para la reducción de ruidos en las medidas sino también para reducir las propias perturbaciones creadas por el carácter discreto del algoritmo de control. En su modalidad discreta unidimensional, el filtro de Kalman demuestra ser una herramienta potente y de fácil implementación.


Referencias

- Barragán, A. J., 2020. Iterative fuzzy modeling of hydrogen fuel cells by the extended Kalman filter. IEEE Access. DOI: 10.1109/ACCESS.2020.301.3690
- Kalman, R. E., 1960. New approach to linear filtering and prediction problems. J. Basic Eng., vol 80, n° 1, pp. 35-45.
- Kalman, R. E., 1963. New methods in Wiener filtering theory. Proc. 1st Symp. Eng. Appl. Random Function Theory Probab., J. L. Bogdanoff and F. Kozin, Eds. New York, NY, USA: Wiley.
- Li, Q., 2015. Kalman filter and its application. Proc. 8th Int. Conf. Intell. Netw. Intell. Syst. (ICINIS), pp. 74-77.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Sintonización heurística mediante algoritmos genéticos del control de un prototipo de un aerogenerador

Andrade, G.^{a,*}, Esteban, S.^b, Santos, M.^c, García, L.^b

^a Facultad de Ciencias Físicas, UCM, 28040, Madrid, España.

^b Departamento de Arquitectura de Computadores y Control, Facultad de Ciencias Físicas, UCM, 28040 Madrid, España.

^c Instituto de Tecnología del Conocimiento, UCM, 28040 Madrid, España.

To cite this article: Andrade, G., Esteban, S., Santos, M., García, L., 2022. Intelligent Control Tuning using Genetic Algorithms in Wind Turbine Scale Model. XVII Simposio CEA de Control Inteligente.

Resumen

La gran madurez de las energías renovables permite la búsqueda de métodos de control más sofisticados de la mano de la mejora computacional propiciada por los avances tecnológicos. Como resultado, se ha obtenido una mejora en cuanto a especificaciones de las turbinas eólicas y eficiencia en los últimos años. En el presente artículo se diseña un modelo a escala de un aerogenerador el cual incluye dos lazos de control para la estabilización de la potencia extraída; el lazo externo se encarga de controlar la carga eléctrica del generador, mientras que el lazo interno controla el ángulo de pitch de las palas de la turbina. El objetivo principal del prototipo es la obtención de un comportamiento análogo al de un aerogenerador convencional, respetando las regiones de operación correspondientes. Partiendo de una sintonización experimental, se optimizan los parámetros del control con ayuda de algoritmos genéticos, dotando de una mayor inteligencia al sistema con la capacidad de adaptarse a distintas condiciones. Finalmente, se obtiene un modelo de turbina eólica capaz de realizar pruebas de algoritmos de control y sirviendo como base para prototipos de aerogeneradores flotantes (FOWT).

Palabras clave: Turbina eólica, Control PID, Algoritmos Genéticos, Sintonía, Réplica.

Heuristic Tuning using Genetic Algorithms of the Control of a Wind Turbine Scale Model

Abstract

The reached maturity of renewable energies allows the application of more sophisticated and efficient control methods due to the computational advances made by the technology. As a result, an improvement in wind turbine specifications and efficiency has been obtained in recent years. In this paper, a wind turbine scale model is designed which includes two control loops for the stabilization of output power: the external loop is responsible of the control of the electrical load of the generator, while the inner loop controls the pitch angle of the turbine blades. The main objective of the prototype is to obtain a behavior analogous to that of a conventional wind turbine, with the corresponding operating regions. Starting from an experimental tuning, the control parameters are used using genetic algorithms, giving the system greater intelligence and the ability to adapt to different conditions. Finally, a wind turbine model able to testing control algorithms is obtained, serving as a base for floating offshore wind turbine prototypes (FOWT).

Keywords: Wind Turbine, PID Control, Genetic Algorithms, Tuning, Replica.

1. Introducción

En la actualidad, la energía eólica experimenta un desarrollo sin precedentes a nivel mundial. La reciente aparición de turbinas flotantes ha incrementado las expectativas en producción de energía. No obstante, esto ha

hecho aparecen nuevos desafíos de control [1]. Los algoritmos de control adquieren un mayor nivel de sofisticación con el fin de abordar estos problemas de mayor complejidad y aumentar la eficiencia y estabilidad de las turbinas [2]. El diseño de los controles más avanzados e inteligentes son usualmente diseñados y desarrollados en

simulación, lo que no considera algunos factores que afectan al control en las turbinas reales. Un paso intermedio, antes de probar el control en las turbinas, es testear los algoritmos de control en prototipos a escala. Además, estos modelos físicos a baja escala son un paso previo que facilita a la industria y a las compañías la incorporación de nuevas técnicas de control en sus sistemas.

Con este propósito, en el presente artículo se describe un modelo a escala de un aerogenerador real. Este prototipo, que incluye significantes mejoras con respecto al modelo inicial [3], es equipado con diferentes subsistemas que permiten probar distintos algoritmos de control. El modelo físico finalmente obtenido es mostrado en la Figura 1. Este incluye hardware en los lazos de control y en las dinámicas del sistema, escalados apropiadamente.




Figura 1: Modelo a escala de aerogenerador.

Dicho prototipo ha permitido observar los problemas que aparecen al trabajar con sistemas reales y los cuales no se llegan a manifestar en las simulaciones. La validación de diferentes soluciones de control en el modelo a escala facilitará la implementación de las mismas en modelos de molinos a escala media o en dispositivos de viento reales [4].

La estructura del artículo es la siguiente. La sección 2 presenta el modelo de aerogenerador. En la sección 3, el modelo es descrito, explicando la composición de cada subsistema. Los resultados experimentales son mostrados en la sección 4. Finalmente, se incluyen las conclusiones y el trabajo futuro al final del artículo.

2. Modelado de aerogenerador

2.1. Modelo aerodinámico

El rendimiento aerodinámico de un aerogenerador es clave para entender cómo mejorar la extracción de energía de las turbinas [5]. La potencia del viento a la entrada de la turbina es dada por la siguiente expresión:

$$P_{in} = 0.5\rho AU^3 [W] \quad (1)$$

Donde $\rho [kg/m^3]$ representa la densidad del viento, $A[m^2]$ es el área barrida por las palas, y $U[m/s]$, el promedio de la velocidad del viento. Teniendo en cuenta el límite de Betz, la relación entre la potencia de entrada P_{in} con la potencia de salida de la turbina P_{out} es denominado

coeficiente de potencia C_p (2). Dicho coeficiente depende del ángulo de pitch de las palas, $\theta [^\circ]$, y del Tip Speed Ratio (TSR) λ .

$$C_p(\lambda, \theta) = \frac{P_{out}}{P_{in}} \quad (2)$$

El TSR es un coeficiente adimensional, el cual relaciona la velocidad tangencial de las puntas de las palas y la velocidad del viento.

$$\lambda = \frac{rw_t}{U} \quad (3)$$

Donde $r[m]$ y $w_t[rad/s]$ son el radio y la velocidad angular de la turbina del aerogenerador, respectivamente. Cuando el ángulo de pitch de las palas se incrementa, el coeficiente de potencia disminuye, y en consecuencia, la potencia de salida de la turbina [6]. Incluso aumentando el valor del TSR, existe un punto de inflexión que limita la extracción de potencia, resultado de la excesiva aceleración de la turbina. Este es el motivo por el cual los aerogeneradores no son capaces de alcanzar el límite establecido por Betz.

Es más, en el propio modelo a escala es necesario trabajar con elevados ángulos de pitch para compensar la baja velocidad del viento empleado en pruebas de laboratorio. Sin embargo, el efecto del coeficiente de potencia es replicado correctamente gracias a la acción del control de pitch.

2.2. Regiones de operación del aerogenerador

En función de la velocidad del viento que llega al rotor, (Figura 2), se diferencian hasta cuatro regiones de trabajo:

- Región I: La velocidad del viento no es lo suficientemente alta como para que la turbina comience a generar potencia. El sistema permanece estático hasta que la velocidad de conexión es alcanzada.
- Región II: Una vez que la turbina comienza su arranque, la extracción de potencia es maximizada hasta que se alcanza la potencia nominal.
- Región III: Con el fin de estabilizar la potencia extraída frente a las variaciones del viento, se aplica el control de pitch.
- Región IV: En caso de superar la velocidad máxima de trabajo, se ejecutan los protocolos de emergencia pertinentes.




Figura 2: Regiones de operación de un aerogenerador [7].

3. Modelo a Escala de Aerogenerador

El prototipo forma parte de una réplica (escala $\approx 1/100$) de un aerogenerador terrestre. Al igual que un aerogenerador real, incluye dos lazos de control: uno interno que controla el ángulo de pitch de las palas, y otro externo que controla la carga eléctrica del generador. En la Figura 3 se muestran los principales componentes que incorpora el sistema completo.

La turbina está formada por unas palas hechas a medida instaladas sobre un mecanismo de paso variable, y ancladas a un motor de radio-control brushless a modo de generador eléctrico. Se incluye un *circuito adaptador de señal* para poder tratar la señal trifásica del generador sin poner en riesgo la electrónica. El *microcontrolador* es capaz de obtener la frecuencia de la señal, y con ella, las revoluciones de la turbina a través de la FFT. Una vez se obtienen las rpm de la turbina, se ejecutan los algoritmos de control pertinentes sobre los *actuadores* de carga y de pitch.




Figura 3: Subconjunto de sistemas del modelo a escala de aerogenerador

3.1. Palas y mecanismo de pitch

Para emular correctamente el funcionamiento de un aerogenerador, se han diseñado y construido palas específicas con ayuda de una impresora 3D. Con un perfil aerodinámico simétrico, el NACA0012 (de la National Advisory Committee for Aeronautics) supone una solución eficaz para una mayor captura de potencia. Estas palas tienen mayor inercia que las palas de radiocontrol comerciales, añadiendo un mayor realismo al funcionamiento del prototipo. A modo de actuador, se emplea un servomotor SG90 RC junto al mecanismo de paso variable de dos palas (ver Figura 4).



Figura 4: Perfil NACA 0012 y actuador del ángulo de pitch variable (gobernado por el servomotor)

Con esta configuración, se han llevado a cabo un conjunto de experimentos en lazo abierto para caracterizar el coeficiente C_p sobre un ángulo de pitch óptimo.

3.2. Generador eléctrico y actuador de carga

El aerogenerador eléctrico es emulado con un motor brushless de radiocontrol, el cual provee de una señal trifásica. La frecuencia de la señal eléctrica es directamente proporcional a la velocidad angular (rpm) del rotor, y depende del número de pares de polos del estátor.

$$w_s = \frac{60f_g}{N} [\text{rpm}] \quad (4)$$

Siendo w_s la velocidad de sincronismo, $f_g [\text{Hz}]$, la frecuencia de la señal trifásica, y N , el número de pares de polos.

Este generador contiene seis pares de devanados enfrentados en el estátor, obteniendo una velocidad de sincronismo diez veces mayor a la frecuencia de la señal. Se diseña un mecanismo actuador capaz de aumentar la potencia extraída para una misma señal trifásica, y en consecuencia, el par electromagnético. Por este motivo, la carga resistiva entre los terminales del generador se modifica por medio de un banco de cargas (Figura 5). Dicho dispositivo es usado para garantizar una disipación de potencia adecuada. Usando un relé de cuatro canales, se logra alternar entre los resistores en paralelo, obteniendo hasta dieciséis estados posibles.




Figura 5: Actuador de carga (banco de cargas con resistencias cerámicas y relé de cuatro canales).

3.3. Sistema de medida

En el sistema completo, el modelo a escala de aerogenerador incluye un circuito adaptador para poder procesar la señal de forma segura (Figura 6). El microcontrolador se encarga de leer la señal trifásica para obtener las revoluciones de la turbina y calcular la potencia generada.

El circuito adaptador de señal es responsable de limitar la señal trifásica al rango de lectura del conversor analógico digital del microcontrolador. En primer lugar se incorporan optoacopladores capaces de aislar eléctricamente la salida del generador al circuito de medida. Seguidamente, se incluyen amplificadores operacionales en configuración de amplificador inversor para regular la amplitud de la señal en función del valor de las resistencias incorporadas.

Sin embargo, al trabajar con señales centradas en cero, es necesario incluir una etapa de offset para centrar la señal en el rango de lectura. Para ello, se incorpora un amplificador

operacional en configuración de amplificador no inversor, el cual suma señal continua a partir del terminal intermedio de un potenciómetro en configuración de divisor de tensión entre alimentación y tierra. Finalmente, se obtiene una impedancia de entrada muy alta la cual limita la potencia disipada en el sistema de medida.




Figura 6: Sistema de medida con circuito adaptador de señal (etapa de escalado y etapa de offset)

3.4. Microcontrolador

Se ha seleccionado el Arduino Nano 33 IOT [8] para cómputo y procesamiento de la señal eléctrica. Dicho microcontrolador incorpora hasta ocho entradas analógicas, ofreciendo un sistema completamente modular con la posibilidad de añadir multitud de sensores y periféricos. A su vez, incorpora un módulo IMU capaz de calcular la posición del sistema, una funcionalidad muy útil para implementaciones futuras en aerogeneradores flotantes.

La señal adaptada es leída por el microcontrolador, empleando uno de los conversores analógico digital. La señal digital es procesada en tiempo real usando la FFT. De este modo, es posible calcular la frecuencia y la amplitud de la señal, y con ello, la velocidad angular y la potencia de salida de la turbina.

La información recogida del sistema consta de: la posición, la velocidad angular, el ángulo de pitch de las palas, la carga y la potencia eléctrica. Los datos son enviados de forma simultánea a través de conexión puerto serie y de una dirección IP seleccionada gracias a una conexión Wifi-UDP. Para la representación de los datos mencionados se emplea el software de Matlab® Simulink. Para dotar de una mayor independencia al sistema, la información es mostrada sobre una pequeña pantalla LCD.

3.5. Sistema de control de carga

Para controlar la velocidad de rotación del aerogenerador es necesario controlar el torque electromagnético del generador.

$$\tau_g = P_g / (\eta_g \eta_m \omega_g) [Nm] \quad (5)$$

Donde $P_g [W]$ es la potencia extraída del generador, η_g la eficiencia del generador, η_m la eficiencia del mecanismo, y $\omega_g [rad/s]$ la velocidad de rotación del generador, en este caso, igual a velocidad de la turbina. El mencionado torque se opone al torque generado por el viento sobre las palas, ralentizando la turbina.

El microcontrolador maneja el cambio entre los diferentes estados posibles hasta que el torque electromagnético sea capaz de controlar la velocidad del rotor, en función del estado de la turbina. En las regiones de operación correspondientes (Figura 2), se aplica un control PD para

estabilizar la potencia extraída. La acción proporcional es capaz de reducir el error a la salida, mientras que la acción diferencial es la responsable de compensar la inercia del sistema.

$$G_{PD}(s) = K_{PL} + K_{DL} s \quad (6)$$

3.6. Sistema de control de pitch

El control de pitch es implementado mediante un regulador PID, el cual además de reducir el error en el estado transitorio, elimina el error en el estado estacionario. El control de pitch es lo suficientemente preciso como para estabilizar la turbina del aerogenerador dentro de un rango restringido en torno a pocos cientos de rpm.

El algoritmo de control de pitch sigue la siguiente expresión con las ganancias correspondientes:

$$\phi(s) = K_{P\phi} + K_{I\phi}/s + K_{D\phi} s \quad (7)$$

Al mismo tiempo, el actuador de pitch puede usarse para ejecutar el modo de parada de emergencia en caso de ser necesario.

3.5. Arquitectura del software

Mediante una correcta codificación secuencial es posible solucionar la ausencia de hilos de ejecución del procesador mononúcleo. El archivo main.c incluye: las cabeceras de los demás ficheros, el arranque de los subsistemas, la lectura de la señal, la aplicación de los algoritmos de control y la transmisión de datos.

Una vez se realiza la lectura de la señal, se calcula la frecuencia, la potencia generada y, de ser necesario, se ajusta la ganancia de entrada. Con la frecuencia obtenida se calcula la velocidad del rotor y seguidamente se detecta la región de operación en la que se encuentra el sistema. Los algoritmos de control permiten manejar los actuadores necesarios para regular las rpm. Finalmente, la información es transmitida por los diferentes canales de comunicación.

En la Figura 7 se muestran las estructuras del software implementada en la placa (disponible en [9]).




Figura 7: Estructura de código incluido en el microcontrolador.

4. Resultados Experimentales

El primer paso para llevar a cabo las pruebas experimentales es ajustar el sistema en torno al ángulo óptimo de pitch, donde se alcanza el mayor coeficiente de potencia. Gracias a la simplicidad de los controladores PD y PID, es posible sintonizar el sistema mediante prueba y error (sintonización manual).




Figura 8: Velocidad angular (rpm) (gráfica azul), ángulo de pitch (grados) (gráfica verde) y estado de la carga eléctrica (gráfica naranja) para una velocidad del viento variable.

En la anterior figura se muestra el funcionamiento que sigue el modelo a escala de aerogenerador para una frecuencia objetivo de 500 rpm. Se puede observar como los valores de los actuadores se adaptan para alcanzar el valor objetivo (gráfico superior, línea azul), usando los dos lazos de control independientes (control de cabeceo, línea verde, y control de carga, línea roja) para hacer frente a las variaciones de la velocidad del viento. Las regiones de funcionamiento de una turbina eólica típica son mostradas en la Figura 8 y son las siguientes:

- Región I: La turbina permanece parada hasta que la velocidad de arranque supera la velocidad de conexión. Se colocan las palas con el mayor ángulo de pitch posible para disminuir el par mecánico estático. Del mismo modo, se aplica el mejor torque electromagnético colocando la mayor resistencia disponible (estado de la carga 0).
- Región II: Una vez el rotor comienza a girar, el aerogenerador empieza a disminuir exponencialmente el ángulo de pitch hacia el óptimo. Al mismo tiempo, se incrementa el estado de la carga para maximizar la potencia extraída y reducir la inercia del sistema hasta llegar a alcanzar la velocidad nominal. En esta región solo se aplica el control de carga.
- Región III: El control de pitch es activado para estabilizar la potencia de salida de la turbina. El control de carga eléctrica es desactivado mientras la velocidad angular se mantenga dentro del rango de trabajo.
- Región IV: En caso de sobrepasar el rango de trabajo (tanto por encima como por debajo), se activa de nuevo el control de carga eléctrica, manteniendo constante el valor del ángulo de pitch. Si el control de carga eléctrica no es capaz de limitar la velocidad de la turbina, se activa el protocolo de parada de

emergencia, colocando las palas de forma perpendicular a la velocidad del viento.

5. Sintonización Óptima mediante Algoritmos Genéticos

El ingeniero debe proveer al sistema de una configuración óptima de control para distintas condiciones. La puesta a punto del control del sistema se realiza con la toolbox de optimización de Matlab. Los algoritmos genéticos se aplican en base a la preservación de los mejores individuos (elitismo), la mutación de genes y el cruce de los individuos para la búsqueda de los mejores resultados [10]. Las ganancias del controlador $[k_p, k_i, k_d]$, se seleccionan como variables de optimización. Se genera una población inicial de treinta individuos con una distribución uniforme. Las variables de optimización se han limitado a un rango cercano al objetivo en el estudio inicial. A lo largo de cien generaciones, se evalúa la función objetivo para cada posible solución.

La integral del tiempo multiplicada por el valor absoluto del error (ITAE) es usada como función de coste para una entrada escalón. El tiempo de asentamiento de la sintonización experimental es usado como referencia para el intervalo de integración. De este modo, es posible considerar las posibles soluciones que devuelvan el menor error en el estacionario en cada simulación.

$$ITAE = \int_0^{t_s} t \cdot |e(t)| \cdot dt \quad (8)$$

En cada generación, el 5% de los mejores individuos sobreviven y pasan directamente a la siguiente generación. Se emplea un método de torneo para la selección de los progenitores que llevarán a cabo el cruce de un grupo. El 80% de la siguiente población se genera empleando este operador. A su vez se aplica una pequeña probabilidad de mutación en cada descendiente, ciñéndose a los valores de restricción. En la Figura 9 se muestra la evolución de los mejores individuos con respecto al criterio ITAE.




Figura 9: Evolución de las posibles soluciones para los parámetros de sintonía del control PID mediante algoritmos genéticos.

Una vez se alcanza el número máximo de generaciones, el algoritmo obtiene los valores óptimos del control PID: $K_p = 0.3$, $K_i = 0.0038$, $K_d = -0.0434$. Las ganancias obtenidas del controlador discreto sintonizado por prueba y error son: $K_p' = 0.03$, $K_i' = 0.01$, and $K_d' = -0.01$.

En la Figura 10 se muestra la respuesta del sistema, en el cual se observa un menor tiempo de asentamiento para el controlador sintonizado por algoritmos genéticos (línea roja). Además, la salida no presenta apenas sobreelongación en comparación al control PID sintonizado experimentalmente (línea azul).




Figura 10: Respuesta del control PID del aerogenerador con diferentes métodos de sintonía.

El aerogenerador real posee cierta inercia que ralentiza la respuesta respecto a la señal de entrada. Además, el sistema debe superar una resistencia inicial de arranque. El incremento de las acciones de los controladores en el sistema real podría causar una respuesta menos estable. A su vez, el microcontrolador requiere de al menos un periodo de muestreo de 0.5 segundos para realizar la medidas de las rpm y la ejecución de los algoritmos de control.

Incluso obteniendo respuestas similares, la optimización del controlador a través de algoritmos genéticos ha conseguido reducir la sobreelongación del sistema junto a la reducción del tiempo de asentamiento.

6. Conclusiones y Trabajo Futuros

En este trabajo se ha descrito el diseño de un prototipo de aerogenerador a escala de laboratorio. El modelo se ha enfocado en la implementación de la electrónica y mecánica necesaria para poder llevar a cabo pruebas de control de lazo cerrado de un aerogenerador. Se han implementado dos lazos de control, uno externo que controla la carga eléctrica y uno interno que controla el paso de las palas. En las pruebas experimentales, el modelo cambia entre los modos de operación típicos de un aerogenerador con una respuesta consistente.

El aerogenerador a escala se ha identificado con el suficiente detalle como para ajustar los controladores mediante algoritmos genéticos. Se ha demostrado cómo los

controladores sintonizados por la técnica heurística de los algoritmos genéticos dan una mejor respuesta del sistema que los ajustados experimentalmente en base al conocimiento del ingeniero.

Por lo tanto, el prototipo se puede emplear para testear algoritmos de control más complejos. Además, como el modelo a escala de aerogenerador es capaz de registrar la posición de la estructura, puede ser usado para replicar aerogeneradores flotantes con una configuración que integre el movimiento de las olas [11]. Esto forma parte de los trabajos futuros junto a la mejora en la comunicación inalámbrica y la evaluación de otras técnicas de optimización para el ajuste de control [12]. El objetivo final es desarrollar una réplica de aerogenerador totalmente autónoma, con recogida de datos subida a la nube, que puede ser controlado telemáticamente por el administrador de la red.

Agradecimientos

Esta publicación ha sido parcialmente financiada por el Ministerio de Ciencia e Innovación de España bajo el proyecto MCI/AEI/FEDER número RTI2018-094902-B-C21.


Referencias

- Sierra-García, J.E., and Santos, M.: Redes neuronales y aprendizaje por refuerzo en el control de turbinas eólicas. *Revista Iberoamericana de Automática e Informática industrial* 18.4 (2021): 327-335.
- Sierra-García, J. E., Santos, M.: Performance analysis of a wind turbine pitch neurocontroller with unsupervised learning, 2020, *Complexity*, 2020.
- Andrade, G.A., Esteban, S.: Modelo a escala de aerogenerador para control. In: Aitor J. Garrido et al. (eds.), *Innovation and Lecture Notes In Control Engineering For Clean Energy Generation*, pp 53-58. Universidad del País Vasco, Bilbao (2021).
- López, R., Santos, M., Polo, O., Esteban, S.: Experimenting a fuzzy controller on a fast ferry. In *Proceedings of the IEEE Int. Conf. on Control Applications CCA*, 2002, vol. 2, pp. 1082- 1087. IEEE.
- Alzayed, M., Chaoui, H., & Farajpour, Y. (2021). Maximum power tracking for a wind energy conversion system using cascade-forward neural networks. *IEEE Transactions on Sustainable Energy*, 12(4), 2367-2377.
- Sierra-García, J. E., Santos, M.: Lookup table and neural network hybrid strategy for wind turbine pitch control. *Sustainability*, 2021, 13(6), 3235.
- Chavero-Navarrete, E., Trejo-Perea, M., Jáuregui-Correa, J.C., Carrillo-Serrano, R.V., Ronquillo-Lomeli, G., Ríos-Moreno, J.G.: Hierarchical pitch control for small wind turbines based on fuzzy logic and anticipated wind speed measurement. *Applied Sciences* 2020, 10(13):4592.
- ARDUINO Store, <http://store.arduino.cc/products/arduino-nano-33-iot>, last accessed 2022/02/25
- GITHUB, https://github.com/GGiordy/TFG_Giordy_Alexander.git, last accessed 2022/02/25
- Zotes, F. A., & Penas, M. S. (2010). Multi-criteria genetic optimisation of the manoeuvres of a two-stage launcher. *Information Sciences*, 180(6), 896-910.
- Villoslada, D., Santos, M., & Tomás-Rodríguez, M. (2021). General methodology for the identification of reduced dynamic models of barge-type floating wind turbines. *Energies*, 14(13), 3902.
- Torrallba-Morales, L. M., Reynoso-Meza, G., & Carrillo-Ahumada, J. (2020). Tuning and comparison of design concepts applying Pareto optimality. a case study of cholette bioreactor. *Revista Iberoamericana de Automática e Informática Industrial*, 17(2), 190-201.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Estudio de estructuras neuronales NARX para reproducir el comportamiento de sistemas con dinámicas complejas

Aimar Alonso, Asier Zabaljauregi, Eloy Irigoyen, Mikel Larrea

Universidad de País Vasco / Euskal Herriko Unibertsitatea (UPV/EHU)

To cite this article: Alonso, A., Zabaljauregi, A., Irigoyen, E., Larrea, M., 2022. Study of NARX neural structures to reproduce the behaviour of systems with complex dynamics. XVII Simposio CEA de Control Inteligente.

Resumen

Este trabajo presenta un estudio preliminar donde se valorará la eficiencia de las redes neuronales artificiales de topología NARX (Nonlinear Autoregressive eXogenous) en la reproducción del comportamiento de sistemas con dinámicas complejas. Estas estructuras neuronales se diseñarán para reproducir tanto sistemas monovariantes, como multivariantes, siguiendo un mismo planteamiento metodológico. Los mencionados estudios están dirigidos a proporcionar dichos modelos neuronales a futuras estrategias de control dependientes de modelos dinámicos, como es el caso del control predictivo no lineal basado en modelos, el cual constituye una línea de trabajo dentro del grupo de investigación de control inteligente (GICI) de la UPV/EHU.

Palabras clave: Red Neuronal, Sistemas no lineales, Identificación

Study of NARX neural structures to reproduce the behaviour of systems with complex dynamics.

Abstract

This work presents a preliminary study that evaluates the NARX artificial neural network performance in reproducing the behaviour of complex dynamics systems. These neural structures will be designed to reproduce both monovariant and multivariant systems, following the same methodological approach. These studies are aimed at providing neural models to future control strategies dependent on dynamic models, as is the case of non-linear predictive control based on models, which constitutes a new line of work within the Intelligent Control Research Group (GICI) at UPV/EHU.

Keywords: Neural Networks, Nonlinear systems, Identification

1. Introducción

En el mundo real, los sistemas a controlar son complejos, ya que incluyen no linealidades e interacción entre las diferentes entradas y salidas de este. Esto causa que la identificación de las características del sistema para desarrollar un modelo sea un proceso complicado, especialmente si el modelo será usado en métodos como *Model Predictive Control* (MPC), que requieren de una buena aproximación de los parámetros del proceso.

En este ámbito, se ha extendido el uso de Redes Neuronales Artificiales (RNA) para la modelización de estos sistemas, ya que se ha comprobado que son aproximadores universales (Hornik et al., 1990), (Jagannathan y Lewis, 1996), (Perrusquía y Yu, 2021). Estos modelos neuronales son así implementables

en las estrategias de control mencionadas, como MPC o su versión no lineal (NMPC) (Camacho y Bordons, 2007), obteniendo buenos resultados (Bamimore et al., 2021).

En este trabajo, se busca modelizar sistemas no lineales mediante RNA, tanto con una única salida y entrada (*Single Input Single Output*, SISO), como con múltiples (*Multiple Input Multiple Output*, MIMO), comparando la respuesta obtenida respecto al modelo real.

2. Presentación del problema

Los sistemas empleados en este trabajo son sintéticos, que buscan valorar el rendimiento de este método de identificación, debido a que presentan regiones con grandes no linealidades. Estos sistemas han sido empleados anteriormente en otros trabajos relacionados con la identificación de modelos no lineales (Larrea et al., 2015). Para ofrecer una representación de las no linealidades de ambos sistemas, se presenta en la Figura 1 un

Correos electrónicos: aalonso198@ikasle.ehu.eus (Aimar Alonso), azabaljauregi001@ikasle.ehu.eus (Asier Zabaljauregi), eloy.irigoyen@ehu.eus (Eloy Irigoyen), m.larrea@ehu.eus (Mikel Larrea)




Figura 1: Relación de entradas/salidas de los sistemas en régimen estacionario

conjunto de puntos de operación en régimen estacionario, mediante la relación entrada/salida, cuyos rangos abarcan dinámicas no lineales suficientemente significativas.

Estos modelos son ambos modelos monovariantes y se ha estudiado uno de ellos, el SNL5, para el primer caso (SISO). Para el estudio del segundo caso (MIMO), sin embargo, se ha generado un sistema multivariable no acoplado con ambos. Para ello se ha creado un sistema compuesto por SNL1 y SNL5.

Las RNA empleadas son de arquitectura NARX en lazo abierto, haciéndose un estudio del rendimiento de las mismas con distintos valores para el número de neuronas en la capa oculta y retardos de las entradas, con el objetivo de obtener redes neuronales que realicen una buena aproximación al sistema real, pero sin sobredimensionamiento.

2.1. SISO

En primer lugar, se ha estudiado el sistema no lineal denominado SNL5:

$$y_{k+1} = \frac{1,5 \cdot y_k \cdot y_{k-1}}{1 + y_k^2 + y_{k-1}^2} + 0,7 \cdot \sin(0,5 (y_k + y_{k-1})) \cdot \cos(0,5 (y_k + y_{k-1})) + 1,2u_k \quad (1)$$

Al ser un sistema con una única entrada y una única salida, se variarán el valor del número de neuronas entre 2 y 6, siendo los retardos de las entradas externas (u) 0 o 0/1, y los retardos de la salida real ($target$) 1 o 1/2.

2.2. MIMO

En segundo lugar, se ha estudiado el caso de un sistema MIMO desacoplado, compuesto por el sistema SNL5, y otro sistema no lineal denominado SNL1:

$$\begin{cases} y_{1,k+1} = \frac{1,5 \cdot y_{1,k} \cdot y_{1,k-1}}{1 + y_{1,k}^2 + y_{1,k-1}^2} + 0,7 \cdot \sin(0,5 (y_{1,k} + y_{1,k-1})) \cdot \cos(0,5 (y_{1,k} + y_{1,k-1})) + 1,2u_{1,k} \\ y_{2,k+1} = \frac{y_{2,k}}{1 + y_{2,k}^2} + u_{2,k}^3 \end{cases} \quad (2)$$

Al ser un sistema MIMO, más complejo, se aumentará el rango de valores de número de neuronas entre 8 y 20, en saltos de 2, para reducir el número de redes a entrenar; y los retardos, al igual que en el anterior caso, de las entradas externas (u) 0 o 0/1, y los retardos de la salida real ($target$) 1 o 1/2.




Figura 2: MSE de configuraciones de redes para el sistema SISO

3. Resultados

Para la obtención de los modelos neuronales se ha realizado un barrido de parámetros, siendo las entradas y *targets* de entrenamiento iguales para todas las redes.

Debido a que el punto de comienzo de cada entrenamiento es aleatorio, no se puede asegurar que la red sea óptima, por lo que se han entrenado 4 redes distintas para cada combinación de parámetros, y de estas se ha escogido aquella con mejor rendimiento en validación con entradas distintas a las de entrenamiento.

Tras obtener la mejor red para cada combinación de parámetros, se ha realizado un gráfico de barras del Error Cuadrático Medio (*Mean Square Error*, MSE) para tomar la decisión de la mejor red del conjunto. Finalmente, se ha realizado un gráfico de la validación de esta red para observar el comportamiento y la aproximación del sistema a identificar.

3.1. SISO

Realizando el proceso de entrenamiento de las redes mencionado, se ha obtenido el gráfico de MSE de las redes (figura 2). En este gráfico se observa que el parámetro que mayor impacto tiene en la disminución del error son los retardos de entrada y *target*. Así, observando el gráfico, se ha decidido elegir la red con 4 neuronas, y retardos de entradas 0/1 y retardos de *targets* 1/2. No se ha seleccionado un número mayor de neuronas, debido a que la reducción del error obtenida es muy pequeña en comparación con el aumento del tiempo de computación necesario.

Graficando la respuesta del sistema frente a una entrada u en el rango $[-2, 2]$ (figura 3), se ha obtenido una respuesta muy buena, siguiendo la salida real del sistema con error muy reducido.

3.2. MIMO

Tras realizar el entrenamiento de las redes con la combinación de parámetros mencionada, se han obtenido los gráficos de los MSE para ambas salidas (figuras 4 y 5). En estos gráficos,




Figura 3: Respuesta de la red neuronal obtenida frente a una entrada de validación




Figura 4: MSE de configuraciones de redes para el sistema MIMO: Subsistema SNL5

se puede observar de nuevo que el parámetro que mayor impacto tiene en la reducción del error es el retardo, en este caso, de las entradas u , aunque el retardo de los $target$ también tiene impacto al combinarlo con el anterior.

Observando los errores, se ha decidido elegir la red neuronal con 14 neuronas, y retardos de entradas 0/1 y retardos de $targets$ 1/2. De nuevo, no se ha seleccionado un número mayor de neuronas debido a la pequeña disminución del error relacionada con aumentar más el número de neuronas.

Realizando una validación con entradas en los rangos $[-2,5, 2,5]$ para la primera entrada (SNL5), y $[-1,8, 1,8]$ para la segunda entrada (SNL1) (figura 6), se comprueba que la respuesta para ambas salidas es excelente, y sigue muy de cerca ambas salidas simultáneamente, con un error muy ajustado.




Figura 5: MSE de configuraciones de redes para el sistema MIMO: Subsistema SNL1

Num Neuronas = 14 | inputDelay [0,1] - targetDelay [1,2]




Figura 6: Respuesta ante validación de la red neuronal elegida para el sistema MIMO

4. Líneas de trabajo futuras

En el futuro, el objetivo es el desarrollo de un modelo neuronal MIMO de un sistema acoplado. Un ejemplo de este es el modelo *Twin-Rotor*, provisto por *Feedback Instruments Ltd* (Feedback Instruments, 2001); que se trata de un modelo MIMO 2x2 fuertemente acoplado.

Adicionalmente, también queda ampliar el uso de estos modelos neuronales a estrategia de Control Inteligente, como el iMO-NMPC (Valera García et al., 2012) para estos sistemas acoplados, en los que resulta crucial que el error del modelo sea mínimo para que el control funcione.

Otro posible desarrollo futuro de estos modelos neuronales pasa por la inclusión de otros parámetros no contemplados, como la adición de capas adicionales, o otras arquitecturas de redes.

Finalmente se buscará la integración de los modelos obtenidos en aplicaciones de tiempo real de MATLAB/Simulink a

modo de código adicional de s-functions.


Referencias

- Bamimore, A., Osinuga, A., Kehinde-Abajo, T., Osunleke, A., Taiwo, O., 2021. A comparison of two artificial neural networks for modelling and predictive control of a cascaded three-tank system. IFAC-PapersOnLine 54 (21), 145–150, control Conference Africa CCA 2021.
DOI: <https://doi.org/10.1016/j.ifacol.2021.12.025>
- Camacho, E. F., Bordons, C., 2007. Nonlinear Model Predictive Control: An Introductory Review. Springer Berlin Heidelberg, Berlin, Heidelberg, pp. 1–16.
DOI: 10.1007/978-3-540-72699-9₁
- Feedback Instruments, L., 2001. Twin Rotor MIMO System Control Experiments 33-949S. Feedback.
- Hornik, K., Stinchcombe, M., White, H., 1990. Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. Neural Networks 3 (5), 551–560.
DOI: [https://doi.org/10.1016/0893-6080\(90\)90005-6](https://doi.org/10.1016/0893-6080(90)90005-6)
- Jagannathan, S., Lewis, F., 1996. Identification of nonlinear dynamical systems using multilayered neural networks. Automatica 32 (12), 1707–1712.
DOI: [https://doi.org/10.1016/S0005-1098\(96\)80007-0](https://doi.org/10.1016/S0005-1098(96)80007-0)
- Larrea, M., Larzabal, E., Irigoyen, E., Valera, J., Dendaluze, M., 2015. Implementation and testing of a soft computing based model predictive control on an industrial controller. Journal of Applied Logic 13 (2, Part A), 114–125, sI: SOCO12.
DOI: <https://doi.org/10.1016/j.jal.2014.11.005>
- Perrusquía, A., Yu, W., 2021. Identification and optimal control of nonlinear systems using recurrent neural networks and reinforcement learning: An overview. Neurocomputing 438, 145–154.
DOI: <https://doi.org/10.1016/j.neucom.2021.01.096>
- Valera García, J. J., Gómez Garay, V., Irigoyen Gordo, E., Artaza Fano, F., Larrea Sukia, M., 2012. Intelligent multi-objective nonlinear model predictive control (imo-nmpc): Towards the ‘on-line’ optimization of highly complex control problems. Expert Systems with Applications 39 (7), 6527–6540.
DOI: <https://doi.org/10.1016/j.eswa.2011.12.052>



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Implementación de un sistema de control predictivo inteligente para sistemas de dinámicas complejas

Asier Zabaljauregi, Aimar Alonso, Eloy Irigoyen, Mikel Larrea

Universidad de País Vasco / Euskal Herriko Unibertsitatea (UPV/EHU)

To cite this article: Zabaljauregi, A, Alonso, A., Irigoyen, E., Larrea, M., 2022. iMO-NMPC strategy development: First steps for implementation on industrial hardware. XVII Simposio CEA de Control Inteligente.

Resumen

Este trabajo presenta la metodología que se está empleando, dentro del grupo de investigación de control inteligente (GICI) de la UPV/EHU, para el desarrollo de estrategias de control inteligente y su posterior implementación en plataformas de tiempo real. De este modo se pretende realizar una validación de dichas estrategias no solamente desde el punto de vista de simulación, sino acercando estos desarrollos a diferente hardware industrial. El caso de uso que se presenta y que está siendo implementado actualmente es el de la estrategia iMO-NMPC, el cual integra dentro de una estrategia de control predictivo, algoritmos evolutivos para la optimización y redes neuronales para el modelado de sistemas. La metodología que se está empleando hace uso de la plataforma de simulación MATLAB/Simulink®.

Palabras clave: NMPC, Hardware Industrial, *S-Function*, dinámicas complejas

Implementation of an intelligent predictive control strategy for systems with complex dynamics.

Abstract

This work presents the methodology used by the Intelligent Control Research Group (GICI) at UPV/EHU, for the development of intelligent control strategies and their further implementation in real time platforms. In this way, it is intended to provide validation of such strategies not only in simulation level but in several industrial devices. The use case that is being developed is the iMO-NMPC strategy which integrates predictive control strategies, evolutionary algorithms for optimization and neural networks for system modelling. The employed methodology involves the simulation platform MATLAB/Simulink®.

Keywords: NMPC, Industrial Hardware, *S-Function*, complex dynamics

1. Introducción

En el mundo de la ingeniería existen muchos sistemas que presentan dinámicas complejas: procesos químicos, aplicaciones robóticas, vehículos aéreos, etc. Estos sistemas debido a su naturaleza no lineal, o a incertidumbres en su comportamiento, o al acoplamiento entre sus variables, u otras características que hacen compleja la tarea de diseñar un sistema de control específico, no son fácilmente controlables con técnicas de control clásicas. Adicionalmente, una linealización sobre un punto de operación tampoco basta para un control satisfactorio. Asimismo, frecuentemente la tarea de identificación y modelización del sistema a controlar, en base a un estudio matemático apoyado en las leyes que gobiernan el comportamiento de sus

diferentes componentes, se ve dificultada al no tener acceso directo al mismo, por la gran cantidad de parámetros y limitaciones técnicas, o simplemente por razones económicas. Hoy en día, más que nunca, surge la necesidad de identificar y controlar estos sistemas con precisión debido a las especificaciones de fabricación y medidas de seguridad más estrictas. Una de las estrategias más empleadas en la industria es el Control Predictivo basado en Modelo (del inglés, MPC) (Camacho y Bordons, 2007b) y su extensión para sistemas no lineales (NMPC) Camacho y Bordons (2007a); algunos ejemplos aplicados recientemente (Vaneshani y Jazayeri-rad, 2011) (Veselov et al., 2019) (Schaaf, 2020) (Marchante et al., 2021).

El trabajo desarrollado y presentado en este documento se está realizando en el contexto de una novedosa estrategia en el ámbito del control predictivo no lineal denominada iMO-NMPC (*Intelligent Multi-objective Nonlinear Model Predictive Control*) (Valera García et al., 2012). Este trabajo da continuación a anteriores desarrollos realizados en esta línea (Eloy Iri-

Correos electrónicos: azabaljauregi001@ikasle.ehu.eus (Asier Zabaljauregi), aalonso198@ikasle.ehu.eus (Aimar Alonso), eloy.irigoyen@ehu.eus (Eloy Irigoyen), m.larrea@ehu.eus (Mikel Larrea)




Figura 1: Esquema iMO-NMPC

goyen, 2014) (Viana et al., 2020). En este documento se presenta una evolución de los pasos dados en un esfuerzo de implementar esta técnica en una plataforma de simulación como MATLAB/ Simulink®.

2. Desarrollo

La estrategia de control inteligente iMO-NMPC integra una base de MPC, paradigmas procedentes del ámbito de la Computación Inteligente como son los algoritmos evolutivos, redes neuronales artificiales (RNA) para la representación del modelo del sistema a controlar (Hornik et al., 1989) y un *Decision Maker* que da soporte a la etapa de optimización. Mediante la propuesta aportada en este trabajo se pretende abordar el control de procesos industriales no lineales sujetos a perturbaciones, con complejas dinámicas acopladas y presencia de varios objetivos contrapuestos. Un primer paso en el desarrollo de este trabajo es llegar a comprender la función de cada componente de dicha estrategia. La estrategia iMO-NMPC queda representada en el esquema del funcionamiento general de esta técnica en la Figura 1. De forma resumida, su funcionamiento general es el siguiente: el MOGA (*Multi-objective Genetic Algorithm*) (en el caso propuesto NSGA-II (Deb et al., 2002)), genera una población de individuos conformados por H_c cromosomas, es decir el número de acciones de control a aplicar en los instantes del horizonte de control, que se aplican al modelo neuronal de la planta, extendiendo la última acción de control hasta H_p , el horizonte de predicción. Estos individuos se evalúan según unos objetivos definidos (e.g el error ($ref - y$), la variación de la acción de control $\Delta u \dots$) y según su coste (y *crowding index* en NSGA-II) se clasificarán y se emplearán para obtener la siguiente generación mediante operadores genéticos de mutación y *crossover*. Mediante este proceso genético, a lo largo de las iteraciones, se minimizará el coste de esos objetivos. Los individuos dominantes que forman el frente de Pareto se entregan después al *Decision Maker*, para que según el contexto en el que se encuentre la planta elija una u otra solución partiendo del conocimiento de un Agente Experto. De la secuencia de control seleccionada se aplica solamente la primera acción y se vuelve a realizar la optimización iterada una vez se retroalimenta la salida de la planta real.

2.1. Aprendizaje de las herramientas de Simulink

Se ha optado por MATLAB/Simulink para el desarrollo y simulación de el sistema de control propuesto, al ser el software estándar de facto de computación numérica y prototipado de algoritmos. Simulink, herramienta de modelización visual

por bloques, cuenta con bloques de llamada a *S-Functions*, que permiten al usuario programar rutinas personalizadas para su ejecución en conjunción al resto de bloques propietarios. Se ha considerado emplear esta funcionalidad para llevar a cabo la tarea de implementar la estrategia, no solo porque otorga al usuario una mayor flexibilidad a la hora de programar, sino porque bajo condiciones específicas, permite generar el código de la simulación para su posterior ejecución en plataformas de tiempo real.

Simulink cuenta con varias formas de desarrollar estas *S-Functions* o funciones especiales, sin embargo el principal detalle a tener en cuenta es lenguaje de programación; se pueden escribir las *S-Functions* de las siguientes maneras:

1. *Level 1 MATLAB S-Functions*. Una manera muy simple y limitada de programar *S-Functions* mediante *Flags* utilizando lenguaje de MATLAB. Pronto será obsoleto y desechado.
2. *Level 2 MATLAB S-Functions*. Proporciona acceso a un conjunto más amplio de la API de las *S-Functions* y admite generación de código. En esta opción también se emplea el lenguaje de programación de MATLAB. Para habilitar la generación de código, el usuario debe proveer un archivo `.tlc` (*Target Language Compiler*), donde se especifican las pautas de generación.
3. *MEX S-Functions*. Permite implementar algoritmos en formato C MEX *S-Functions* o programar *wrappers* como llamada a código ya existente escrito en C, C++ o Fortran. En este caso, proveer un archivo `.tlc` para la generación de código es opcional.

Se puede encontrar más información sobre el tema en la documentación proporcionada por MathWorks. Por razones de comodidad se ha optado por emplear la tercera manera. En el proceso de aprendizaje del API, se han implementado bloques de *S-Function* como PI, PID con filtro y sin filtro y funciones de transferencia entre otros. Un desarrollo que vale la pena destacar, es un control DMC (*Dynamic Matrix Control*) Figura 2, como primer paso a dar en la programación del control predictivo antes de afrontar la programación del iMO-NMPC.

2.2. Estudio del algoritmo mediante scripts de MATLAB


Antes de pasar a la implementación en C, se ha estudiado el comportamiento de la estrategia iMO-NMPC mediante *scripts* de MATLAB, con diferentes modelos no-lineales como *benchmark*. Los modelos en cuestión han sido empleados anteriormente en (Larrea et al., 2015) y (Larrea et al., 2010). Las ecuaciones de los modelos no lineales empleados son las siguientes:

$$y_{k+1} = \frac{1,5 \cdot y_k \cdot y_{k-1}}{1 + y_k^2 + y_{k-1}^2} + 0,7 \sin [0,5 (y_k + y_{k-1})] \cdot \cos [0,5 (y_k + y_{k-1})] + 1,2u_k \quad (1)$$


$$y_{k+1} = u_k^3 + \frac{y_k}{1 + y_k^2} \quad (2)$$

Los pasos que se reproducen dentro de la estrategia iMO-NMPC se presentan a continuación:

- Paso1: Lectura del estado actual de la simulación.



(a) Esquema de bloques para DMC en Simulink



(b) Salida del sistema y referencia

Figura 2: Modelo de prueba DMC en Simulink

- Paso2: Generación de cromosomas (acciones de control).
- Paso3: Proceso de optimización con predicciones de la RNA.
- Paso4: Selección de acción de control a aplicar.
- Paso5: Aplicar la acción de control y volver al Paso1.

Para el apartado de la optimización se ha empleado el algoritmo genético multi-objetivo @gamultiobj propietario de MATLAB. El @gamultiobj proporciona un frente de pareto con múltiples soluciones entre las que se debe seleccionar la más adecuada. El criterio empleado en este trabajo consiste en la seleccionar aquella solución cuya distancia al origen del frente de pareto sea mínima.

Como modelos de predicción se han empleado tanto modelos matemáticos inicialmente, como redes neuronales entrenadas para representar las ecuaciones (1) y (2). Una profundización sobre el empleo de redes neuronales para la identificación de dinámicas no lineales se presenta en (Jagannathan y Lewis, 1996). También se han realizado pruebas con una red neuronal MIMO para representar ambas ecuaciones.

Por otro lado, en un esfuerzo de acelerar los tiempos de ejecución y gracias a que la función @gamultiobj permite una entrada vectorizada, se ha modificado el script existente para evaluar vectorialmente las acciones de control (cromosomas) de todos los individuos de la población en cada iteración y para cada instante de muestreo. Se muestra en la Figura 3, la evolución de las salidas de ambos sistemas bajo control, estando los sistemas representados por una misma red neuronal empleando




Figura 3: Evolución del control de los sistemas (1)(SNL5) y (2)(SNL1)

un horizonte de control y predicción $H_c = H_p = 4$, 200 individuos de población y un tiempo de muestreo de 0.5 s. Debido al tiempo de muestreo tan reducido, en el equipo donde se ha realizado la simulación, en cada instante de muestreo solo se llega a 30 iteraciones antes de que se corte por límite de tiempo. No obstante, se puede observar que se obtiene un resultado satisfactorio de control.

Se debe añadir en este apartado también, una de las pruebas heurísticas realizadas en la gestión de la inicialización de la población del siguiente instante de muestreo. Para inicializar los cromosomas de los individuos de la siguiente población se emplean los calculados para la población actual desplazados en un instante de muestreo tal y como se aprecia en la Figura 4. Para asignar un valor al último cromosoma de los individuos, simplemente se llama a una función que genera un número aleatorio entre los límites inferior y superior de la señal de control. Pese a que no se han realizado pruebas exhaustivas del efecto de esta inicialización, la técnica demuestra consistentemente reducir el tiempo de cómputo del control predictivo, aún siendo una reducción ligera, cuando se han realizado ejecuciones sin límite de tiempo en cada ciclo de iteración.

2.3. Implementación en CMEX S-Function

Finalmente, tras haber dado los pasos anteriores se expone en este apartado el desarrollo hasta el momento de la implementación en *S-Function* de iMO-NMPC. Partiendo del código de NSGA-II de Kalyanmoy Deb y ulteriores avances partiendo de (Larrea et al., 2015), se han creado archivos adicionales, para encapsular ahí la lógica necesaria para el modelo de predicción y los criterios de selección, a parte del archivo *S-Function* principal, el cual es llamado por la rutina principal de simulación en Simulink mostrada en la Figura 5. La lógica principal de la estrategia se divide en los pasos de la rutina recuadrados en azul. En el paso `mdlStart` se realiza la adjudicación de memoria, definición y asignación de variables; en el paso `mdlOutputs` se actualiza la salida con la acción de control seleccionada; finalmente en `mdlUpdate` se realiza la optimización para encontrar las soluciones del siguiente instante.




Figura 4: Esquema inicialización de individuos de la siguiente población








Figura 5: Interacción del Motor de Simulink con C S-Functions

En la siguiente Figura 6 se muestran las respuestas de los sistemas (2) y (1) para $H_c = 4$, $H_p = 6$, una población de 200,

número de generaciones 200 y con un tiempo de muestreo de 0.1 s. En este caso el tiempo de muestreo no limita el número de iteraciones realizadas, solamente sirve para dar una escala de tiempo a la simulación. Para ambos sistemas, se ha empleado su correspondiente modelo matemático para realizar las predicciones.



(a) Esquema de bloques para iMO-NMPC S-Function en Simulink



(b) Salida del sistema y referencia

Figura 6: Modelo de prueba S-Function de iMO-NMPC

3. Próximos desarrollos y Líneas Futuras

Un desarrollo clave en el futuro es el traslado de la ejecución a una plataforma de tiempo real para una validación y experimentación adicional, similar a lo realizado en (Larrea et al., 2014). Para esta labor Simulink cuenta con aplicaciones como *Simulink Real Time* o *Simulink PLC Coder*.

En un esfuerzo de asegurar la concurrencia del software, facilitar la depuración del código y aseguramiento de la periodicidad del cómputo en cada instante de muestreo, se plantea introducir una ejecución similar a una máquina de estados con algún mecanismo de *timeout* en la optimización del algoritmo genético.

Por otro lado queda por extender la utilidad del programa a sistemas MIMO multi-objetivo. Adicionalmente queda como línea futura, la adición de diferentes lógicas de *Decision Maker*, a parte del criterio de distancia mínima implementado en el momento, que estén basadas en técnicas de *Soft Computing* tales como la lógica difusa. El método de inicialización de la pobla-

ción, mencionada anteriormente, queda por ser implementada también en la versión programada en C.

Finalmente, queda como posible desarrollo futuro el análisis y la experimentación con técnicas de optimización mas recientes, como puede el NSGA-III (Deb y Jain, 2014), una versión mejorada sobre el NSGA-II, o MOEA/D (Zhang y Li, 2007) (Zhou et al., 2012) un algoritmo evolutivo multi-objetivo basado en descomposición y operadores diferenciales.

Agradecimientos

Este trabajo se ha desarrollado en el marco del proyecto PID2020-120087GB-C22 financiado por el Ministerio de Ciencia e Innovación del Gobierno de España.
(AEI / <http://dx.doi.org/10.13039/501100011033>)


Referencias

- Camacho, E., Bordons, C., 2007a. Nonlinear Model Predictive Control: An Introductory Review.
DOI: 10.1007/978-3-540-72699-9_1
- Camacho, E. F., Bordons, C., Apr. 2007b. Model Predictive Control, 2nd Edición. Springer.
- Deb, K., Jain, H., 2014. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part i: Solving problems with box constraints. *IEEE Transactions on Evolutionary Computation* 18 (4), 577–601.
DOI: 10.1109/TEVC.2013.2281535
- Deb, K., Pratap, A., Agarwal, S., Meyarivan, T., 2002. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE Transactions on Evolutionary Computation* 6 (2), 182–197.
DOI: 10.1109/4235.996017
- Eloy Irigoyen, Ekaitz Larzabal, J. J. V. M. L. A. G., 2014. Primeros resultados de un control genético predictivo sobre maqueta de helicóptero (twinrotor). *Jornadas de Automática*.
- Hornik, K., Stinchcombe, M., White, H., 1989. Multilayer feedforward networks are universal approximators. *Neural Networks* 2, 359–366.
- Jagannathan, S., Lewis, F., 1996. Identification of nonlinear dynamical systems using multilayered neural networks. *Automatica* 32 (12), 1707 – 1712.
DOI: 10.1016/S0005-1098(96)80007-0
- Larrea, M., Irigoyen, E., Gómez, V., 2010. Adding nonlinear system dynamics to levenberg-marquardt algorithm for neural network control. En: *ICANN 2010*. Vol. 6354 of *Lecture Notes in Computer Science*. pp. 352–357.
DOI: 10.1007/978-3-642-15825-4_47
- Larrea, M., Larzabal, E., Irigoyen, E., García, J. J. V., Dendaluze, M., 2015. Implementation and testing of a soft computing based model predictive control on an industrial controller. *J. Appl. Log.* 13, 114–125.
- Larrea, M., Larzabal, E., Irigoyen, E., Valera, J., Dendaluze, M., 2014. Implementation and testing of a soft computing based model predictive control on an industrial controller. *Journal of Applied Logic*.
DOI: 10.1016/j.jal.2014.11.005
- Marchante, G., Acosta, A., González, A., Zamarreño, J., Álvarez, V., abr. 2021. Comfort constraints evaluation in predictive controller for energy efficiency. *RIAI Journal* 18 (2), 146–159.
DOI: 10.4995/riai.2020.13937
- Schaaf, M., jul. 2020. Hybrid model predictive control of a gravity separator with intermittent product extraction. *RIAI Journal* 17 (3), 318–328.
DOI: 10.4995/riai.2020.11957
- Valera García, J. J., Gómez Garay, V., Irigoyen Gordo, E., Artaza Fano, F., Larrea Sukia, M., 2012. Intelligent multi-objective nonlinear model predictive control (imo-nmpc): Towards the ‘on-line’ optimization of highly complex control problems. *Expert Systems with Applications* 39 (7), 6527–6540.
DOI: <https://doi.org/10.1016/j.eswa.2011.12.052>
- Vaneshani, S., Jazayeri-rad, H., 2011. Nonlinear control of a chemical plant employing a combination of fuzzy logic and particle swarm optimization techniques.
- Veselov, G., Sklyarov, A., Chávez, J. V., 2019. Non-linear control of a tracked robot. En: *2019 IEEE 17th International Conference on Industrial Informatics (INDIN)*. Vol. 1. pp. 641–646.
DOI: 10.1109/INDIN41052.2019.8972253
- Viana, K., Larrea, M., Irigoyen, E., Diez, M., Zubizarreta, A., 2020. MIMO neural models for a twin-rotor platform: Comparison between mathematical simulations and real experiments. En: *Álvaro Herrero, et al. (Eds.), 15th Int. Conf. SOCO’20, Burgos, Spain, 2020*. Vol. 1268 of *Advances in Intelligent Systems and Computing*. Springer, pp. 407–417.
DOI: 10.1007/978-3-030-57802-2_39
- Zhang, Q., Li, H., 2007. Moea/d: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on Evolutionary Computation* 11 (6), 712–731.
DOI: 10.1109/TEVC.2007.892759
- Zhou, A., Zhang, Q., Zhang, G., 06 2012. A multiobjective evolutionary algorithm based on decomposition and probability model. pp. 1–8.
DOI: 10.1109/CEC.2012.6252954



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Detección de ataques de inyección de datos falsos en turbinas eólicas mediante sistemas neuro-borrosos

Chicaiza, W. D.^a, Dorado, F.^a, Rodríguez, F.^b, Gómez, J.^a, Escaño, J.M.^{a,*}

^aDept. de Ing. de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos, s/n, 41092, Sevilla, España.

^bDepartamento de Matemáticas Aplicadas II, Universidad de Sevilla, Camino de los Descubrimientos, s/n, 41092, Sevilla, España.

To cite this article: Chicaiza, W. D., Dorado, F., Rodríguez, F., Gómez, J., Escaño, J.M. 2022. Detección de ataques de inyección de datos falsos en turbinas eólicas mediante sistemas neuro-borrosos. XVII Simposio CEA de Control Inteligente.

Resumen

Uno de los ataques populares en microrredes y sistemas industriales es el conocido como ataque por inyección de datos falsos. Estos constituyen inserciones maliciosas de datos falsos como mediciones de sensores en un sistema ciberfísico, con el fin de llevar al sistema a tomar una acción incorrecta. Los ataques de inyección de datos falsos no atacan los componentes informáticos o de red de los sistemas ciberfísicos, sino la interfaz entre la parte física y la cibernética. En este trabajo se presenta un sistema de detección de datos falsos en la potencia activa y reactiva simultáneamente, provocados por un ciberataque. El sistema se basa en clasificadores neuro-borrosos combinados con proyecciones de datos de entrada sobre espacios reducidos, mediante análisis de componentes principales.

Palabras clave: Ciberataque en la generación eléctrica, Detección de datos falsos, Sistemas Neuro-borroso, Análisis de componentes principales.

False data injection attack detection on wind turbine using neurofuzzy systems

Abstract

One of the popular attacks on microgrids and industrial systems is known as a false data injection attack. These are malicious insertions of fake data such as sensor measurements into a cyber-physical system, in order to lead the system to take an incorrect action. Fake data injection attacks do not attack the computer or network components of cyber-physical systems, but the interface between the physical and the cyber part. This paper presents a system for detecting false data in active and reactive power simultaneously, caused by a cyber-attack. The system is based on neuro-fuzzy classifiers combined with input data projections on reduced spaces, by means of principal component analysis.

Keywords: Cyber-attack in power generation, Fake data detection, Neurofuzzy Systems, Principal Component Analysis.

1. Introducción

Las políticas de transición energética han hecho de las energías renovables, principalmente termosolar, fotovoltaica y eólica, una nueva fuente esencial del mix energético actual, con capacidades de producción en progresivo aumento. (IEA, 2021). Según el informe de la IEA el 12 % de la energía mundial provino de fuentes renovables en el año 2020, representando el 28 % del total de la producción eléctrica. Estas cifras están previsto que se incrementen progresivamente hasta el 26 % y el

60 % respectivamente para el año 2050. Uno de los principales inconvenientes de estas tecnologías, y lo que hace difícil su avance a gran escala es la propia variabilidad de la generación, debiendo adoptarse estrategias de almacenamiento, transporte y distribución inteligente en el seno de smart grids cada vez más avanzadas. Si bien la comunidad científica está trabajando activamente en esta dirección (Bordons et al., 2020) aún quedan pendientes retos que deben ser resueltos. Precisamente los beneficios que aportan esta integración y digitalización en el

*Autor para correspondencia: jescano@us.es

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

tratamiento de la energía conlleva de forma inherente el riesgo de ciberataques que pueden conducir a la pérdida del control sobre los dispositivos y procesos relacionados con los sistemas eléctricos, causando daño físico e interrupción del servicio. Aunque la protección total de estos ciberataques no es posible, sí que hay que proteger a los sistemas eléctricos de estos. Estas acciones pueden ser realizadas en dos capas distintas del propio sistema. En primer lugar mejorando los protocolos de red y comunicaciones, haciéndolos más seguros e invulnerables. Por otro lado también es posible emplear sistemas inteligentes basados en técnicas de inteligencia artificial capaces de detectar un ataque una vez que haya logrado superar el mencionado primer nivel de protección. Los ataques de inyección de datos falsos (FDI) son inserciones maliciosas de datos falsos como mediciones de sensores en un sistema ciberfísico, con el fin de llevar al sistema a tomar una acción incorrecta. Los ataques de inyección de datos falsos no atacan los componentes informáticos o de red de los sistemas ciberfísicos, sino la interfaz entre la parte física y la cibernética (Wolf and Serpanos, 2020).

Recoge (itUser Tech & Business, 2022) que "la demanda de habilidades de seguridad y experiencia específica en tecnología operativa (OT) ha ido en aumento en las empresas industriales durante los últimos años, debido a la escalada de amenazas y la mayor prevalencia de marcos y regulaciones de seguridad de TI/OT. Sin embargo, la falta de profesionales de seguridad en este ámbito amenaza su ciberprotección. Así lo pone de manifiesto el informe "Kaspersky ICS Security Survey 2022: Las siete claves para mejorar los resultados de la seguridad OT", que muestra que la escasez de equipos de seguridad OT amenaza la protección en el 16 % de las organizaciones industriales europeas".

Comienza a existir en la literatura una gran variedad de métodos propuestos para detectar los ciberataques, de entre los cuales las técnicas de Machine Learning han encontrado gran éxito. (Shahid et al., 2022) Propone una estrategia de detección de ataques de inyección de datos falsos en una red de distribución de corriente alterna empleando técnicas basadas en variables ficticias (dummy values). En (Almasabi et al., 2021) se expone una técnica para detectar ataques de datos falsos en dispositivos de medida de fasores. Los autores de (Qu et al., 2021) sugieren un método de detección basado en genes ciberfísicos, mejorando los problemas de detección en datos complejos con bajo nivel de precisión. Por otro lado, los sistemas de distribución de corriente continua son considerados cada vez más como el próximo salto tecnológico debido a su capacidad de integrar distintos tipos de fuentes de energías renovables y distribuirlos a una gran variedad de cargas y usos. Con esta motivación, (Tan et al., 2022) emplea una aproximación de optimización multi-objetivo para detectar intrusiones en este tipo de redes.

Teniendo en cuenta la mayor penetración e importancia que tienen los sistemas de generación de energía basado en fuentes renovables y la creciente vulnerabilidad de los mismos a los ataques mal intencionados, en este trabajo se propone una estrategia basada en técnicas de redes neuroborrosas capaces de aportar una solución viable e implementable en el mundo industrial a estos ataques. Se realiza el estudio en un aerogenerador empleando medidas de campo obtenidas de una instalación existente. La organización del resto del artículo es la siguiente. En la sección 2 se realiza un tratamiento previo de datos

obtenidos de un sistema de supervisión y adquisición de datos (SCADA) y se preparan los conjuntos con fallos inducidos artificialmente. En la misma sección se hace un análisis de correlación de las variables, la organización de los datos y los análisis de las componentes principales de las variables. En la sección 3 se presenta el diseño de los detectores neuro-borrosos propuestos. En la sección 4 se procede a la evaluación de los detectores, terminando con una sección de conclusiones.

2. Preparacion de los datos de operacion

Para el desarrollo del detector neuro-borroso partimos de los datos históricos recogidos por el SCADA de un aerogenerador de 3MW de una instalación onshore con rotor a barlovento de eje horizontal con tres palas como muestra la Figura 1.




Figura 1: Aerogenerador.

Los datos históricos contienen las medidas realizadas por los sensores de las variables que se muestran en la Tabla 1. Además, el SCADA almacena los datos en una hoja Excel día a día, se hace mención a que el registro de datos (como es el caso del viento) es de 10 minutos como una práctica estándar de la industria eólica IEC 61400.

Tabla 1: Datos historicos de operación del aerogenerador

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

El sistema SCADA del aerogenerador entrega datos históricos en bruto sin ningún tratamiento, por lo cual es necesario filtrar el ruido de la instrumentación, suprimir valores atípicos y elegir cuidadosamente las variables que afectan al proceso a partir de los datos reales de funcionamiento, en este caso a la potencia activa y reactiva generada por la turbina eólica. El archivo histórico contiene una serie de variables y contiene datos de todo un año de calendario, que se exportó a Matlab como tablas de tiempo con los nombres de cada variable. Inicialmente se realizó un proceso de eliminar datos inconsistentes, datos negativos y una interpolación de datos en las muestras faltantes en cada una de las variables.

Además, la energía que entrega el aerogenerador a la carga conectada en él, en algunos días de varios meses, su potencia activa se ve saturada por una excesiva generación, debido a que no cuenta con una unidad de almacenamiento que pueda capturar este exceso de energía y porque no cuenta con una conexión a la red eléctrica donde se podría verter dicha energía. Por lo cual dichos datos se han eliminado mediante un proceso de agrupación con la finalidad de capturar un comportamiento realista de la potencia y por ende de la energía eléctrica generada como se muestra en la Figura 2.




Figura 2: Aerogenerador.

Como resultado se tiene una tabla de tiempo con 16 variables (columnas) que componen un conjunto total de 41426 muestras con un tiempo de muestreo de 10 minutos y se muestra parte de ellos en la Figura 3. Cabe mencionar que se cuenta con

los datos mínimos y máximos de las variables Ws, Rs, Q y P , que en este trabajo se han omitido. Como la velocidad el viento produce el empuje de las palas, hacen rotar el cono que tiene conexión con el eje a la caja de engranajes, variando así la velocidad de rotación del generador conectado en él, que transforma las energías de rotación en energía eléctrica. Pero el elemento final que hace de interfaz entre el generador y la carga que ha de consumir dicha energía es un inversor (Alcalá et al., 2011) que adecua la potencia generada a los estándares eléctricos, mediante los sistemas de control potencia montados sobre DSP, que calcula la estabilidad de la frecuencia de la red, la potencia activa y reactiva de la turbina, es decir asegura que la calidad de la potencia sea la adecuada.

El objetivo de este trabajo es la detección de la inyección de datos falsos desde un enfoque de ciberataque en la tecnología operativa (OT) que conforman la turbina de viento, un ejemplo de ello son los dispositivos del control que conforman el sistema de control, que reciben las mediciones de los sensores-transmisores que aseguran que la estabilidad y calidad de la potencia activa y reactiva. Sin embargo, estas mediciones podrían ser falseadas o modificadas dentro de los sistemas de control y el SCADA lo que provocaría un desequilibrio en la red eléctrica o en su caso en la carga conectada en él. Por lo cual este trabajo se enfoca a la detección de datos falsos en la potencia activa y reactiva por ser las variables de mayor interés en los sistemas de control.

Para simular la inyección de datos falsos, partimos de todos los datos de operación y formamos un conjunto de datos con un offset positivo y negativo tanto de la potencia activa y reactiva, el offset añadido se calcula con un umbral del 25 % de la media de la potencia activa y de la misma forma para la potencia reactiva, por lo que el detector neuro-borroso ha de clasificar los datos en tres clases distintas: operación normal, falso positivo y falso negativo en las variables antes mencionadas, como se muestra en la Tabla 2.

Tabla 2: Fallos añadidos en las variables P, Q

Variable	Unidad	inyección de dato falso
Potencia activa (P)	<i>kW</i>	$\pm 272,8$
Potencia reactiva (Q)	<i>kW</i>	$\pm 28,2$

2.1. Análisis de correlación de las variables

El análisis de correlación se realiza con el fin de ver el grado relación que existe entre cada variable y elegir las variables que influyen en su variación. Para realizar el análisis de correlación se reorganiza el conjunto de datos inicial, omitiendo las variables máximas y mínimas de la velocidad del viento, velocidad del rotor, potencia activa y reactiva.

Partimos de una matriz de datos $\mathbf{X} \in \mathbb{R}^{n \times m}$, donde n representa el número total de muestras que son 41426 y m representa el número de variables que en este caso son 7, cada una de las variables de la matriz $\mathbf{X}$ inicialmente se normalizan con media cero y varianza unitaria; cuyo análisis de correlación da como resultado una matriz de coeficientes de correlación $\mathbf{\Gamma} \in \mathbb{R}^{m \times m}$ como muestra la Figura 4.




Figura 3: Datos históricos del Aerogenerador.




Figura 4: Matriz de coeficientes de correlación de los datos del aerogenerador.

Como se puede observar en la matriz de coeficientes de correlación las variables pueden tomar valores en un rango de $[-1, 1]$, donde -1 representa una correlación negativa, 1 representa una correlación positiva completa y 0 indica que las variables de la matriz $\mathbf{X}$ no están correlacionadas. En este caso se aprecia que las variables lectura del contador y posición de la góndola presentan correlaciones casi nulas en relación con las variables: electricidad generada, velocidad del viento, velocidad el rotor, potencia activa y reactiva, motivo por el cual se excluyen para el diseño del detector neuro-borroso al igual que la electricidad generada ya que está en función de la potencia generada y sería un dato redundante para nuestro fin.

2.2. Organización de los datos

Partiendo del análisis de correlación se ha formado los grupos con las variables que afectan a la potencia activa y reactiva: $[Ws, Rs]$, como se puede apreciar en la matriz de correlación (ver Figura 4) la velocidad de viento y la velocidad de giro del rotor tienen una alta correlación con las variables en las cuales se detectará la inyección de datos falsos.

Además, se realiza una estructuración previa de los datos antes de diseñar los clasificadores neuro-borrosos, es así que se forman tres conjuntos: el primer conjunto conformado por datos de operación normal de la potencia activa, mientras que el segundo y tercer conjunto está formado por los umbrales de inyección positiva y negativa (ver tabla 2), resultado de sumar y restar a cada muestra de la potencia activa su respectivo umbral de fallo.

$$\mathbf{D}_P^N = [Ws, Rs, P]$$

$$\mathbf{D}_P^{Fp} = [Ws, Rs, P^{Fp}]$$

$$\mathbf{D}_P^{Fn} = [Ws, Rs, P^{Fn}]$$

Donde, Nr , Fp y Fn representan operación normal, falso positivo y falso negativo respectivamente, una vez formado los conjuntos se han de normalizar con media cero y varianza unitaria para su posterior uso. Obtenemos de esta forma diferentes matrices de datos $\mathbf{D}_v^c \in \mathbb{R}^{n \times k}$, donde c indica la clase y v la variable de interés.

Las matrices de datos se dividen en subconjuntos: entrenamiento, chequeo y validación como muestra la Figura 5.




Figura 5: Subconjuntos a utilizar en el aprendizaje y validación de cada ANFIS

Tal y como se presenta en (Chicaiza et al., 2021), con los conjuntos de entrenamiento se realiza un análisis de componentes principales (Principal Component Analysis, PCA) para reducir la dimensión del espacio de variables, proyectando los datos originales en las componentes de mayor variabilidad. Adicionalmente se obtiene las componentes principales de todas las clases de cada variable de interés. Dichas proyecciones se emplearán en el aprendizaje y validación de los ANFIS de cada clase que conformaran el clasificador neuro-borroso. El mismo procedimiento se aplicará con los datos de la potencia reactiva para el aprendizaje de su clasificador.

2.3. Análisis de componentes principales

Partiendo del conjunto de datos normalizados $\mathbf{D}_v^c \in \mathbb{R}^{n \times m}$ del cual se obtiene de su matriz de covarianzas $\mathbf{R}_v^c \in \mathbb{R}^{n \times m}$ (1) con rango r ($r \leq \min\{n, m\}$), donde N es el numero total de muestras de la matriz $\mathbf{D}_v^c$:

$$(N - 1)\mathbf{R}_v^c = \mathbf{D}_v^c T \mathbf{D}_v^c \quad (1)$$

Y conjuntamente con la descomposición de valores singulares de la matriz de datos $\mathbf{D}_v^c$ (2) que esta relacionada con la descomposición propia de la matriz de covarianzas $\mathbf{R}_v^c$ como:

$$\mathbf{D}_v^c = \mathbf{U}_v^c \mathbf{S}_v^c \mathbf{V}_v^{cT} \quad (2)$$

donde, $\mathbf{U}_v^c \in \mathbb{R}^{n \times r}$, $\mathbf{V}_v^c \in \mathbb{R}^{m \times r}$ son matrices con columnas ortogonales y $\mathbf{S}_v^c \in \mathbb{R}^{r \times r}$ es una matriz diagonal cuyos elementos son la raíz cuadrada de los valores propios de $\mathbf{D}_v^c \mathbf{D}_v^{cT}$ en forma descendente. Al reemplazar (2) en (1) se obtiene el PCA(3) de la siguiente manera:

$$(N - 1)\mathbf{R}_v^c = \mathbf{V}_v^c \mathbf{\Lambda}_v^c \mathbf{V}_v^{cT} \quad (3)$$

donde, $\mathbf{\Lambda}_v^c \in \mathbb{R}^{r \times r}$ es una matriz diagonal con los valores propios de $(N - 1)\mathbf{R}_v^c$ en forma descendente. Las columnas de $\mathbf{V}_v^c$ son los vectores propios $\mathbf{v}_r$ de los λ_r valores propios y marcan la dirección del nuevo espacio de las componentes principales (CP).

2.4. Proyección de los datos en las componentes principales

Tras realizar el algoritmo PCA, la matriz $\mathbf{V}_v^c$ formada por los vectores propios contienen los coeficientes de las componentes principales de cada variable. Los vectores propios se almacenan en una nueva matriz $\mathbf{C}_v^c \in \mathbb{R}^{r \times r}$ definida como *matriz loading* que se empleara para obtener la proyección de los datos como (4) ;

$$\mathbf{T}_v^c = \mathbf{D}_v^c \times \mathbf{C}_v^c \quad (4)$$

donde, $\mathbf{T}_v^c \in \mathbb{R}^{n \times m}$ contiene varios vectores columna $\mathbf{t}_m$ resultado de la proyección en su respectiva componente principal $\mathbf{p}_m$ y se define como la *matriz score*, los nuevas variables proyectadas no tienen ninguna correlación entre ellas. Generalmente la matriz de datos se proyecta en la componente que contenga la mayor variabilidad ¹.

La calidad de una componente principal (CP) puede ser medida de una manera estándar (Jolliffe and Cadima, 2016) como la proporción de la varianza total explicada expresada como un porcentaje.

$$\pi_j = \frac{\lambda_j}{\sum_{j=1}^p \lambda_j} \times 100 \% \quad (5)$$

Tras realizar las mediciones de calidad de cada CP se ha determinado que las dos primeras representan un variabilidad del 98,63 %, por lo cual la proyección de cada conjunto total de datos $\mathbf{D}_v^c$ se realiza en las dos primeras componentes de cada uno de ellos.

2.4.1. Obtención de prototipos proyectados en las CP

Los dos primeros vectores propios de cada $\mathbf{V}_v^c \rightarrow \{\mathbf{V}_v^{Nr}, \mathbf{V}_v^{Fp}, \mathbf{V}_v^{Fn}\}$ se almacenan en las matrices *load* $\mathbf{C}_v^c \rightarrow \{\mathbf{C}_v^{Nr}, \mathbf{C}_v^{Fp}, \mathbf{C}_v^{Fn}\}$, ya que contienen los coeficientes de cada CP, donde $c \rightarrow \{Nr, Fp, Fn\}$ representa la clase: operación normal, falso positivo, falso negativo y v representa la variable de estudio. En el caso de el PCA de todas las clases del vector $\mathbf{V}_v^{Tot}$ se toma la primer componente que contiene una variabilidad del 95 %y se almacena en la matriz $\mathbf{C}_v^{Tot}$.

Se determina las proyecciones de cada clase por cada una de las componentes, es decir, se va a proyectar cada clase $\mathbf{D}_v^c \rightarrow \{\mathbf{D}_v^{Nr}, \mathbf{D}_v^{Fp}, \mathbf{D}_v^{Fn}\}$ en las dos primeras componentes principales de las distintas clases. Las matrices *score* $\mathbf{T}_v^c \rightarrow \{\mathbf{T}_v^{Nr}, \mathbf{T}_v^{Fp}, \mathbf{T}_v^{Fn}\}$ contienen las distintas proyecciones obtenidas de las variables que componen cada clase que llamaremos prototipos, consiguiendo seis nuevas variables por clase en el subespacio de componentes principales, que se empleará posteriormente en el aprendizaje del clasificador.

$$\begin{aligned} Nr \mathbf{T}_v^c &= \mathbf{D}_v^{Nr} \times \mathbf{C}_v^c \\ Fp \mathbf{T}_v^c &= \mathbf{D}_v^{Fp} \times \mathbf{C}_v^c \\ Fn \mathbf{T}_v^c &= \mathbf{D}_v^{Fn} \times \mathbf{C}_v^c \end{aligned} \quad (6)$$

Además, se obtiene la matriz *score* general de cada clase $^s \mathbf{T}_v^c$, resultado de realizar el producto de cada clase con la matriz $\mathbf{C}_v^{Tot}$.

$$^s \mathbf{T}_v^c = \mathbf{D}_v^c \times \mathbf{C}_v^{Tot} \quad (7)$$

Con las proyecciones obtenidas se conforman los conjuntos de entrenamiento y chequeo para cada ANFIS que conformaran el

¹El primer componente principal, que es una combinación lineal de las variables originales, define la dirección de la mayor variabilidad en el conjunto de datos, por lo cual tiene la mayor suma de varianza en la matriz $\mathbf{\Lambda}$ (Wold et al., 1987).

clasificador neuro-borroso:

$$\mathbf{Trn}^{Nr} = \begin{bmatrix} Nr\mathbf{T}_v^{Nr} & Nr\mathbf{T}_v^{Fp} & Nr\mathbf{T}_v^{Fn} & g\mathbf{T}_v^{Nr} \end{bmatrix}, \quad (8a)$$

$$\mathbf{Trn}^{Fp} = \begin{bmatrix} Fp\mathbf{T}_v^{Nr} & Fp\mathbf{T}_v^{Fp} & Fp\mathbf{T}_v^{Fn} & g\mathbf{T}_v^{Fp} \end{bmatrix}, \quad (8b)$$

$$\mathbf{Trn}^{Fn} = \begin{bmatrix} Fn\mathbf{T}_v^{Nr} & Fn\mathbf{T}_v^{Fp} & Fn\mathbf{T}_v^{Fn} & g\mathbf{T}_v^{Fn} \end{bmatrix}, \quad (8c)$$

Como se puede apreciar la proyección de cada clase sobre las demás clases y la proyección general de la clase conforman el conjunto de entrenamiento. El procedimiento para obtener los conjuntos de chequeo es el mismo y se utilizan las matrices *load* $\mathbf{C}_v^c$, $\mathbf{C}_v^{Tot}$ que se utilizaron en el conjunto de entrenamiento para el cálculo de las proyecciones.

3. Detector neuro-borroso con proyección de PCA

El detector neuro-borroso desarrollado combina un análisis de componentes principales (PCA) con el fin de proyectarlas en el subespacio de la o las variables que presenten mayor variabilidad con una arquitectura de red ANFIS(sistema de inferencia neuro-borroso adaptativo).

El PCA representa observaciones de un espacio n-dimensional de forma óptima en un espacio de dimensión reducida, además trasforma las variables correladas en variables ortogonales no-correladas en el subespacio de las variables que presente mayor variabilidad. Mientras que ANFIS combina las ventajas de la lógica borrosa para representar el conocimiento en una forma interpretable basado en reglas con etiquetas lingüísticas del lenguaje humano con las ventajas de aprendizaje de las redes neuronales adaptativas (RNA) para optimizar los parámetros de los antecedentes y consecuentes de las reglas borrosas. Con ambas técnicas se desarrolla el detector neuro-borroso, que se basa en *clasificadores neuro-borroso* para detectar los fallos en la potencia activa y reactiva.

El detector se basa en dos clasificadores neuro-borrosos con proyecciones PCA para detectar la inyección de datos falsos en la potencia activa y reactiva. Como se puede observar en la Figura 6, el clasificador se basa en un sistema de inferencia neuro-fuzzy adaptativo (ANFIS) para obtener un modelo digital capaz de detectar los datos con fallos utilizando como entradas las medidas entregada por los sensores del aerogenerador.



Figura 6: Detector neuro-borroso.

A partir de los valores medidos, el detector indicará los fallos en las variables, cuando los haya, asignando a las variables binarias F_P , F_Q el valor 1 cuando haya un defecto o 0 cuando no lo haya.

3.1. Clasificador neuro-borroso

El clasificador neuro-borroso se conforma de varios sistemas de inferencia borrosa (FIS) obtenidos después de realizar

un proceso de aprendizaje. En dicho proceso se emplea una arquitectura de red ANFIS (Jang, 1993) que utiliza los conjuntos de entrenamiento y chequeo de cada clase. Cada ANFIS utiliza como entradas los prototipos de cada clase (proyección de cada clase sobre las demás clases) y el prototipo general de la clase como la salida que debe aprender. Por lo tanto, se utilizan tres ANFIS uno por clase $c \rightarrow \{Nr, Fp, Fn\}$ que son entrenados para su posterior validación, de tal forma que se obtiene tres FIS, que entregan la estimación del prototipo general $g\mathbf{T}_v^c$ correspondientes a cada clase.

El entrenamiento de cada ANFIS se realiza aplicando primero un método de agrupación sustractivo (Chiu, 1994) que estima inicialmente el número de clusters y sus centros para determinar el número de reglas y las funciones de membresía (FM). A continuación, los parámetros de cada capa de ANFIS se actualizan mediante un método de aprendizaje híbrido que combina el descenso de gradiente para optimizar los parámetros antecedentes y los mínimos cuadrados para determinar los parámetros lineales consecuentes en cada época. Los parámetros de la arquitectura ANFIS es la misma en todos los casos debido a la correlación que tienen los datos (similitud entre cada clase, debido a que se añade un offset en positivo y negativo). La Tabla 3 presenta el resumen de cada parámetro ANFIS para cada clase de la potencia activa y reactiva.

Tabla 3: Parámetros ANFIS para cada clase de las variables P , Q

Description	ANFIS		
Tipo FM :	Gaussiana		
Método de optimización:	hibrido		
Tipo de salida:	lineal		
Clase	1	2	3
FIS_P	Nr	Fp	Fn
Número de FM:	2	2	2
Número de reglas:	2	2	2
Rango de influencia:	0,8	0,8	0,8
Epocas:	175	175	175
Clase	1	2	3
FIS_Q	Nr	Fp	Fn
Número de FM:	2	2	2
Número de reglas:	2	2	2
Rango de influencia:	0,8	0,8	0,8
Epocas:	175	175	175

El proceso de entrenamiento de cada ANFIS emplea número de épocas relativamente bajas, mostrando un aprendizaje generalizado de los conjuntos de entrenamiento y chequeo. Esto se refleja en los índices de error que se obtienen tras finalizar el proceso de aprendizaje de cada FIS_v^c que se muestran en la tabla 4.

El objetivo es detectar la inyección de datos falsos utilizando los sistemas FIS_v^c que entregan a su salida la estimación de los prototipos generales $g\mathbf{T}_v^c$, por lo cual definimos una función de coste que determina que sistema alcanza al prototipo general real $g\mathbf{T}_v^{*real}$ de un nuevo dato.

$$J_i = \left\| g\mathbf{T}_v^{*real} - g\mathbf{T}_v^{c_i} \right\|_2^2 \quad (9)$$

Se emplea entonces, un *algoritmo de búsqueda exhaustiva*

Tabla 4: Índices RMSE obtenido del proceso de aprendizaje de cada ANFIS

RMSE minimo		FIS obtenidos		
Entrenamiento & Chequeo				
<i>Clase</i>	1	2	3	
<i>FIS_P</i>	<i>Nr</i>	<i>Fp</i>	<i>Fn</i>	
<i>RMS E_{Train}</i>	0.000521981	0.000521977	0.000521981	
<i>RMS E_{Check}</i>	0.000515779	0.000515776	0.000515780	
<i>Clase</i>	1	2	3	
<i>FIS_Q</i>	<i>Nr</i>	<i>Fp</i>	<i>Fn</i>	
<i>RMS E_{Train}</i>	0.000579924	0.000579675	0.000579939	
<i>RMS E_{Check}</i>	0.000576049	0.000575746	0.000576069	

(ESA) que asignará para la clase a la que pertenece el $gT_v^{c,*real}$ del nuevo dato. Este algoritmo evalúa la función de coste con el valor que entrega cada sistema de inferencia borroso FIS_v^c a su salida, es decir los prototipos generales estimados gT_v^c y determina la clase por comparación directa, eligiendo aquel que minimiza la función coste. El FIS_v^c que presente el mínimo J_i define la clase a la que pertenece el nuevo dato.

3.2. Estructura del clasificador neuro-boroso

Con cada uno de los sistemas de inferencia borrosos FIS_v^c obtenidos, que estiman los prototipos generales gT_v^c de cada tipo de fallo inducido de la variable de interés v , se crea la estructura final que tendrá el clasificador neuro-boroso.

Cada FIS_v^c contiene un conjunto de relas j del tipo TS (Takagi and Sugeno, 1983):

IF x_1 is F_{1j} and x_2 is F_{2j} and x_i is F_{ij} ,

THEN : $f_j(x) = g_{0j} + g_{1j}x_1 + \dots + g_{ij}x_i$

cada conjunto borroso F_{ij} de cada entrada nítida x_i : T_v^c contiene varias funciones de pertenencia tipo gaussiana:

$$\mu_{F_{ij}}(x_i) = \frac{1}{1 + \left[\left(\frac{x_i - c_{ij}}{a_{ij}} \right)^2 \right]^{b_{ij}}} \quad (10)$$

donde, $\{a_{ij}, b_{ij}, c_{ij}\}$ son los *parámetros antecedentes* que la definen y los términos $g_{ij} \in \mathcal{R}$ de cada función polinómica de primer orden son los *parámetros consecuentes*. La salida final de cada FIS_v^c es la media ponderada de la salida que entrega cada regla.

La estructura formada del clasificador se muestra en la Figura 7.

C_v^c , C_v^{Tot} de la potencia activa y reactiva

Las matrices *score* para cada clase $\{C_P^c, C_Q^c\}$ obtenidas anteriormente se mantienen como parámetros fijos y sirven para definir los nuevos prototipos $\{T_P^c, T_Q^c\}$ de entrada a cada $\{FIS_P^c, FIS_Q^c\}$ que estiman el prototipo general $\{gT_P^c, gT_Q^c\}$ de cada clase.

Si evaluamos un conjunto de datos de operación normal (no contiene inyección de datos falsos) y se multiplica por la matriz $\{C_P^{Nr}, C_Q^{Nr}\}$ se obtendrá el prototipo proyectado en la clase normal $\{T_P^{Nr}, T_Q^{Nr}\}$, si los mismos datos se multiplican por la matriz $\{C_P^{Fn}, C_Q^{Fn}\}$ obtendremos la proyección en la clase falso

positivo $\{T_P^{Fp}, T_Q^{Fp}\}$ y cuando se multipliquen por $\{C_P^{Fn}, C_Q^{Fn}\}$, se proyectan en la clase falso negativo $\{T_P^{Fn}, T_Q^{Fn}\}$. El dato que ingresa pasa por la matriz $\{C_P^c, C_Q^c\}$ es proyectado en la clase $c \rightarrow \{Nr, Fp, Fn\}$, obteniendo de esta manera su prototipo correspondiente T_P^c , donde P, Q denotan la potencia activa y reactiva. Los prototipos calculados $\{T_P^c, T_Q^c\}$ forman el vector de entrada con el que se evalúa cada uno de los $\{FIS_P^c, FIS_Q^c\}$. Finalmente, al pasar los datos por la matriz $\{C_P^{Tot}, C_Q^{Tot}\}$, se obtiene el prototipo general real $\{gT_P^{*real}, gT_Q^{*real}\}$ con el cual se ha de evaluar la función coste en el **ESA** para determinar la clase a la que pertenece el nuevo dato entrante. **ESA** realiza una comparación directa evaluando la función de coste con el valor estimado de cada $\{FIS_P^c, FIS_Q^c\}$ y asigna la etiqueta del FIS que minimiza dicha función. Por ejemplo, cuando los datos evaluados contiene inyección de datos negativos, el sistema $\{FIS_P^{Fn}, FIS_Q^{Fn}\}$ minimiza la función de coste y esa clase es la que le asigna.

4. Evaluación del clasificador neuro-boroso

Evaluamos cada FIS_P^c con datos de cada clase. Si el dato que ingresa no contiene inyección de datos falsos, la salida del FIS_P^c que más se acerca al prototipo real es la del FIS_P^{Nr} como se observa en la Figura 8(a). La Figura 8(b) muestra que, si el dato que ingresa tiene inyección de datos falsos positivos, los valores estimados por el FIS_P^{Fp} seguirán al prototipo general real. Si clasificamos un dato con inyección de datos falsos negativos, la salida del FIS_P^{Fn} sigue al prototipo general como se puede observar la Figura 8(c).

El algoritmo propuesto para asignar la clase a la que pertenece un nuevo dato evaluado presenta buenos resultados como se puede observar la Figura 4. **ESA** realiza una comparación directa evaluando la función de coste con el valor estimado de cada FIS_P^c y asigna la etiqueta del FIS que minimiza dicha función. Por ejemplo, cuando los datos evaluados tienen falsos positivos, el FIS_P^{Fp} minimizará la función de coste, y esa clase se asigna a los datos, como se muestra en la Figura 9(b). Si el dato evaluado son de operación normal, el FIS_P^{Nr} minimizará la función de coste y se asigna esa clase al dato, ver la Figura 9(a). Finalmente, la Figura 9(c) muestra que si el dato presenta falsos negativos el FIS_P^{Fn} minimizará la función de coste y el algoritmo asignará esa clase al nuevo dato entrante.

Adicionalmente se ha realizado la matriz de confusión (ver Tabla 5) para evaluar el clasificador propuesto, esta matriz




Figura 7: Detector neuro-borroso

muestra la distribución de las clases asignadas a los datos predichos, en comparación con sus clases verdaderas.

Tabla 5: Matriz de confusión **Potencia activa**.
Clases estimadas

Actual		F_n	Nr	F_p
	F_{neg}	8204	81	0
	Norm	279	7925	81
	F_{pos}	13	266	8006


Presicion	99.02 %	95.65 %	96.63 %
Recall	96.56 %	95.81 %	99.00 %
Accuracy	97.10 %		

De manera similar ocurrirá con el clasificador que detecta si hay inyección de datos en la potencia reactiva, por ellos los resultados muestran los prototipos generales estimados gT_Q^c por cada FIS_Q^c y el prototipo general real gT_Q^{*real} con datos de operación normal, falsos positivos y falsos negativos en las Figura 4. Mientras que la Figura 4 muestra la clase $c \rightarrow \{Nr, Fp, Fn\}$ obtenida tras aplicar el algoritmo ESA al dato nuevo evaluado. Además, se puede observar su respectiva matriz de confusión en la Tabla 6.


Tabla 6: Matriz de confusión **Potencia reactiva**.
Clases estimadas

Actual		F_n	Nr	F_p
	F_{neg}	7920	345	20
	Norm	1174	6779	332
	F_{pos}	137	1150	6998

Presicion	95.59 %	81.82 %	84.47 %
Recall	85.80 %	81.93 %	95.21 %
Accuracy	87.29 %		




(a) Salidas de los FIS_p^c




(b) Zoom en las salidas de los FIS_p^c

(a) Prototipo real y estimado por cada FIS tras ser evaluado con datos de operación normal




(a) Salidas de los FIS_p^c




(b) Zoom en las salidas de los FIS_p^c

(b) Prototipo real y estimado por cada FIS tras ser evaluado con datos que contienen falsos positivos




(a) Salidas de los FIS_p^c




(b) Zoom en las salidas de los FIS_p^c

(c) Prototipo real y estimado por cada FIS tras ser evaluado con datos que contienen falsos negativos


Figura 8: Prototipos obtenidos con inyección de datos falsos y operación normal en la potencia activa.




(a) Clase obtenida por comparación directa del ESA con datos de operación normal.




(b) Clase obtenida por comparación directa del ESA con datos que contienen falsos positivos.




(c) Clase obtenida por comparación directa del ESA con datos que contienen falsos negativos.



(a) Prototipo real y estimado por cada FIS tras ser evaluado con datos de operación normal




(b) Prototipo real y estimado por cada FIS tras ser evaluado con datos que contienen falsos positivos




(c) Prototipo real y estimado por cada FIS tras ser evaluado con datos que contienen falsos negativos

Figura 9: Errores entregados por el ESA tras minimizar la función de coste para la potencia activa.

Figura 10: Prototipos obtenidos con inyección de datos falsos y operación normal en la potencia reactiva.




(a) ESA con datos de operación normal.




(b) Clasificación con datos de operación normal

(a) Clase obtenida por comparación directa del ESA con datos de operación normal.




(a) ESA con datos que contienen falsos positivos.




(b) Clasificación con datos que contienen falsos positivos.

(b) Clase obtenida por comparación directa del ESA con datos que contienen falsos positivos.



(a) ESA con datos que contienen falsos negativos.



(b) Clasificación con datos que contienen falsos negativos.

(c) Clase obtenida por comparación directa del ESA con datos que contienen falsos negativos.

Figura 11: Errores entregados por el ESA tras minimizar la función de coste para la potencia reactiva.

5. Conclusiones

Se ha diseñado un detector basado en clasificadores neuro-borrosos que determina la existencia de inyección de datos falsos en la potencia activa y reactiva simultáneamente de un aerogenerador de 3 MW. El clasificador neuro-borroso lo conforma una estructura de diversos sistemas de inferencia borrosos del tipo Takagi-Sugeno, donde los nuevos datos de entrada se proyectan sobre las componentes principales y se utilizan como

entradas de cada FIS que estiman el prototipo general que lo define para su posterior clasificación. Se han efectuado pruebas en simulación, cambiando artificialmente los datos de las potencias. Los resultados de la clasificación presenta índices muy adecuados de precisión y sensibilidad.

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 en virtud del acuerdo de subvención nº 958339.

The authors thanks 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.

Referencias

- Alcalá, J., Cárdenas, V., Ramírez-López, A. R., Gudiño-Lau, J., 2011. Study of the bidirectional power flow in back - to - back converters by using linear and nonlinear control strategies. In: 2011 IEEE Energy Conversion Congress and Exposition. pp. 806–813.
DOI: 10.1109/ECCE.2011.6063853
- Almasabi, S., Alsuwian, T., Javed, E., Irfan, M., Jalalah, M., Aljafari, B., Harraz, F. A., 2021. A novel technique to detect false data injection attacks on phasor measurement units. *Sensors* 21 (17).
URL: <https://www.mdpi.com/1424-8220/21/17/5791>
DOI: 10.3390/s21175791
- Bordons, C., Garcia-Torres, F., Ridao, M., 2020. *Model Predictive Control of Microgrids*. Advances in Industrial Control. Springer Verlag.
- Chicaiza, W., Rodríguez, F., Sánchez, A. J., Escaño, J. M., 2021. Detección de fallos en datos para la decisión de acción de aprendizaje de gemelos digitales de sistemas de energía. In: XVI Simposio CEA de Control Inteligente: Libro de Actas. Universidad de Las Palmas de Gran Canaria, Las Palmas de Gran Canaria, Spain, pp. 55–60.
- Chiu, S. L., may 1994. Fuzzy model identification based on cluster estimation. *J. Intell. Fuzzy Syst.* 2 (3), 267–278.
- IEA, 2021. *World Energy Outlook 2021*.
- itUser Tech & Business, 2022. El 16 % de la industria europea, en riesgo por la escasez de equipos de seguridad ot.
- 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
- Qu, Z., Dong, Y., Qu, N., Li, H., Cui, M., Bo, X., Wu, Y., Mugemanyi, S., 2021. False data injection attack detection in power systems based on cyber-physical attack genes. *Frontiers in Energy Research* 9.
DOI: 10.3389/fenrg.2021.644489
- Shahid, M. A., Ahmad, F., Albogamy, F. R., Hafeez, G., Ullah, Z., 2022. Detection and prevention of false data injection attacks in the measurement infrastructure of smart grids. *Sustainability* 14 (11).
URL: <https://www.mdpi.com/2071-1050/14/11/6407>
DOI: 10.3390/su14116407
- Takagi, T., Sugeno, M., 1983. Derivation of fuzzy control rules from human operator's control actions. *IFAC Proceedings Volumes* 16 (13), 55–60, IFAC Symposium on Fuzzy Information, Knowledge Representation and Decision Analysis, Marseille, France, 19–21 July, 1983.
DOI: [https://doi.org/10.1016/S1474-6670\(17\)62005-6](https://doi.org/10.1016/S1474-6670(17)62005-6)
- Tan, S., Xie, P., Guerrero, J. M., Vasquez, J. C., 2022. False data injection cyber-attacks detection for multiple dc microgrid clusters. *Applied Energy* 310, 118425.
DOI: <https://doi.org/10.1016/j.apenergy.2021.118425>


Wold, S., Esbensen, K., Geladi, P., 1987. Principal component analysis. *Chemometrics and Intelligent Laboratory Systems* 2 (1), 37–52, proceedings of the Multivariate Statistical Workshop for Geologists and Geochemists.
DOI: [https://doi.org/10.1016/0169-7439\(87\)80084-9](https://doi.org/10.1016/0169-7439(87)80084-9)

Wolf, M., Serpanos, D., 2020. False Data Injection Attacks. Springer International Publishing, Cham, pp. 73–83.
URL: <https://doi.org/10.1007/978-3-030-25808-5-6>
DOI: 10.1007/978-3-030-25808-5-6



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Mejoras para el ajuste de controladores robustos mediante optimización multiobjetivo en procesos con incertidumbre

Blasco, X.^{a,*}, Pajares, A.^a, Herrero, J.M.^a, Veyna, U.^a

^a*Instituto de Automática e Informática Industrial, Universitat Politècnica de València, Camino de Vera S/N, 46022, Valencia, España.*

To cite this article: Blasco, X., Pajares, A., Herrero, J.M., Veyna, U. 2022. Improvements for robust controller tuning by multi-objective optimization in processes with uncertainty. XVII Simposio CEA de Control Inteligente.

Resumen

Breve descripción de algunas de las ideas sobre las que está trabajando el grupo de investigación CPOH del Instituto de Automática e Informática Industrial (ai2) de la Universitat Politècnica de València (UPV). En particular, mostramos las ideas básicas correspondientes a una de las líneas de trabajo para el ajuste mediante optimización multiobjetivo de controladores robustos para todo tipo de proceso que presenten incertidumbre paramétrica en su modelo. El objetivo fundamental que se se persigue es conseguir una metodología y algoritmos que permitan el ajuste robusto de controladores con un coste computacional viable. Las ideas que se describen usan soluciones casi-óptimas para mejorar la exploración de soluciones robustas sin sacrificar el coste computacional.

Palabras clave: Optimización Multiobjetivo, Control robusto, Incertidumbre paramétrica.

Improvements for robust controller tuning by multi-objective optimization in processes with uncertainty

Abstract

Brief description of some of the ideas on which the CPOH research group of the Instituto de Automática e Informática Industrial (ai2) of the Universitat Politècnica de València (UPV) is working. In particular, we show the basic ideas corresponding to one of the research lines for the tuning using multiobjective optimization of robust controllers for all types of processes that present parametric uncertainty in their model. The main objective is to achieve a methodology and algorithms that allow the robust tuning of controllers with a viable computational cost. The ideas described use nearly optimal solutions to improve the exploration of robust solutions without sacrificing computational cost.

Keywords: Multiobjective Optimization, Robust Control, Parametric uncertainty.

1. Introducción

Este trabajo trata de mostrar brevemente algunas de las ideas sobre las que estamos trabajando en el grupo de investigación CPOH del Instituto de Automática e Informática Industrial (ai2) de la Universitat Politècnica de València (UPV). En particular se van a mostrar las ideas básicas del trabajo para el ajuste mediante optimización multiobjetivo de controladores robustos para todo tipo de proceso que presenten incertidumbre paramétrica en su modelo.

Durante el proceso de diseño de un sistema de control, el diseñador debe escoger una estructura para el controlador y ajustar sus parámetros. El ajuste de los parámetros del controlador, al igual que ocurre en muchos otros diseños de ingeniería, pue-

de ser formulado como un problema de optimización. En este caso, se eligen los objetivos a optimizar que medirán el rendimiento del controlador y suele ser común que muchos de estos objetivos esten en conflicto, por tanto, resulta un problema de optimización multi-objetivo (MOP) (Miettinen, 2012; Reynoso-Meza et al., 2017).

Además, no es difícil encontrar que los modelos del proceso a controlar, que se usan en el diseño y ajuste del controlador, tengan cierto grado de incertidumbre. Evidentemente dicha incertidumbre impactará en las prestaciones reales del control diseñado. Cuando se implemente en el proceso real podría, además de dejar de ser óptimo, ser totalmente inadecuado. Por lo tanto, para obtener un buen controlador es deseable que,

*Autor para correspondencia: xblasco@isa.upv.es

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

además de conseguir un buen rendimiento sobre el modelo nominal, sea un control robusto (insensible a las incertidumbres de dicho modelo).

Por ello, es muy conveniente para el diseñador analizar las incertidumbres e incorporarlas en el procedimiento de ajuste del controlador. Un enfoque muy potente, cuando se considera incertidumbre paramétrica, pasa por usar la programación estocástica. En este caso los parámetros del modelo son considerados como variables aleatorias, donde cada combinación de parámetros (posible modelo) es considerado como un escenario. Este enfoque es especialmente interesante cuando es usado con modelos no lineales. De este modo, es posible elegir un controlador con un rendimiento adecuado que sea robusto ante incertidumbre, es decir, en todos los escenarios. Dar con estos controladores robustos supone incorporar, en el proceso de optimización, los diferentes escenarios a considerar (incluido el nominal). Parece claro que esto conlleva un alto coste computacional que crece linealmente con el número de escenarios considerados haciendo, en la mayoría de los problemas, inabordable computacionalmente el problema de optimización.

En este trabajo se presentan brevemente las ideas que nos llevan a una propuesta novedosa, computacionalmente más económica, que permite obtener una buena aproximación a controladores robustos. El aspecto clave para mantener un coste computacional limitado en este tipo de problemas, es conseguir que el número de modelos/escenarios que se manipulan en el proceso de optimización sea limitado. Pero además, para aprovechar al máximo el esfuerzo computacional, es necesario que estos controladores sean relevantes, es decir, deben mantener un cierto grado de calidad en las prestaciones.

2. Optimización Multiobjetivo de controladores robustos

La hipótesis de partida para conseguir un regulador robusto, es que este debería obtener un funcionamiento adecuado para todos los escenarios posibles, esto es, para todas las variaciones del modelo respecto del nominal. Tradicionalmente, una forma de verificar la robustez es conseguir un controlador con un comportamiento adecuado para el modelo que presente la mayor degradación, lo que se suele denominar peor caso. En un problema multiobjetivo, la mayor degradación se puede dar en distintos objetivos para diferentes modelos, por tanto, la peor degradación para todos los objetivos se da en general para un conjunto de modelos (peores casos).

Si pérdida de generalidad, para simplificar la descripción de las ideas básicas suponemos que tenemos un problema de ajuste bidimensional, tanto en objetivos como en parámetros a ajustar. El vector de objetivos $f(x, \xi) = [f_1(x, \xi), f_2(x, \xi)]$ está formado por f_1 un indicador de las prestaciones y, f_2 un indicador del esfuerzo de control. El vector de decisión es $x = [x_1, x_2]$, son los parámetros a ajustar en el controlador. Por ejemplo, en un controlador PI, serían la ganancia proporcional y tiempo integral del controlador. Consideramos que un escenario viene definido por una combinación de valores de los parámetros del modelo $\xi = [\xi_1, \dots, \xi_m]$. El problema de optimización para un escenario (modelo) concreto se definiría:

$$\min_{x \in Q} f(x, \xi) \quad (1)$$

Donde Q contempla todas las restricciones aplicables al problema, por ejemplo, los límites de los parámetros del controlador, estabilidad, etc.

Si disponemos de una descripción de la incertidumbre que afecta al proceso mediante un conjunto de posibles modelos $\mathcal{U} = \{\xi^1, \dots, \xi^k\}$, para contemplar la robustez en la optimización, se debe reformular el problema de optimización. Existen distintas estrategias para evaluar la robustez, pero una de las más comunes es la de considerar el comportamiento ante el peor caso para cada objetivo de forma independiente:

$$\min_{x \in Q} f_{\mathcal{U}}^{\max}(x) \quad (2)$$

Donde:

$$f_{\mathcal{U}}^{\max}(x) = [\sup_{\xi \in \mathcal{U}} f_1(x, \xi), \sup_{\xi \in \mathcal{U}} f_2(x, \xi)] \quad (3)$$

Este problema tiene un coste computacional notablemente superior al problema (1), puesto que requiere evaluar f para todos los modelos $\xi \in \mathcal{U}$ y en cada controlador que aparece en el proceso de optimización.

Una alternativa para reducir este enorme coste computacional, consiste en plantear un MOP sobre el escenario nominal y evaluar la robustez de todos los controladores obtenidos en el conjunto de Pareto. Este procedimiento no aporta ninguna garantía de que estos controladores sean los más adecuados desde el punto de vista de la robustez. Lo que se consigue es elegir entre los óptimos de Pareto aquellos que son más robustos, pero es posible que otros controladores que no forman parte del conjunto óptimo presenten características de robustez interesantes para el diseñador. Para incrementar la diversidad de soluciones disponibles en este análisis de robustez (sin sacrificar en exceso el coste computacional) proponemos caracterizar tanto los controladores óptimos como los casi-óptimos no dominados en su vecindad (Pajares et al., 2019, 2018). El concepto de vecindad hace referencia a una zona determinada (por el diseñador) en el espacio de parámetro. Vecindades diferentes corresponden a controladores sensiblemente diferentes en el espacio de parámetros. Suponemos que controladores que presentan valores sensiblemente diferentes en el espacio de parámetros pueden tener comportamientos diferentes en lo que respecta a la robustez.

Para no incrementar en exceso el coste computacional, la obtención de soluciones casi-óptimas debe ser limitada a un entorno concreto. Por ello, es necesario que el diseñador establezca la zona de prestaciones que considera adecuada. La búsqueda de soluciones casi-óptimas se limita a esta zona. Una vez caracterizadas estas soluciones, la robustez se evalúa posteriormente en la fase de toma de decisión. El análisis de estos controladores para todos los modelos que conforman la descripción de la incertidumbre determina qué controladores son más robustos. La clave en la reducción del coste computacional consiste en conseguir caracterizar óptimos y casi-óptimos sin incrementar el coste computacional. En trabajos previos ya se ha desarrollado un algoritmo, nevMOGA¹. (Pajares Ferrando, 2019),

¹Disponible en Matlabcentral <https://es.mathworks.com/matlabcentral/fileexchange/71448-nevmoga-multiobjective-evolutionary-algorithm>.




Figura 1: Conceptos básicos en la optimización multiobjetivo para un problema particular 2D. El espacios de objetivos (f_1 Prestaciones, f_2 Esfuerzo de control], figura izquierda) y el espacio de los parámetros a optimizar ($[x_1, x_2]$, figura derecha). Se muestran soluciones óptimas y casi-óptimas, degradación debida a incertidumbres y vecindarios.

que permite caracterizar adecuadamente conjuntos de controladores óptimos y casi-óptimos simultáneamente con un coste computacional similar al que se requiere para la obtención de las soluciones óptimas de Pareto. Por tanto, se trata de explotar esta herramienta para el problema del ajuste de controladores robustos.

En la figura 1 se muestra las posibilidades que aparecen en el análisis de robustez al disponer de soluciones casi-óptimas. Se muestra que la optimización multiobjetivo convencional ofrece las soluciones del frente de Pareto (en azul), estas se encuentra en una zona determinada del espacio de parámetros (vecindario1). Se muestra también la degradación que sufren estos controladores cuando se evalúan con todos los modelos de $\mathcal{U}$ (elipse coloreada en azul). Si se consigue caracterizar soluciones casi-óptimas relevantes, es decir, en un vecindario diferente (en la figura se colorea en verde), podemos encontrar controladores que, aplicados a todos los modelos de conjunto $\mathcal{U}$, consiguen una degradación de los objetivos sensiblemente menor que la que sufren las soluciones óptimas de Pareto (elipses verdes comparadas con las azules). La zona sombreada en gris mostraría la zona de prestaciones y esfuerzo de control adecuada para el diseñador, esta zona debe ser definida por el diseñador.

Por tanto, si se consiguen soluciones óptimas y casi-óptimas relevantes (en vecindarios diferentes) que mantienen las prestaciones en una zona adecuada (zona gris), el diseñador dispone de más soluciones alternativas y es posible que el diseño robusto pase por elegir una solución casi-óptima en lugar de una óptima.

3. Conclusiones

Dentro de los trabajos que estamos llevando a cabo para mejorar la robustez de los controladores ajustados mediante optimización multiobjetivo, estamos explotando el potencial que aporta el uso de soluciones casi-óptimas relevantes. En trabajos previos se ha desarrollado un algoritmo (nevMOGA) que

permite la obtención de soluciones óptimas y subóptimas simultáneamente sin incrementar casi el coste computacional. Una de las aplicaciones de este algoritmo es la que se presenta en este breve resumen. Se muestra el potencial para realizar el ajuste de controladores robustos. Los trabajos en esta línea ya están en una fase avanzada, los resultados obtenidos confirman los beneficios en términos de coste computacional que se obtienen. Se ha aplicado al ajuste de una estructura de control para un proceso multivariable, no-lineal con incertidumbres obteniendo buenos resultados. Se ha enviado un artículo para su posible publicación en revista de alto impacto.

Agradecimientos

Estos trabajos han sido realizado parcialmente gracias al apoyo de: el proyecto RTI2018-096904-B-I00 financiado MCIN/AEI/10.13039/501100011033/ y por "FEDER Una manera de hacer Europa"; la ayuda PRE2019-087579 financiada por MCIN/AEI/10.13039/501100011033 and by "FSE invierte en tu futuro"; y la ayuda SP20200109 (PAID-10-20) de la Universitat Politècnica de València.


Referencias

- Miettinen, K., 2012. Nonlinear multiobjective optimization. Vol. 12. Springer Science & Business Media.
- Pajares, A., Blasco, X., Herrero, J. M., Reynoso-Meza, G., 2018. A multiobjective genetic algorithm for the localization of optimal and nearly optimal solutions which are potentially useful: nevmoGA. Complexity 2018. DOI: 10.1155/2018/1792420
- Pajares, A., Blasco, X., Herrero, J. M., Reynoso-Meza, G., 2019. A new point of view in multivariable controller tuning under multiobjective optimization by considering nearly optimal solutions. IEEE Access 7, 66435–66452. DOI: 10.1109/ACCESS.2019.2915556
- Pajares Ferrando, A., 2019. Development of a multi-objective optimization methodology considering nearly optimal solutions. application to problems in control engineering. Ph.D. thesis, Universitat Politècnica de València. URL: <http://hdl.handle.net/10251/133974>
- Reynoso-Meza, G., Blasco, X., Sanchis, J., Herrero, J. M., 2017. Controller tuning with evolutionary multiobjective optimization: A holistic multiobjective optimization design procedure. Springer.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Sensor virtual de caudal basado en técnicas de deep learning

Rodríguez-Ossorio, J.R.^{a,*}, González-Herbón, R.^a, González-Mateos, G.^a, Morán, A.^a, Prada, M. A.^a, Díaz, I.^b, Domínguez, M.^a

^aGrupo de investigación en Supervisión, Control y Automatización de Procesos Industriales (SUPPRESS), Esc. de Ing. Industrial e Informática, Universidad de León, Campus de Vegazana s/n, 24007, León, Spain.

^bDepartamento de Ingeniería Eléctrica, Electrónica, de Comunicaciones y de Sistemas, Universidad de Oviedo, Edif. Departmental 2, Campus de Viesques s/n, Gijón 33204 Spain.

To cite this article: Rodríguez-Ossorio, J.R., González-Herbón, R., González-Mateos, G., Morán, A., Prada, M. A., Díaz, I., Domínguez, M. 2022. Flow virtual sensor based on deep learning techniques. XVII Simposio CEA de Control Inteligente.

Resumen

En el contexto de la digitalización de la industria, los sensores virtuales resultan muy útiles tanto para construir gemelos digitales, que permiten simular comportamientos que ayudan a optimizar el proceso productivo y prevenir errores, como para ser utilizados en las situaciones en las que un sensor real es muy costoso o directamente no puede ser instalado. En este artículo se propone un método para implementar sensores virtuales utilizando tres de las técnicas de deep learning más comunes: redes convolucionales, redes neuronales densas y redes recurrentes. El método se ha utilizado para construir un sensor virtual de caudal en una maqueta de control de procesos que dispone de instrumentación industrial real.

Palabras clave: Sensor virtual, Deep learning, LSTM, Digitalización, Industria 4.0.

Flow virtual sensor based on deep learning techniques

Abstract

In the context of industry digitalization, virtual sensors are very useful both to develop digital twins, which simulate behaviors that help us to optimize the process and prevent faults, such as to be used on the cases where a real sensor is very expensive or cannot be installed. In this paper, it is proposed a method to develop virtual sensors using three of the most common deep learning techniques: convolutional networks, dense neural networks and recurrent neural networks. The method has been used to develop a flow virtual sensor for a pilot plant that has real industrial instrumentation.

Keywords: Virtual sensor, Deep learning, LSTM, Digitalization, Industry 4.0

1. Introducción

En los últimos años ha surgido un nuevo modelo de producción industrial basado en la digitalización de la industria. Esta digitalización combina los últimos avances en el campo de la automatización industrial (OT) con las tecnologías de la información (IT) (Xu et al., 2018). La integración de ambos campos supone un reto tecnológico que se extiende a todos los niveles de la planta, rompiendo con las estructuras tradicionales, y logra la vinculación del mundo físico al virtual.

El empleo de simulaciones de entornos industriales se ha convertido en un aspecto clave. Los denominados gemelos digitales permiten operar con un sistema virtual de la misma manera que si se hiciera con el sistema real, alcanzando la convergencia entre procesos virtuales y físicos con sus correspondientes datos vinculados (Tao et al., 2018). Las versiones virtuales de los sistemas industriales reales permiten modificar parámetros que, más adelante, ayudan a predecir el comportamiento del sistema, optimizar el proceso productivo y prevenir errores (Babiceanu and Seker, 2016).

*Autor para correspondencia: jrodre@unileon.es

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

Para que el comportamiento del gemelo digital se asemeje al del sistema real es imprescindible que los modelos de las partes que lo componen sean lo más precisos posibles. En el caso de los sensores, los modelos virtuales permiten predecir u obtener el valor de una determinada variable del sistema a partir de la medición de los datos de otras variables relacionadas. Además, estos sensores virtuales son de suma utilidad en situaciones donde un sensor real es muy costoso o directamente no puede ser instalado (Alonso et al., 2019). Estos modelos se pueden desarrollar, tanto de una forma básica, teniendo en cuenta estados ideales del sistema objetivo, como más avanzada, empleando datos más completos que abarcan diferentes situaciones que pueden ocurrir en el proceso real (Kadlec et al., 2009).

A partir de los datos obtenidos del sistema real es posible recurrir a diferentes métodos para predecir la variable deseada, desde modelos matemáticos simples hasta técnicas más sofisticadas, como las basadas en *deep learning*, que pueden aportar una mayor precisión que otras aproximaciones. Esta última opción es la empleada en el caso de estudio del presente documento, tomando como punto de partida una planta piloto industrial con instrumentación real, que representa un proceso industrial genérico con un fluido circulando entre dos tanques situados a distintas alturas. Para este proceso se ha implementado un sensor virtual de caudal utilizando diferentes técnicas de *deep learning*.

El presente documento se estructura de la siguiente forma: en el apartado 2 se hace una introducción sobre el uso de sensores virtuales en la industria y se analizan algunos métodos para su implementación. A continuación, en el apartado 3, se describe el método propuesto en este artículo para desarrollar un sensor virtual de caudal. En el apartado 4 se describen los experimentos realizados y los resultados alcanzados. Finalmente, el documento termina con el apartado 5 en el que se explican las conclusiones y posibles líneas futuras de trabajo.

2. Estado del arte

Los sensores virtuales son, en esencia, aplicaciones software basadas en modelos matemáticos que permiten predecir u obtener el valor de determinadas variables del sistema a partir de la medición de otras variables relacionadas (Li et al., 2011). Por este motivo, los sensores virtuales son sumamente útiles en situaciones en las que un sensor físico real que puede medir la variable deseada es costoso, impreciso o se encuentra temporalmente fuera de servicio. Además, este tipo de sensores resultan más económicos que otras implementaciones, no son invasivos ni alteran el proceso a estudiar, y no requieren realizar modificación alguna en el sistema (McDonald and Zmeureanu, 2015).

Junto con las características descritas, los sensores virtuales son muy flexibles y pueden ser reconfigurados con relativa facilidad, mientras que los sensores físicos solo pueden cambiarse con una intervención en el sistema que conllevará una consecuente interrupción del proceso (Martin et al., 2021). Además, los sensores virtuales pueden servir

también para corregir ciertas imperfecciones de los sensores reales, como el ruido de las señales o la confianza en que los valores obtenidos sean precisos, teniendo en cuenta que los sensores virtuales basan su medida en las de varios instrumentos distintos. Asimismo, es también conocido que los sensores físicos se pueden hacer más inexactos e imprecisos con el paso del tiempo, debido a su desgaste o a la acumulación de suciedad, defecto que puede ser compensado o amortiguado con el uso de sensores virtuales (Tegen et al., 2019).




Figura 1: Metodología aplicada.

Existen diferentes metodologías para el desarrollo de sensores virtuales, y de su implementación dependerá el modo en el que estos modelos se comporten con respecto a la variable real medida. Una forma de implementación se trata del análisis estadístico multivariable donde existe alguna característica estadística constante (Abeykoon, 2018). Otra manera de implementación es con los observadores basados en datos e identificación que se basan en la existencia de los estados de sistema. También existen los modelos de primer principio cuya condición de partida es la de modelar el sistema a través de los principios matemáticos y físicos que lo definen (Mattera et al., 2018). Otro método es el filtrado, como es el ejemplo de los filtros de Kalman (Yang et al., 2019), que estiman las variables de estado que definen la dinámica del sistema. Por último,

también están las técnicas de *machine learning*, especialmente las técnicas de *deep learning*, que emplean diferentes estructuras como las redes neuronales densas, las redes LSTM o redes convolucionales, entre otras (Jiang et al., 2021; Márquez-Vera et al., 2021).

Los sensores virtuales están presentes en diferentes ámbitos de la automatización. Más concretamente, en el ámbito de la automatización industrial existen numerosas implementaciones de sensores virtuales, empleados para medir variables como el flujo volumétrico de fluidos no newtonianos (Chhantyal et al., 2018), el pH de un fluido (Thürlimann et al., 2018) o la concentración de ácidos grasos volátiles (Nair et al., 2019). Otro ámbito es el de la automatización de edificios donde uno de los usos es para la mejora en términos de monitorización, diagnóstico y optimización (Li et al., 2011).

3. Descripción del método

Como ya se ha mencionado anteriormente, para el caso de estudio del presente documento se ha optado por emplear aproximaciones de *deep learning* a la hora de desarrollar el sensor de caudal propuesto. En la Figura 1 puede verse una representación esquemática del método empleado.

El proceso comienza con la preparación de los datos de partida, obtenidos de los sensores y actuadores de planta piloto industrial que se explica con detalle en el apartado 4, junto con un caudalímetro portátil conectado externamente. Las variables leídas son: presión, nivel, potencia de la bomba, porcentaje de apertura de la válvula y caudal. Estas variables se almacenan en una base de datos y se normalizan antes de aplicar los modelos de aprendizaje seleccionados.

Más concretamente, los datos disponibles se tratarán con tres aproximaciones de *deep learning* distintas: una red neuronal convolucional, una red neuronal LSTM y una red neuronal densa.

La primera de ellas es una red neuronal convolucional con filtros de dimensión $1 \times n$ que se va desplazando en el eje de las muestras temporales. En el caso de la red LSTM (*Long short-term Memory*) se selecciona también una ventana de muestras sobre el eje temporal. Este tipo de red aplica una cierta recurrencia de forma que se tienen en cuenta los estados previos para obtener la salida más adecuada. Por último, en la red neuronal densa se aplica también una ventana temporal como las descritas anteriormente.

Con la aplicación de estos tres modelos se estima el valor que tendrá el caudal del proceso en función del que toman el resto de las variables seleccionadas, constituyendo de esta forma el sensor virtual buscado.

4. Experimentos

4.1. Descripción de la planta piloto

Los experimentos realizados toman como punto de partida una planta piloto (Domínguez et al., 2010) que incluye

instrumentación industrial real y que cuenta con tres circuitos diferenciados. La maqueta empleada y sus diferentes circuitos aparecen representados en la Figura 2. El circuito principal o de proceso está diseñado para controlar cuatro variables (caudal, nivel, presión y temperatura) de un fluido en circulación entre dos tanques situados a distintas alturas. Además, el líquido es impulsado desde el tanque inferior al superior por medio de una bomba centrífuga, y su flujo a través de las tuberías se regula por medio de una válvula de accionamiento neumático y una electroválvula.

La maqueta industrial cuenta, además, con un circuito de calentamiento, con resistencias eléctricas que permiten calentar agua y transmitir ese calor al proceso por medio de un intercambiador de placas. Por último, la maqueta presenta también un circuito de enfriamiento, que recircula un refrigerante externo y permite enfriar el fluido de proceso por medio de otro intercambiador de placas.



Figura 2: Maqueta industrial empleada.

Para poder implementar lazos de control sobre las cuatro variables mencionadas anteriormente, el circuito de proceso incluye a su vez los correspondientes sensores: un sensor de nivel ultrasónico, una sonda de temperatura PT-100, un sensor de presión diferencial y un caudalímetro electromagnético. Este último sensor, esencial para los experimentos planteados, permite calcular el caudal del fluido de proceso, sabiendo que el voltaje inducido por éste cuando circula a través de un campo magnético es proporcional a la velocidad con la que el líquido se mueve.

Con el fin de disponer de otra medida distinta y poder comparar los datos obtenidos y los resultados del sensor virtual, se ha conectado un caudalímetro portátil externo. El principio de funcionamiento del sensor se basa en obtener el caudal del fluido en función del tiempo que tarda un haz de ultrasonidos en llegar desde un emisor a un receptor colocados convenientemente en el exterior de la tubería.

4.2. Descripción de la adquisición y dataset

La adquisición de los datos generados a lo largo de los experimentos planteados se ha realizado mediante el empleo de una aplicación multihilo, desarrollada mediante el lenguaje de programación Python. Dicha aplicación ofrece soporte multiprotocolo, permitiendo una lectura unificada de los datos con independencia de la naturaleza y fabricante de los equipos involucrados en la experimentación. Cada equipo definido en la aplicación se encuentra estrechamente vinculado a un hilo de ejecución, el cual se encargará de realizar la solicitud de los datos especificados, en el intervalo que se considere. Los conjuntos de datos solicitados serán temporalmente almacenados en memoria hasta su volcado definitivo en una base de datos determinada, de donde posteriormente se extraerán para su consulta y manipulación.

En los experimentos desarrollados para el presente caso de estudio, se han realizado solicitudes de datos únicamente sobre un autómata Modicon M340 de Schneider Electric, utilizando el protocolo ModBus TCP/IP. Dichas solicitudes se realizan de manera recurrente a intervalos de 100 milisegundos.

La estructura de los datos solicitados se compone de un total de 6 variables reales de las cuales 5 se corresponden con una serie de entradas y salidas de la maqueta (presión, caudal de proceso, válvula de proceso, frecuencia de la bomba y nivel), mientras que la sexta variable se encuentra asociada al caudalímetro ultrasónico. Este equipo ofrece una salida 4-20mA que será utilizada como entrada analógica en el autómata, centralizando y simplificando el proceso de adquisición de datos. Cada solicitud de éste conjunto de variables será provista además del timestamp en el que se produce, con el objetivo de simplificar su clasificación dentro de todo el conjunto de datos del experimento.

Se han realizado un total de 3 experimentos de captura de datos, consistentes en la modificación de la posición de la válvula de proceso, en combinación con la variación de la frecuencia de la bomba que impulsa el fluido de proceso. De esta manera se obtienen una serie de combinaciones aleatorias, que unidas a la inercia asociada al llenado del depósito de la maqueta, ofrecen un conjunto de datos altamente variado. Cada experimento tiene una duración de 1 hora.

Analizando los datos recabados del sistema, se ha comprobado que el tiempo de establecimiento del mismo es de 5 segundos. Teniendo esto en cuenta, se realiza un enventanado de los datos de acuerdo al tiempo de establecimiento, que se traduce en 50 muestras por ventana, dado el intervalo de muestreo de 100 milisegundos utilizado ($T_s=50 \cdot 0.1=5s$). El conjunto de datos totales se ha dividido en 3 partes iguales, destinando 2 de ellas al entrenamiento y validación de los modelos planteados, mientras la restante se utilizará para el testeado del modelo finalmente seleccionado.

El subconjunto de datos destinado a entrenamiento y validación se sirve a los modelos siguiendo un método de validación cruzada de 10 fases (10-fold cross validation): se divide el subconjunto aleatoriamente en 10 partes, uti-

lizando 9 de esas partes para el entrenamiento, mientras que la última parte se destina a la validación. Este procedimiento se repite un total de 10 veces, reservando cada vez una décima parte diferente para la validación. Los diferentes modelos se han parametrizado utilizando los rangos de valores mostrados en la Tabla 1, para evaluar su comportamiento y seleccionar la parametrización óptima.

4.3. Resultados




Figura 3: Predicción del sensor virtual (método 1DCNN) con los datos de test.




Figura 4: Predicción del sensor virtual (método LSTM) con los datos de test.




Figura 5: Predicción del sensor virtual (método DENSE) con los datos de test.

Se definen un total de 10 épocas de entrenamiento, en cada una de las cuales se baraja la totalidad del conjunto

de muestras y se subdivide en lotes de 32 muestras con las que se alimenta a los diferentes modelos, de esta manera se obtiene un conjunto elevado de posibles combinaciones que garanticen el correcto aprendizaje de los diferentes modelos.

Tras el entrenamiento y validación de los modelos parametrizados con los valores anteriores y en las condiciones definidas, se concluye que la parametrización óptima en cada caso es la mostrada en la última columna de la Tabla 1.

Tabla 1: Hiperparámetros utilizados

Hiperparámetro	Rango	Valor
1DCNN		
Filtros	5,10,20,40,80,160	80
Kernel	3,9,27	3
LSTM		
Neuronas	5,10,20,40,80,160	80
DENSE		
Neuronas	5,10,20,40,80,160	20

Tabla 2: Errores usando los datos de test

Método	MAE	RMSE
1DCNN	0.4547	0.2588
LSTM	0.3844	0.2132
DENSE	0.4453	0.2594




Figura 6: Comparación de los tres métodos (1DCNN, LSTM, DENSE).

Por último, se muestran de forma gráfica los resultados obtenidos con cada modelo, enfrentados a los datos capturados con los caudalímetros empleados (Figura 3, Figura 4, Figura 5), concluyendo con una comparación entre los 3 modelos desarrollados (Figura 6). Dicha comparación se expresa numéricamente en el análisis de los errores cuadrático medio (RMSE) y error absoluto medio (MAE), facilitado en la Tabla 2. Como se ha indicado anteriormente, junto con la medida del caudalímetro integrado en la planta piloto industrial, se utiliza también la lectura aportada por un sensor de caudal ultrasónico externo. Aunque este sensor produce más ruido en la medida, el error de la medida real en comparación con los datos aportados por el sensor virtual es aceptable: con la red LSTM, el MAE es de 0.5740 y el RMSE es de 0.4297.

5. Conclusiones y líneas futuras

En este artículo se presenta un método para desarrollar sensores virtuales que se basa en la utilización de técnicas de *deep learning*. Se han comparado tres implementaciones que usan tres de las arquitecturas más típicas del aprendizaje profundo: redes neuronales, redes convolucionales y redes recurrentes. Los experimentos se han realizado en una planta industrial real que dispone de un transmisor de caudal y en la que se ha instalado otro transmisor adicional de caudal, que es portátil. Los mejores resultados se han obtenido con el método basado en una red LSTM ya que el error cuadrático medio (RMSE) y el error absoluto medio (MAE) son los menores. Además, se han realizado pruebas para evaluar el desempeño del sensor virtual comparado con el sensor de caudal portátil, siendo, como era de esperar, los errores obtenidos superiores, pero aceptables. Como líneas futuras se pretenden sustituir los sensores de los lazos de control de la planta piloto por los sensores virtuales obtenidos con el método propuesto. Adicionalmente, se está trabajando en el desarrollo del gemelo digital de la planta piloto, en el que los sensores se virtualizarán también utilizando este método.

Agradecimientos

Esta publicación ha sido financiada por el Ministerio de Ciencia e Innovación, MCIN/AEI/10.13039/501100011033/, mediante el proyecto PID2020-117890RB-I00. El trabajo de José Ramón Rodríguez-Ossorio y de Guzmán González-Mateos ha sido financiado por una beca del *Programa de Investigación de la Universidad de León*.

Referencias


- Abeykoon, C., 2018. Design and applications of soft sensors in polymer processing: A review. *IEEE Sensors Journal* 19 (8), 2801–2813.
- Alonso, S., Morán, A., Pérez, D., Reguera, P., Díaz, I., Domínguez, M., 2019. Virtual sensor based on a deep learning approach for estimating efficiency in chillers. *Communications in Computer and Information Science* 1000, 307–319.
DOI: 10.1007/978-3-030-20257-6_26
- Babiceanu, R. F., Seker, R., 2016. Big data and virtualization for manufacturing cyber-physical systems: A survey of the current status and future outlook. *Computers in Industry* 81, 128 – 137, emerging ICT concepts for smart, safe and sustainable industrial systems.
DOI: 10.1016/j.compind.2016.02.004
- Chhantyal, K., Jondahl, M. H., Viumdal, H., Mylvaganam, S., 2018. Upstream ultrasonic level based soft sensing of volumetric flow of non-newtonian fluids in open venturi channels. *IEEE Sensors Journal* 18 (12), 5002–5013.
DOI: 10.1109/JSEN.2018.2831445
- Domínguez, M., Fuertes, J. J., Reguera, P., González, J. J., Ramón, J. M., 2010. Maqueta industrial para docencia e investigación. *Revista Iberoamericana de automática e informática industrial* 1 (2), 58–63.
- Jiang, Y., Yin, S., Dong, J., Kaynak, O., 2021. A review on soft sensors for monitoring, control, and optimization of industrial processes. *IEEE Sensors Journal* 21 (11), 12868–12881.
DOI: 10.1109/JSEN.2020.3033153

- Kadlec, P., Gabrys, B., Strandt, S., 2009. Data-driven soft sensors in the process industry. *Computers & Chemical Engineering* 33 (4), 795–814.
DOI: 10.1016/j.compchemeng.2008.12.012
- Li, H., Yu, D., Braun, J. E., 2011. A review of virtual sensing technology and application in building systems. *HVAC&R Research* 17 (5), 619–645.
DOI: 10.1080/10789669.2011.573051
- Martin, D., Kühl, N., Satzger, G., 2021. Virtual sensors. *Business & Information Systems Engineering* 63 (3), 315–323.
- Mattera, C. G., Quevedo, J., Escobet, T., Shaker, H. R., Jradi, M., 2018. A method for fault detection and diagnostics in ventilation units using virtual sensors. *Sensors* 18 (11), 3931.
- McDonald, E., Zmeureanu, R., 2015. Development and testing of a virtual flow meter tool to monitor the performance of cooling plants. *Energy Procedia* 78, 1129–1134.
DOI: 10.1016/j.egypro.2015.11.071
- Márquez-Vera, M. A., López-Ortega, O., Ramos-Velasco, L. E., Ortega-Mendoza, R. M., Fernández-Neri, B. J., Zúñiga-Peña, N. S., abr. 2021. Diagnóstico de fallas mediante una lstm y una red elástica. *Revista Iberoamericana de Automática e Informática industrial* 18 (2), 160–171.
DOI: 10.4995/riai.2020.13611
- Nair, A. M., Fanta, A., Haugen, F. A., Ratnaweera, H., 08 2019. Implementing an Extended Kalman Filter for estimating nutrient composition in a sequential batch MBBR pilot plant. *Water Science and Technology* 80 (2), 317–328.
URL: <https://doi.org/10.2166/wst.2019.272>
DOI: 10.2166/wst.2019.272
- Tao, F., Cheng, J., Qi, Q., Zhang, M., Zhang, H., Sui, F., feb 2018. Digital twin-driven product design, manufacturing and service with big data. *International Journal of Advanced Manufacturing Technology* 94 (9-12), 3563–3576.
DOI: 10.1007/s00170-017-0233-1
- Tegen, A., Davidsson, P., Mihailescu, R.-C., Persson, J. A., 2019. Collaborative sensing with interactive learning using dynamic intelligent virtual sensors. *Sensors* 19 (3).
URL: <https://www.mdpi.com/1424-8220/19/3/477>
DOI: 10.3390/s19030477
- Thürlimann, C. M., Dürrenmatt, D. J., Villez, K., 2018. Soft-sensing with qualitative trend analysis for wastewater treatment plant control. *Control Engineering Practice* 70, 121–133.
DOI: <https://doi.org/10.1016/j.conengprac.2017.09.015>
- Xu, L. D., Xu, E. L., Li, L., 2018. Industry 4.0: State of the art and future trends. *International Journal of Production Research* 56 (8), 2941–2962.
DOI: 10.1080/00207543.2018.1444806
- Yang, X., Zhang, Y., Shardt, Y. A., Li, X., Cui, J., Tong, C., 2019. A kpi-based soft sensor development approach incorporating infrequent, variable time delayed measurements. *IEEE Transactions on Control Systems Technology* 28 (6), 2523–2531.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Sintonización con lógica fuzzy de un controlador PID del ángulo de las palas de una turbina eólica flotante

E. López, L. García-Pérez^{a*}, S. Esteban^a, M. Santos^b

^aDpto. de Arquitectura de Computadores y Automática, Facultad de Físicas, Universidad Complutense de Madrid, 28040-Madrid

^bInstituto de Ingeniería del Conocimiento, Universidad Complutense de Madrid, 28040, Madrid, España.

To cite this article: Lopez, E., García-Pérez, L., Esteban, S., Santos, M. 2022. Fuzzy logic tuning of a PID controller of a floating wind turbine blade angle. XVII Simposio CEA de Control Inteligente

Resumen

En este artículo se aplica la lógica fuzzy para ajustar los parámetros de un controlador PID de ángulo de las palas de una turbina eólica marina. El objetivo del control de cabeceo (ángulo de las palas) es obtener la máxima potencia en la fase en la que la velocidad del viento supera la velocidad nominal, mientras se reduce la vibración de la estructura flotante. Se ha simulado un modelo realista de un aerogenerador tipo barcaza de 5 MW, implementado con el software FAST, y se han considerado algunas de las cargas que afectan a la estructura por las perturbaciones ambientales. Los resultados del controlador híbrido inteligente se han comparado con un regulador PI de ganancia programada integrado en el modelo FAST, con resultados satisfactorios.

Palabras clave: Energía eólica, control del ángulo de palas, lógica fuzzy, PID, turbina eólica flotante.

Fuzzy logic tuning of a PID controller of a floating wind turbine blade angle

Abstract

In this paper fuzzy logic is applied to tune the parameters of a PID blade angle controller for an offshore wind turbine. The objective of the pitch (blade angle) control is to obtain the maximum power in the phase where the wind speed exceeds the rated speed, while reducing the vibration of the floating structure. A realistic model of a 5 MW barge-type wind turbine has been simulated, implemented with FAST software, and some of the loads affecting the structure due to environmental disturbances have been considered. The results of the intelligent hybrid controller have been compared with a programmed gain PI controller integrated in the FAST model, with satisfactory results.

Keywords: Wind energy, blade angle control, fuzzy logic, PID, floating wind turbine.

1. Introducción

La más reciente y prometedora producción de energía eólica marina tiene algunas ventajas sobre la terrestre. Las regiones con alta calidad de viento a menudo se encuentran en zonas marinas, donde se pueden instalar parques eólicos con turbinas de mayor tamaño, y presentan menor contaminación visual y acústica y menos daños ecológicos al medio ambiente (Lynn 2012).

Durante la operación de una turbina eólica, la estructura puede verse afectada por las vibraciones producidas por las perturbaciones externas (viento, y en el caso de las turbinas marinas, también las olas, corrientes, etc) y por el acoplamiento producido por el control de la turbina (Tomas-Rodriguez and Santos, 2019) – lo que se conoce como impacto de la amortiguación negativa- y cómo el mismo control afecta a la estructura y a la plataforma (Jonkman, 2018); (Jose *et al.*, 2018). Este comportamiento del control puede hacer que las turbinas eólicas marinas flotantes oscilen, provocando daños

en su estructura mecánica y disminuyendo su vida útil drásticamente. Por eso es interesante cuando se diseña un algoritmo de control para una turbina analizar no sólo su eficiencia en términos de energía sino también cómo el control afecta a la estructura.

El control del ángulo de cabeceo de las palas (pitch) se aplica cuando la velocidad del viento supera el valor nominal. Este control tiene como objetivo mantener la potencia de salida constante a su valor máximo, limitando la potencia capturada para no dañar la estructura. Pero este control puede ser complejo debido a que la relación entre el coeficiente de potencia del aerogenerador marino y el ángulo de paso es no lineal, el actuador tiene una gran inercia y el entorno de trabajo tiene perturbaciones externas (Lin and Wang, 2020). Por ello algunos investigadores han aplicado métodos de control inteligente (Sierra-García and Santos, 2020), (Sierra-García and Santos, 2021). Centrándonos en los que aplican lógica fuzzy a los aerogeneradores, en (Salic *et al.*, 2019) describen un controlador fuzzy cuyo funcionamiento es más suave y cubre un rango de funcionamiento más amplio o el propuesto en (Lin and Wang, 2020), donde se muestra un control híbrido que combina el control repetitivo y el control PID difuso. También en (Han *et al.*, 2016) se presenta un controlador borroso del ángulo de pitch que optimiza varios objetivos de control, como el momento de la pala y el par del generador, con criterios que apuntan a mitigar las cargas de fatiga y regular la potencia de salida. La efectividad del método propuesto se verifica mediante resultados de simulación para un aerogenerador NREL de 2 MW.

El objetivo de este trabajo es investigar si se pueden reducir las oscilaciones de una plataforma de un aerogenerador marino flotante con un control de ángulo de pala PI adaptativo empleando un control fuzzy para sintonizar los parámetros.

La estructura de este trabajo es la siguiente: en primer lugar, en la sección 2 se explicará el modelo de la turbina eólica empleada. En la sección 3 se describe el controlador empleado, concretamente el sistema borroso usado para sintonizar los parámetros del PID. La sección 4 presenta los resultados obtenidos en simulación y la sección 5 las conclusiones y líneas de trabajo futuro.

2. Modelo de la turbina eólica

La incidencia del viento que recibe cada pala proporciona la fuerza para levantarla y arrastrarla. Esta fuerza genera el par del motor. Si integramos el par tangencial en toda la longitud de la pala, obtenemos el par aerodinámico que afecta al rotor (Tabatabaeipour *et al.*, 2012).

$$\tau_r(t) = \frac{1}{2} \rho \pi R^3 C_q(\lambda(t), \beta(t)) v_w^2 \quad (1)$$

donde ρ es la densidad del aire, R es el radio de las palas, $v_w(t)$ es la velocidad del viento y C_q se define como el coeficiente de par, que es la relación entre la velocidad del viento y la velocidad de la punta de la pala. El momento de inercia del rotor se expresa como:

$$\lambda(t) = \frac{R \omega_r(t)}{v_w(t)} \quad (2)$$

donde ω_r es la velocidad del rotor. En la ecuación anterior asumimos que las palas se pueden controlar de forma colectiva, por lo que siempre tienen el mismo ángulo de inclinación.

Por otro lado, el actuador se puede definir como un modelo de segundo orden que incluye la inercia de la pala:

$$\frac{\beta(s)}{\beta_r(s)} = \frac{\omega_n^2}{s^2 + 2\zeta\omega_n s + \omega_n^2} \quad (3)$$

donde β_r es la referencia del ángulo de paso.

El generador incluye un eje de baja velocidad y un eje de alta velocidad, conectados entre sí mediante una transmisión con un engranaje. Se define como dos ejes con un eje de fricción y momentos de inercia conectados con un engranaje que tiene una relación de transmisión i .

Se puede expresar la dinámica del eje de baja velocidad como:

$$J_r \dot{\omega}_r = \tau_r - \tau_l - B_r \omega_r \quad (4)$$

donde J_r y B_r son el momento de inercia y la fricción viscosa del eje de baja velocidad respectivamente. ω_r es la velocidad del rotor y τ_l se define como el par en el eje de baja velocidad.

La dinámica del eje de alta velocidad es:

$$J_g \dot{\omega}_g = \tau_h - \tau_g - B_g \omega_g \quad (5)$$

donde J_g y B_g son el momento de inercia y la fricción viscosa del eje de alta velocidad respectivamente. ω_g es la velocidad del rotor en el generador y τ_h es el par en el eje de alta velocidad. La caja de cambios se define como:

$$\tau_h = \frac{\tau_l}{N_g} \quad (6)$$

La torsión del tren de transmisión se puede definir como un coeficiente de fricción y un resorte de torsión como:

$$\tau_l = K_{dt} \theta_{\Delta} + \mu_{dt} B_{dt} \dot{\theta}_{\Delta} \quad (7)$$

donde K_{dt} es la rigidez a la torsión de la transmisión, B_{dt} es el coeficiente de amortiguación de la torsión de transmisión, y $\theta_{\Delta}(t)$ es el ángulo de torsión que se representa en la siguiente ecuación:

$$\theta_{\Delta} = \theta_r - \frac{\theta_g}{N_g} \quad (8)$$

donde θ_r es el ángulo del eje de baja velocidad y θ_g es el ángulo del eje de alta velocidad. Con las ecuaciones anteriores, podemos reescribir la dinámica general de la siguiente manera:

$$\begin{aligned}
& \begin{bmatrix} \dot{\omega}_r(t) & \dot{\omega}_g(t) & \dot{\theta}_\Delta(t) \end{bmatrix} \\
& = A_{DT} \begin{bmatrix} \omega_r(t) & \omega_g(t) & \theta_\Delta(t) \end{bmatrix} \\
& + B_{DT} \begin{bmatrix} \tau_r(t) & \tau_g(t) \end{bmatrix} \\
& A_{DT} = \begin{bmatrix} -\frac{B_{dt} + B_r}{J_r} & \frac{B_{dt}}{N_g J_r} \\ -\frac{K_{dt}}{J_r} & \frac{\mu_{dt} B_{dt}}{N_g J_g} - \frac{B_g}{J_g} & \frac{\mu_{dt} K_{dt}}{N_g J_g} \\ -\frac{1}{N_g} & 0 \end{bmatrix} \\
& B_{DT} = \begin{bmatrix} \frac{1}{J_r} & 0 & 0 & -\frac{1}{J_g} & 0 & 0 \end{bmatrix}
\end{aligned} \quad (9)$$

Estas fórmulas divergen en el par del generador, que puede ser controlado por un regulador. Podemos aproximar la dinámica de este convertido como un sistema de primer orden:

$$\frac{\tau_g(s)}{\tau_{g,s}(s)} = \frac{\alpha_{gc}}{s + \alpha_{gc}} \quad (12)$$

La potencia generada por el generador es entonces:

$$Pg(t) = \mu_g \omega_g(t) \tau_g(t) \quad (13)$$

donde μ_g se define como la eficiencia del generador.

3. Control de la turbina eólica

Un aerogenerador puede trabajar en diferentes regiones, dependiendo de la velocidad del viento. El control de pitch se aplica cuando la velocidad del viento es mayor que la nominal, por lo que la turbina ha alcanzado tanto la velocidad de giro como la potencia máxima permitida. El objetivo de control es mantener la velocidad constante, lo que se conseguirá controlando el ángulo de inclinación de las palas.

Inicialmente vamos a emplear un controlador PI de ganancia programada, como el descrito en (Hansen *et al.*, 2005), con valores para las ganancias del PI: $p = 0.02$ y $i = 0.00$.

Como modelo de la turbina se usa un modelo no-lineal que incluye la dinámica, proporcionado por la herramienta FAST.

3.1 Propuesta de sintonía mediante lógica fuzzy del control de pitch de la turbina

Vamos a emplear un sistema borroso que permita ajustar las ganancias proporcional e integral del controlador PI del pitch de la turbina. En la Figura 1 se observa las entradas al sistema borroso son el error y el cambio en el error con respecto a la velocidad del rotor.




Figura 1: Esquema del sistema borroso para el ajuste de los parámetros del controlador PI

En este trabajo hemos utilizado funciones de pertenencia del tipo gaussiano, tanto para las dos entradas como para las dos salidas. Se han usado 7 funciones de pertenencia para cada una, etiquetadas como [NB, NM, NS, ZO, PS, PM, PB], que significan [Negative Big, Negative Medium, Negative Small, Zero, Positive Small, Positive Medium, Positive Small]. En la Figura 2 podemos ver la variable de entrada error, e , y en la Figura 3 la variable de salida, K_p . La variable cambio de error es similar a error, y la variable K_i es similar a K_p .




Figura 2: Variable de entrada error




Figura 3: Variable de salida K_p

Para diseñar la base de reglas, se estudió el efecto del error de estado estacionario (SSE) al variar K_p y K_i para este sistema. Los resultados se utilizaron para enunciar 49 reglas para la sintonización de K_p y K_i . Se muestran en la Figura 4 las que definen la variación de K_p según el error y su derivada, y de igual forma se han obtenido para K_i .

Como método de defuzzyficación se ha usado el centroide, y como operador implicación el producto.

$\begin{matrix} \text{ce} \\ \text{e} \end{matrix}$	NB	NM	NS	ZO	PS	PM	PB
NB	PB	PB	PM	PM	PS	ZO	ZO
NM	PB	PB	PM	PS	PS	ZO	NS
NS	PM	PM	PM	PS	ZO	NS	NS
ZO	PM	PM	PS	ZO	NS	NM	NM
PS	PS	PS	ZO	NS	NS	NM	NM
PM	PS	ZO	NS	NM	NM	NM	NB
PB	ZO	ZO	NM	NM	NM	NB	NB

Figura 4: Reglas para variar Kp

4. Resultados y discusión

El objetivo del control es mantener la potencia del generador en 5 MW, controlando el ángulo de las palas, que es lo mismo que mantener la velocidad del rotor en 12,1 rpm para obtener la potencia del generador deseada. Se ha simulado el modelo de turbina flotante NREL 5 MW - ITI Barge en FAST.

La Tabla 1 describe las principales características de esta turbina. Las condiciones de viento utilizadas son las adecuadas para que la turbina se encuentre en la región de operación de velocidad de viento superior a la nominal.

Tabla 1: Propiedades de la turbina

Propiedad	Valor
Altura del buje	87.6 m
Velocidad nominal del generador	1173.7 rpm
Inercia del generador en el eje de alta velocidad	534.116 $\text{kg}\cdot\text{m}^2$
Constante de resorte de torsión	867637000 $\text{N}\cdot\text{m}/\text{rad}$
Constante de amortiguación	6215000 $\text{N}\cdot\text{m}/(\text{rad}/\text{s})$

4.1 Resultados de la simulación

El objetivo es comprobar si el controlador PI con ajuste de parámetros mediante el sistema borroso reduce las oscilaciones de la plataforma. La velocidad media del viento a la altura del

buje es de 18 m/s, el valor característico de la desviación estándar es de 2.674 m/s y la altura del buje es de 90 m.

Se va a comparar el funcionamiento y las vibraciones generadas del control sintonizado con el sistema fuzzy (línea azul), con el controlador PI con ganancia programada (GS-PI) implementado en el software FAST (línea verde), un control PI diseñado en Matlab (línea roja) y el control de FAST con los parámetros ajustados usando un algoritmo genético (línea amarilla).

En la Figura 5 puede verse la evolución temporal de la velocidad del rotor en revoluciones por minuto para cada método de control. Esto permite validar la propuesta ya que los resultados son similares en todos los casos.




Figura 5: evolución temporal de la velocidad del rotor. Simulación FAST (verde), control PI (naranja), algoritmo genético (amarillo), control PI sintonizado con sistema borroso (azul).

En esta Figura 5 puede verse que la velocidad del rotor obtenida con el sistema borroso es muy parecida a las obtenidas los demás controladores. Se ha calculado la diferencia entre la velocidad del rotor deseada y la obtenida usando el controlador de referencia de FAST y el control propuesto. En la Tabla 2 se muestran los errores cuadráticos medios. Puede observarse que ambos son parecidos aunque el obtenido usando el sistema fuzzy es ligeramente inferior.

Tabla 2: Error absoluto de la salida de velocidad del rotor

Controlador	Error absoluto (rpm)
Controlador FAST	6.8006
Controlador difuso	6.6872

En la Figura 6 se presenta la evolución del ángulo de oscilación de la plataforma (pitch).




Figura 6: Oscilación de la plataforma. GS-PI FAST (verde), control PI (naranja), algoritmo genético (amarillo), control PI difuso (azul).

En la Figura 7 vemos la deflexión en la parte superior de la turbina, lo que se conoce como tower top displacement (TTP) en la dirección del viento.




Figura 7: Deflexión longitudinal en la parte superior de la turbina. GS-PI FAST (verde), control PI (naranja), algoritmo genético (amarillo), control PI difuso (azul).

En cuanto a las vibraciones los resultados son alentadores puesto que tanto el ángulo de oscilación de la plataforma como la deflexión en la parte superior de la turbina son ligeramente menores al emplear el control difuso, como se observa en las Figuras 6 y 7.

5. Conclusiones y trabajos futuros

En este trabajo se ha realizado un diseño de controlador PI del ángulo de pitch de un aerogenerador, cuyas ganancias integral y proporcional han sido ajustadas mediante un sistema difuso. Este controlador se ha usado para regular el ángulo de las palas de una turbina eólica flotante de 5MW. El objetivo de este trabajo era comprobar si el ajuste de los parámetros del controlador mediante un sistema borroso mejoraba las prestaciones del controlador de referencia implementado en FAST, y por otro lado, si con el controlador difuso se obtenían menos oscilaciones en la plataforma de la turbina.

Del análisis de los resultados obtenidos se ha comprobado que el sistema de control inteligente se comporta de forma parecida al control integrado en el modelo de la turbina, y que reduce ligeramente las vibraciones de la plataforma. Sin embargo, estos resultados no son concluyentes y se necesita

seguir profundizando en el uso de controladores inteligentes para turbinas eólicas flotantes.

Es necesario usar modelos realistas del y del oleaje para poder realizar simulaciones más realistas que permitan estudiar mejor las oscilaciones de las plataformas y vibraciones en la torre.

Agradecimientos

Este trabajo ha sido parcialmente financiado por el proyecto de investigación del Ministerio de Ciencia, Innovación y Universidades MCI/AEI/FEDER Proyecto RTI2018-094902-B-C21.


Referencias

- Benitz M., Lackner M. y Schmidt D., 2015 Hydrodynamics of offshore structures with specific focus on wind energy applications. *Renewable and Sustainable Energy Reviews*, 44, 692-716.
- Han, B.; Zhou, L.; Yang, F.; Xiang, Z. 2016. Individual pitch controller based on fuzzy logic control for wind turbine load mitigation. *IET Renew. Power Gener.* 10, 687-693.
- Hansen, M. H., Hansen, A. D., Larsen, T. J., Øye, S., Sørensen, P., & Fuglsang, P. 2005. Control design for a pitch-regulated, variable speed wind turbine. Denmark. Forskningscenter Risoe. Risoe-R No. 1500(EN)
- Jonkman J., 2008. Influence of Control on the Pitch Damping of a Floating Wind Turbine. *ASME Wind Energy Symposium*, Reno.
- Jonkman, B., 2009. *TurbSim User's Guide: Version 1.50*. National Renewable Energy Laboratory, 2009.
- Jose A., Falzarano J. and Wang H., 2018. A Study of Negative Damping in Floating Wind Turbines Using Coupled Program FAST-SIMDYN. *Proceedings of the ASME 2018 1st International Offshore Wind Technical Conference*.
- Lin Pan, Xudong Wang, 2020. Variable pitch control on direct-driven PMSG for offshore wind turbine using Repetitive-TS fuzzy PID control. *Renewable Energy*, 159, 221-237. DOI: <https://doi.org/10.1016/j.renene.2020.05.093>.
- Lynn P. A., 2012. *Onshore and Offshore Wind Energy*, John Wiley & Sons Ltd.
- Salic, T.; Charpentier, J.F.; Benbouzid, M.; Le Boulluec, M., 2019. Control Strategies for Floating Offshore Wind Turbine: Challenges and Trends. *Electronics*, 8, 1185. DOI: <https://doi.org/10.3390/electronics8101185>
- Sierra-García, J. E., Santos, M., 2020. Performance Analysis of a Wind Turbine Pitch Neurocontroller with Unsupervised Learning, *Complexity*, (2020) DOI: <https://doi.org/10.1155/2020/4681767>
- Sierra-García, J. E., Santos, M., 2021. Redes neuronales y aprendizaje por refuerzo en el control de turbinas eólicas. *Revista Iberoamericana de Automática e Informática industrial*, 18(4), 327-335.
- Tabatabaeipour S., Odgaard P., Bak T. y Stoustrup J., 2012. Fault Detection of Wind Turbines with Uncertain Parameters: A Set-Membership Approach. *Energies*, 5 (12), 2224-2248.
- Tomas-Rodriguez, M., and Santos, M., 2019. Modelling and control of floating offshore wind turbines. *Revista Iberoamericana de Automática e Informática industrial*, 16(4).
- Wright A. y Fingersh L., 2008. *Advanced Control Design for Wind Turbines*,» National Renewable Energy Laboratory.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Detección y clasificación de animales subacuáticos en observatorios cableados

Lopez-Vazquez, V.^{a, b, *}, Lopez-Guede, J.M.^c

^a Universidad del País Vasco (UPV/EHU), Nieves Cano, 12, 01006, Vitoria-Gasteiz, España.

^b Deusto Seidor S.A., 01015, Vitoria-Gasteiz, España.

^c Departamento de Ingeniería de Sistemas y Automática, Universidad del País Vasco (UPV/EHU), Nieves Cano, 12, 01006, Vitoria-Gasteiz, España.

To cite this article: Lopez-Vazquez, V., Lopez-Guede, J.M. 2022. Detection and classification of underwater animals at cabled observatories. XVII Simposio CEA de Control Inteligente.

Resumen

Los océanos son ecosistemas sensibles y de gran importancia debido a la biodiversidad y recursos que ofrecen. A pesar de que el fondo marino es prácticamente inaccesible para el ser humano, es posible explorarlo gracias a vehículos de guiado automático (AGVs) o mediante cámaras fijas provistas por observatorios cableados. Estos dispositivos pueden obtener imágenes sobre la fauna y flora en entornos donde la luz natural escasea y la presión es mayor, con el fin de realizar un seguimiento del entorno y de las especies que habitan en él. Sin embargo, analizar y clasificar manualmente grandes cantidades de imágenes de manera rápida es una tarea imposible. Por ello, proponemos un proceso para el análisis de datos visuales que integra técnicas de detección y clasificación de animales subacuáticos y de mejora de imágenes y/o vídeos del fondo marino para desarrollar un proceso de detección y clasificación automática de especies marinas.

Palabras clave: Aprendizaje automático, Procesamiento de imágenes, Redes neuronales, Técnicas de inteligencia artificial, Algoritmos en tiempo real.

Detection and classification of underwater animals at cabled observatories

Abstract

The oceans are sensitive ecosystems of great importance due to the biodiversity and resources they offer. Although the seabed is virtually inaccessible to humans, it can be explored using automated guided vehicles (AGVs) or fixed cameras provided by wired observatories. These devices can obtain images of fauna and flora in environments where natural light is scarce and pressure is higher, in order to monitor the environment and the species that inhabit it. However, manually analyzing and classifying large amounts of images quickly is an impossible task. Therefore, we propose a process for the analysis of visual data that integrates techniques for the detection and classification of underwater animals and the enhancement of images and/or videos of the seabed to develop a process of automatic detection and classification of marine species.

Keywords: Machine Learning, Image processing, Neural networks, Artificial intelligence techniques, Real-time algorithms.

1. Introducción

En las últimas dos décadas, la vigilancia y monitorización de los océanos, así como la obtención de imágenes subacuáticas (Bicknell et al. 2016) y el desarrollo de plataformas robóticas cubiertas de sensores ambientales para la obtención de datos, han adquirido una gran importancia (Danovaro et al. 2017). Los observatorios cableados son plataformas multiparamétricas conectadas a la costa mediante

cables de fibra óptica (Favali et al. 2015), siendo una de sus funciones adquirir material de imagen para posteriormente analizarlo e identificar y contar animales de diferentes especies durante largos periodos de tiempo (De Leo et al. 2018).

Sin embargo, en muchos casos, el procesamiento de imágenes sigue siendo manual y las plataformas de observatorios cableados aún no están equipadas con las herramientas adecuadas para el reconocimiento y clasificación de imágenes.

1.1 Objetivo

El objetivo de este artículo es presentar una línea de trabajo para la detección y clasificación de animales submarinos, que incluye la mejora de la imagen, la anotación manual (para definir los conjuntos de datos de entrenamiento y validación), y los pasos automatizados de reconocimiento de contenido y posterior clasificación en la imagen.

Para ello, se hizo uso del material visual proporcionado por la red de observatorios cableados Lofoten-Vesterålen (LoVe) (Godø et al. 2014), situada a 260 m de profundidad, en Noruega. Aún no se ha llevado a cabo el seguimiento de su población local y de otras especies de la comunidad circundante, algo que podría ser de gran relevancia para producir algunos datos auxiliares para los modelos de gestión independientes de la pesca y basados en el ecosistema.

2. Materiales y métodos

2.1. Datos

Las imágenes proporcionadas por el observatorio LoVe fueron adquiridas en un entorno no controlado, caracterizado por un fondo heterogéneo, donde la turbidez y los cambios de iluminación artificial dificultan la detección de elementos. La Figura 1 muestra las diferentes especies detectadas en el conjunto de imágenes.




Figura 1: Un ejemplo de las especies detectadas y utilizadas para construir el conjunto de datos de entrenamiento. A., Pez Roca (*Sebastes* sp.); B., Cangrejo real (*Lithodes maja*); C., Calamar (*Sepiolidae*); D., Estrella de mar; E., Cangrejo ermitaño; F., Anémona (*Bolocera tuediae*); G., Camarón (*Pandalus* sp.); H., Erizo de mar (*Echinus esculentus*); I., Pez anguila (*Brosme brosme*); J., Cangrejo (*Cancer pagurus*); K., Coral (*Desmophyllum pertusum*); y finalmente, L. Turbidez y M., Sombra.

Las imágenes utilizadas fueron obtenidas por una cámara fija en dos ventanas temporales, la primera del 04/10/2017 al 27/06/2018 y la segunda del 10/12/2018 al 29/06/2019. En consecuencia, se dispuso de un total de 8818 imágenes de forma continua en el periodo de 24 horas (obteniendo una imagen cada 60 minutos).

2.2. Procesamiento de imágenes

Se diseñó y desarrolló un proceso para el tratamiento de imágenes basado en herramientas de visión por ordenador para mejorar el contraste de la imagen y para segmentar las subregiones relevantes de la imagen, cuyo esquema puede verse en la Figura 2.

En primer lugar, se generan imágenes de fondo que después se utilizarán para realizar la sustracción de fondo tras aplicar diferentes técnicas a las imágenes. Para mejorar el contraste fondo y primer plano de la imagen se aplicó la técnica de Ecuilización Adaptativa de Histograma con Contraste Limitado (CLAHE) (Reza 2004). Después de esta ecualización, se aplica un filtrado bilateral (Tomasi and Manduchi 1998) para descartar la información no relevante de la imagen y preservar los bordes de los objetos que se van a extraer. En este momento se realiza la sustracción de fondo. De este modo, se obtiene un fotograma con sólo los elementos detectados en la imagen original. Finalmente, se detectan los contornos de la imagen a la que se le aplicó el método del valor umbral para extraer las características globales (como las de textura o color) para su posterior clasificación.




Figura 2: Proceso para el tratamiento de imágenes.

2.3. Diseño experimental

En cuanto a los algoritmos de clasificación utilizados, se seleccionaron un total de 16 algoritmos, teniendo en cuenta sus resultados en este campo (Fang et al. 2018; Rimavicius and Gelzinis 2017; Saberioon et al. 2018; Spampinato et al. 2016). Se escogieron 8 algoritmos clásicos: dos versiones de Support Vector Machine (LSVM y SVM+SGD), dos K-Nearest Neighbors (K-NN1 y K-NN2), dos Decision Trees (DT1 y DT2) y dos Random Forests (RF1 y RF2).

Por otra parte, 8 redes neuronales: cuatro redes convolucionales (denominadas CNN1, CNN2, CNN3 y CNN4) y cuatro redes neuronales profundas (DNN1, DNN2, DNN3 y DNN4). Se eligieron diferentes parámetros de configuración, optimizadores y estructuras, para realizar una comparación entre las redes.

3. Resultados

Los valores medios de exactitud (*accuracy*) y AROUC; el área bajo la curva ROC (acrónimo de *Receiver Operating Characteristic*, o Característica Operativa del Receptor) obtenidos para todas las clases y para cada clasificador que se obtuvieron realizando una validación cruzada, pueden verse en la Tabla 1.

En cuanto a los clasificadores tradicionales, el peor resultado lo obtuvo el K-NN2, ya que apenas alcanzó un valor de AUROC de 0.6390. El RF2 obtuvo el valor AUROC más alto, siendo 0.8210. Los valores de exactitud son bastante

inferiores para cada clasificador en comparación con los valores de AUROC.

Los enfoques DL obtuvieron mejores resultados que casi todos los clasificadores tradicionales. Todas las redes obtuvieron valores AROUC de más del 80%. Las CNN obtuvieron valores de AROUC entre 0.7983 y 0.8180, mientras que las DNN obtuvieron valores más altos, entre 0.8361 y 0.8759 respectivamente.

Tabla 1: Valores de exactitud y AUROC alcanzados con el conjunto de datos de prueba obtenidos por diferentes modelos.

Enfoque	Clasificador	Exactitud	AUROC
Clasificadores tradicionales	Linear SVM	0.5137	0.7392
	LSVM+SGD	0.4196	0.6887
	K-NN1	0.4463	0.7140
	K-NN2	0.3111	0.6390
	DT1	0.4310	0.6975
	DT2	0.4331	0.6985
	RF1	0.4326	0.6987
	RF2	0.6527	0.8210
Técnicas de DL	CNN1	0.6191	0.7983
	CNN2	0.6563	0.8180
	CNN3	0.6346	0.8067
	CNN4	0.6421	0.8107
	DNN1	0.7618	0.8759
	DNN2	0.7576	0.8730
	DNN3	0.6904	0.8361
	DNN4	0.7140	0.8503

La figura 3 muestra la matriz de confusión de los resultados de clasificación obtenidos por la DNN1, que obtuvo buenos resultados para casi todas las clases.




Figura 3: Matriz de confusión para los resultados de clasificación (precisión) obtenidos por la DNN1.

4. Conclusiones

El objetivo de este trabajo fue diseñar un proceso automático para la detección y clasificación de animales subacuáticos, realizando técnicas de filtrado y mejora y utilizando técnicas de aprendizaje automático. Se obtuvieron

resultados altos con valores de exactitud del 76.18% y AUROC del 87.59%.

La mejora de las imágenes subacuáticas también desempeñó un papel importante en la detección de elementos. Sería interesante profundizar en estos métodos, ya que una clara mejora de las imágenes podría reducir el trabajo posterior de detección de características y obtener mejores tasas de clasificación.

La utilización de clasificadores tradicionales y técnicas de DL orientadas a la detección de especies marinas y los resultados obtenidos, demuestran que la utilización de estos métodos puede ser un avance importante en este campo.

Agradecimientos

La investigación y desarrollo de este trabajo ha sido realizado en la empresa Deusto SEIDOR, junto con varias empresas colaboradoras. Se desarrolló en el marco de la Tecnoterra (ICM-CSIC/UPC), la Cofundación MarTERA ERA-Net y fue financiado por el Centro para el Desarrollo Tecnológico Industrial (CDTI) y RESBIO (TEC2017-87861-R; Ministerio de Ciencia, Innovación y Universidades).


Referencias

- Bicknell, A. W., B. J. Godley, E. V. Sheehan, S. C. Votier, and M. J. Witt. 2016. "Camera technology for monitoring marine biodiversity and human impact." *Frontiers in Ecology and the Environment*, 14 (8): 424–432.
- Danovaro, R., J. Aguzzi, E. Fanelli, D. Billett, K. Gjerde, A. Jamieson, E. Ramirez-Llodra, C. Smith, P. Snelgrove, L. Thomsen, and C. Dover. 2017. "An ecosystem-based deep-ocean strategy." *Science*, Vol. 355: 452–454. <https://doi.org/10.1126/science.aah7178>.
- De Leo, F. C., B. Ogata, A. R. Sastri, M. Heesemann, S. Mihály, M. Galbraith, and M. G. Morley. 2018. "High-frequency observations from a deep-sea cabled observatory reveal seasonal overwintering of *Neocalanus* spp. in Barkley Canyon, NE Pacific: Insights into particulate organic carbon flux." *Progress in Oceanography*, 169: 120–137.
- Fang, Z., J. Fan, X. Chen, and Y. Chen. 2018. "Beak identification of four dominant octopus species in the East China Sea based on traditional measurements and geometric morphometrics." *Fisheries Science*, 84 (6): 975–985.
- Favali, P., L. Beranzoli, and A. De Santis. 2015. *SEAFLOOR OBSERVATORIES: A New Vision of the Earth from the Abyss*. Springer Science & Business Media.
- Godø, O. R., S. Johnsen, and T. Torkelsen. 2014. "The LoVe Ocean Observatory is in Operation." *Marine Technology Society Journal*, 48 (2): 24–30.
- Reza, A. M. 2004. "Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement." *Journal of VLSI signal processing systems for signal, image and video technology*, 38 (1): 35–44.
- Rimavicius, T., and A. Gelzinis. 2017. "A Comparison of the Deep Learning Methods for Solving Seafloor Image Classification Task." *International Conference on Information and Software Technologies*, 442–453. Springer.
- Saberioon, M., C. Petr, L. Laurent, P. Sou, P. Pelissier, and T. Kerneis. 2018. "Comparative Performance Analysis of Support Vector Machine, Random Forest, Logistic Regression and k-Nearest Neighbours in Rainbow Trout (*Oncorhynchus Mykiss*) Classification Using Image-Based Features." *Sensors*, 18: 1027.
- Spampinato, C., S. Palazzo, P.-H. Joalland, S. Paris, H. Glotin, K. Blanc, D. Lingrand, and F. Precioso. 2016. "Fine-grained object recognition in underwater visual data." *Multimedia Tools and Applications*, 75 (3): 1701–1720.
- Tomasi, C., and R. Manduchi. 1998. "Bilateral filtering for gray and color images." *Iccv*, 2. Iccv.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Contribuciones del gemelo digital y la inteligencia artificial en la industria de la automoción

Otxoa-De-La-Torre, I.^{a,*}, Lopez-Guede, J. M.^a

^a Departamento de Ingeniería de Sistemas y Automática, Universidad del País Vasco (UPV-EHU), C/ Nieves Cano 12, 01006, Vitoria-Gasteiz, España.

To cite this article: Otxoa-De-La-Torre, I., Lopez-Guede, J. M.. 2022. Digital twin and artificial intelligence contributions towards the automotive industry. XVII Simposio CEA de Control Inteligente.

Resumen

Factores como la electrificación y la pandemia del Covid-19 están ocasionando tiempos difíciles en la industria del automóvil, obligando a las fábricas a ser más eficientes y flexibles que nunca para hacer frente a la incertidumbre resultante. Ante este panorama, conceptos bajo el paraguas de la Industria 4.0 como el del Gemelo Digital (GD) junto a técnicas de Inteligencia Artificial (IA) se muestran como facilitadores para lograr ambos factores. Con el fin de demostrar su potencial, este trabajo presenta la aplicación de dos técnicas de IA destinadas a mejorar el proceso de llenado del circuito de aire acondicionado (A/C) de los vehículos producidos en la fábrica de Mercedes-Benz de Vitoria-Gasteiz, estando ambas enmarcadas dentro de un proyecto orientado al desarrollo de un GD de dicho proceso.

Palabras clave: Industria automoción, Industria 4.0, Gemelo digital, Inteligencia artificial, Clustering, Autoencoders.

Paper Title in English, Bold Style

Abstract

Factors like electrification and the Covid-19 pandemic are leading to hard times in the automotive industry, making necessary for factories to be more efficient and flexible than ever to cope with the resulting uncertainty. Against this background, concepts under the umbrella of the Industry 4.0 such as the Digital Twin (DT) and Artificial Intelligence (AI) techniques appear as enablers for achieving these two factors. As proof of their potential, this paper presents the application of two AI techniques oriented to the improvement of the air conditioning (A/C) circuit filling process of the vehicles produced in the Mercedes-Benz Vitoria-Gasteiz factory, both being framed within a DT development project of the said process.

Keywords: Automotive industry, Industry 4.0, Digital twin, Artificial intelligence, Clustering, Autoencoders.

1. Introducción

A lo largo de su historia, la industria del automóvil ha experimentado numerosas transformaciones para adaptarse a las nuevas exigencias del mercado. Pero lejos de ser suficiente, los tiempos actuales vuelven a exigir nuevos y profundos cambios. Según reconocidas consultoras y revistas internacionales (Cubiss, 2021), (Kuhnert and Stürmer, 2021), las pautas que marcarán el vehículo del futuro pasan por la electrificación, las comunicaciones entre vehículos (V2X), la conducción autónoma y la movilidad compartida. Además, el sector se está viendo afectado por acontecimientos como la pandemia del Covid-19, la escasez de microchips y la guerra

de Ucrania. Son por tanto tiempos complicados, que ponen de manifiesto la necesidad de que las fábricas sean cada vez más flexibles y eficientes para poder sobrevivir.

En este contexto, conceptos como el del Gemelo Digital (GD) (Grieves and Vickers, 2017) dentro de la corriente de la Industria 4.0 (Lasi *et al.*, 2014) aparecen como respuesta estratégica a estas necesidades de eficiencia y flexibilidad. Su base tecnológica reside en el Internet de las Cosas (IoT) (Ashton, 2009), que propone la integración de electrónica, software y conectividad en los dispositivos para favorecer la recogida y transferencia de datos a través de la red. La recepción en tiempo real de estos datos permite la construcción de representaciones virtuales de las entidades de las que proceden, dando lugar al concepto de GD. Además, el

procesamiento de estos datos mediante técnicas de Inteligencia Artificial (IA) permite controlar, simular y predecir los posibles estados del gemelo físico representado. Así, la adopción del GD proporciona a las organizaciones la oportunidad de monitorizar y optimizar sus operaciones ganando en eficiencia y flexibilidad, desarrollar productos y servicios innovadores, así como diversificar la creación de valor y los modelos de negocio, entre otros (Lu *et al.*, 2020).

Perteneciendo a este sector y con el fin de manejar toda esta incertidumbre, la fábrica de Mercedes-Benz de Vitoria-Gasteiz se encuentra actualmente desarrollando numerosos proyectos relacionados con la digitalización y la Industria 4.0. Esto incluye la implementación de GDs para varios de sus procesos productivos, siendo el del llenado de los circuitos de aire acondicionado (A/C) uno de ellos. Dentro de este proyecto y como parte de las funcionalidades del GD previstas, se han ideado dos casos de uso que apoyados sobre técnicas de IA prometen ser de gran valor.

El objetivo de este documento es presentar ambos junto con los planes para su desarrollo. Así, la Sección 2 comienza ofreciendo una breve descripción del proceso de llenado de A/C, acompañada de los principales inconvenientes que existen en él. Seguidamente, la Sección 3 presenta los dos casos de uso basados en la IA que pretenden resolver los problemas anteriores, incluyendo los materiales y métodos concretos que se planean utilizar para su desarrollo.

2. Proceso de llenado de los circuitos de A/C y problemas asociados

La fábrica de Mercedes-Benz de Vitoria-Gasteiz ha desarrollado su propio proceso de llenado, cuya curva característica se muestra en color azul claro sobre la Figura 1. Básicamente, se compone de una fase de presurización destinada a la detección de fugas desde el interior hacia el exterior, una fase de vacío orientada a la identificación de fugas desde el exterior hacia el interior, una fase de recuperación de vacío en la que recupera el vacío que se hubiera podido perder como consecuencia de un cambio de línea que deben de realizar los vehículos, y finalmente, una fase de carga en la que se procede a llenar el circuito con el gas refrigerante correspondiente siempre y cuando no se hayan detectado fugas en las etapas anteriores.

Actualmente, existen dos problemas principales relacionados con el proceso. El primero de ellos está relacionado con una falta de dominio del mismo, siendo uno de los motivos la captura incompleta de datos que se realiza. En lugar de registrar todos los valores de presión a lo largo de un ciclo, sólo se leen ciertos puntos de presión en instantes prefijados, haciendo que la curva resultante de su unión se aleje de la ya presentada como teórica (ver Figura 1). Por consiguiente, esto impide tener un conocimiento exacto del comportamiento real descrito por los circuitos de los vehículos en el momento del llenado. La otra razón tiene que ver con la explosión en las opciones de configuración de los vehículos motivada por las actuales demandas del mercado (longitud de los vehículos, A/C delantero/trasero, motor de combustión/eléctrico, ...), afectando muchas de ellas a las propiedades de los circuitos de A/C. Esto ha provocado una ruptura de los esquemas y procedimientos tradicionales de la

fábrica para acometer los llenados, ya que todos ellos estaban asentados sobre la poca variabilidad característica de épocas anteriores. En otras palabras, prácticamente la totalidad de los circuitos de A/C eran idénticos, lo que permitía suponer la igualdad entre sus curvas de llenado y la existencia de no más de un par de curvas de referencia. En consecuencia, los ingenieros de proceso se enfrentan a la necesidad de descubrir las posibles nuevas variantes de llenado que existen y reacondicionar el proceso en consonancia.

El segundo problema tiene que ver con la ausencia de estrategias de mantenimiento predictivo para la detección temprana de anomalías en las consolas encargadas de realizar los llenados. Los enfoques actuales de mantenimiento preventivo no sirven para detectar las pequeñas desviaciones que surgen momentáneamente, derivando muchas veces en grandes fallos que afectan negativamente a los objetivos de producción, costes y eficiencias.




Figura 1: Comparación entre la curva de llenado de A/C teórica y la que es posible obtener en la actualidad.

3. Propuestas de resolución: materiales, métodos y resultados esperados

Con el fin de superar los dos problemas descritos, seguidamente se presenta una propuesta de resolución para cada uno de ellos. Ambas se basan en técnicas de IA, empleando datos del proceso como materia prima. En particular, se sugiere el uso de una técnica de clustering para la identificación de las diferentes variantes de llenado que existen dentro de la cartera actual de vehículos. En cuanto a la detección de anomalías, se propone un enfoque consistente en el entrenamiento de redes neuronales de tipo autoencoder. Cabe apuntar que la implementación de cualquiera de ellas requiere de una actualización del sistema de adquisición de datos, de forma que se registre la totalidad de la curva por cada llenado realizado.

4.1. Clustering para la identificación de variantes de llenado

El clustering (Milligan and Cooper, 1987) es una conocida técnica de clasificación no supervisada que consiste en dividir una determinada población de datos en diferentes grupos, buscando la mayor unión intragrupal a la vez que la máxima separación intergrupala. Trasladado al escenario de los llenados de los circuitos de A/C, la aplicación de tal técnica sobre los datos de vehículos ya llenados parece ser una herramienta prometedora para ayudar a los ingenieros a detectar patrones, identificar nuevas variantes de llenado y obtener sus correspondientes curvas de referencia. Concretamente, la entrada para el algoritmo debería de ser un conjunto de datos

compuesto por ciclos de llenado OK de vehículos, incluyendo asimismo los códigos comerciales relacionados con el circuito de A/C asociados a cada uno de ellos. Sobre esta base, se espera que el algoritmo de clustering identifique y agrupe todas aquellas variantes de vehículos que, aun siendo diferentes en términos de códigos comerciales, sus circuitos de A/C muestren un comportamiento similar durante el proceso de llenado. Como salida, debería de proporcionar las particiones detectadas que vienen a representar variantes de llenado diferentes, aportando por cada una de ellas la curva de referencia que la caracteriza y el grupo de vehículos procedente del conjunto de datos original que le pertenece. Igualmente, se podrían calcular las agrupaciones de códigos comerciales que definen a cada uno de los clusters descubiertos. La Figura 2 pretende representar todo este proceso. En cuanto al algoritmo de clustering y medida de distancia específicos a utilizar, dado que los datos a manejar vienen a ser series temporales de longitud variable, una estrategia basada en el uso conjunto del popular algoritmo k-means (Hartigan and Wong, 1979) junto con la medida de similitud Dynamic Time Warping (DTW) (Berndt and Clifford, 1994) parece ser razonable.




Figura 2: Representación del proceso de aplicación de un algoritmo de clustering sobre los datos del proceso de llenado A/C, ilustrando las posibles entradas y salidas.

4.2. Autoencoders para la detección de anomalías

Un autoencoder es un tipo especial de red neuronal artificial que intenta aprender a generar como salida lo mismo o algo similar a lo que recibe como entrada (ver estructura de red en la Figura 3). Esta propiedad y comportamiento de los autoencoders los hace ideales para escenarios de detección de anomalías (An and Cho, 2015). Llevado al contexto de los llenados de circuitos de A/C, en caso de que un autoencoder se entrene sólo con muestras de ciclos de OK pertenecientes a una variante de llenado específica, es de esperar que la red sea capaz de extraer y aprender las características más relevantes que definen a tales ciclos. De este modo, una vez se complete el entrenamiento de un modelo y llegado el punto de ponerlo en producción, se deberá de prestar especial atención a aquellos ciclos de llenado que vengán categorizados como OK por las consolas que los realizan. Si realmente no presentan ninguna irregularidad, el error de reconstrucción será mínimo

y no será necesario hacer saltar las alarmas. Sin embargo, en caso de contener alguna anomalía, se presupone que el error de reconstrucción será significativo, provocando en este caso el disparo de las alarmas en señal de que algo está fallando en la consola que originalmente los realizó. Más aún si esto ocurre repetidamente por cada ciclo y sobre la misma consola. Ante tal situación, la idea es que las alarmas lleguen al equipo de mantenimiento de modo que puedan realizar las comprobaciones y reparaciones oportunas a tiempo antes de que se produzcan fallos mayores. Todo este escenario queda representado en la Figura 3. En cuanto a los ciclos directamente categorizados como NOK por las consolas de llenado, cabe apuntar que no es necesario hacerlos pasar por los autoencoders entrenados. Evidentemente, éstos harían saltar las alarmas puesto que el error de reconstrucción sería sustancial. Sin embargo, estas situaciones no son motivo de alerta, ya que la categorización NOK del ciclo inicialmente proporcionada por la consola es muestra suficiente de que el error no proviene de la misma sino que del propio circuito del vehículo (posiblemente una o más fugas).




Figura 3: Situación en la que el ciclo recibido viene categorizado como OK aunque sí que contiene una anomalía. Esto se percibe en el error de reconstrucción, haciendo saltar las alarmas.

Agradecimientos

Este trabajo ha sido realizado gracias al apoyo de la fábrica de Mercedes-Benz Vitoria a través del programa PIFG19/29.


Referencias

- An, J. and Cho, S., 2015. Variational autoencoder based anomaly detection using reconstruction probability. Special Lecture on IE, 2(1), pp.1-18.
- Ashton, K., 2009. That 'internet of things' thing. RFID journal, 22(7), pp.97-114.
- Berndt, D.J. and Clifford, J., 1994. Using dynamic time warping to find patterns in time series. In KDD workshop, Vol. 10, No. 16, pp. 359-370.
- Cubiss, J., 2021. The future of automotive and mobility. Forbes (online).
- Grieves, M. and Vickers, J., 2017. Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems. In Transdisciplinary perspectives on complex systems, pp. 85-113. Springer, Cham.
- Hartigan, J.A. and Wong, M.A., 1979. Algorithm AS 136: A k-means clustering algorithm. Journal of the royal statistical society. series c (applied statistics), 28(1), pp.100-108. 9.
- Kuhnert, F., Stürmer, C., 2021. Five trends transforming the automotive industry. PwC (online).
- Lasi, H., Fettke, P., Kemper, H.G., Feld, T. and Hoffmann, M., 2014. Industry 4.0. Business & information systems engineering, 6(4), pp.239-242.
- Lu, Y., Liu, C., Kevin, I., Wang, K., Huang, H. and Xu, X., 2020. Digital Twin-driven smart manufacturing: Connotation, reference model, applications and research issues. Robotics and Computer-Integrated Manufacturing, 61, p.101837.
- Milligan, G.W. and Cooper, M.C., 1987. Methodology review: Clustering methods. Applied psychological measurement, 11(4), pp.329-354.
- Zhou, C. and Paffenroth, R.C., 2017. Anomaly detection with robust deep autoencoders. In Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining (pp. 665-674)



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Convolutional Neural Network for Malware Detection in IoT Network

AlHamdi, M. J. M.^{a,*}, Lopez-Guede, J. M.^b, Rahebi, J.^c

^a Systems and Automatic Control Department, University of the Basque Country (UPV/EHU), Spain

^b Systems and Automatic Control Department, University of the Basque Country (UPV/EHU), Spain

^c Department of Software engineering, Istanbul Topkapi University, Istanbul, Turkey.

To cite this article: Alhamdi, M. J.M., Lopez-Guede, J. M., Rahebi, J. 2022. Convolutional Neural Network for Malware Detection in IoT Network. XVII Simposio CEA de Control Inteligente.

Abstract

The network has exploded in popularity in the twenty-first century in the last few years, becoming one of the most extensively utilized and prominent technologies. Nowadays, cyberattacks occurring and the variety, size, and intensity of cyberattacks are increasing. In this work, the machine learning method is used to predict Intrusion in the Internet of Things. Attacks on networks connected to smart cities or on intelligent transportation systems endanger the security of these networks. Studies show that IoT attacks can cost the network millions of dollars. DDoS attacks by malicious botnets and nodes on the IoT network are among the most malicious attacks on the network and can disable IoT application servers.

Keywords: Internet of Things, Malware Detection, Convolutional Neural Network.

1. Introduction

Machine learning models require training data regardless of the method utilized. There is no exception to this rule in machine learning models used in anomaly-based intrusion detection systems. Public data sets are distinguished from private data sets by their availability to the general public. In the lack of private sector inquiry, this study will only look at well-known public data sets. These are frequently employed by academics and researchers alike for benchmarking purposes. It contains attacks that are distinct from those of its parents, such as smurf and Neptune. There are also four different types of attacks classified as DoS, user to root, remote to local, and probing. It is, however, criticized for being very repetitive and for having damaged data (Cup, 1999). It was suggested that NSLKDD be used to solve these problems (Tavallae et al., 2009). Although it mitigates statistical weaknesses in the data set, NSL-KDD still suffers from the lack of modern attacks and real-world samples. Additionally, the data collection includes packet capture (pcap) files of flowing traffic and characteristics derived from raw data. These characteristics are retrieved by the authors using the freely available argues tool and some custom scripts. The Canadian Institute for Cybersecurity has also compiled a collection of available data sets for IDS research (CIC). These are designated using the CICIDS format, for example,

CICIDS2017 (Sharafaldin et al., 2018). Majority of prior work has been conducted on public or private data sets generated in lab settings using network traffic simulators. However, drawbacks associated with the use of artificially generated data sets may be described as follows: (1) a lack of real-world behavior profiling for a particular business network; (2) a model's lack of representation of real-world risks.

2. Literature review

The IoT has different applications and can be used in various fields such as agriculture. Nowadays, smart objects can be placed on farms to control the quality of crops and enhance their productivity by regular monitoring of the status of crops. It is also possible to control the sales network of a product in the market by monitoring the product distribution process. The IoT applications are not limited only to agriculture. According to figure 1, it can be also employed to enhance and upgrade security, productivity, and smartness to high levels:



Fig. 1. The IoT applications (Pardini et al., 2019)

As seen in figure 1, the IoT can be used in smart homes and cities, agriculture, transportation, vehicles, healthcare, industries, education and business. A very important application of the IoT is in future smart homes by enhancing comfort greatly. In this technology, a set of nodes are placed in smart homes to collect data from the home environment and to control home appliances.

In research (Liu et al., 2020) and in 2020, a review of Android malware detection approaches based on machine learning is presented. Android apps are evolving rapidly in the mobile ecosystem, but Android malware is also emerging endlessly, and many researchers have explored the issue of Android malware detection and theories and methods from different perspectives. Have provided. Existing research shows that machine learning is an effective and promising way to detect Android malware. This article provides a comprehensive overview of machine learning approaches based on machine learning. They briefly introduced some areas related to Android applications, including Android system architecture, security mechanisms, and Android malware classification. This review will help academics get a complete picture of machine-based Android malware detection. They can then serve as a basis for future researchers to start new work and help guide research in this area.

In the study (Chakravarty, 2020) and in 2020, presented feature selection and evaluation of licensed Android malware detection. Android malware is a pervasive threat to the security of mobile users' information. Android users often download apps from unauthorized and unreliable sources. Such programs may require multiple permissions from the user, and due to lack of awareness, the user can grant the necessary permissions. Android licenses are one of the most important sources of malware infection. By analyzing the permissions, it is possible to classify malware and malware in the database with the help of machine learning tools. There are a total of 330 licenses in Android apps. However, not all of them may contribute to the classification. In this paper, the proposed system examines the identification of the most effective permissions using feature reduction. In this research, decision tree, random committee, perceptron multilayer, sequential

minimum optimization and random classifiers are used to evaluate the selected features. Experimental results show that five licenses can be almost complete, thus optimizing the malware detection system.

In the study (Haddadpajouh et al., 2020) and in 2020, they introduced a meta-heuristic and multi-kernel feature selection approach to identify the threat of IoT malware in the sensor layer and smart objects. IoT devices are increasingly targeted by malware due to their presence in a wide range of applications, including at home and in corporate environments. In this paper, they propose a method for detecting malware on IoT devices using the Gray Wolf optimization method and a multi-core support vector machine. This model is trained with IoT sample malware codes. The training data set consists of 271 benign samples and 281 malicious samples of Cortex A9 and is evaluated using cross-validation method. They validated the proposed model in terms of its ability to detect IoT malware that had not been seen before. Their proposed model, compared to the previous model of deep neural network, which requires more than 80 seconds to train the same data, requires only 20 seconds to train. In general, the proposed multi-core backup vector machine method performs better in terms of accuracy than deep network and IoT malware detection techniques based on fuzzy methods, while reducing computational cost and training time significantly reduced.

Host-based examines activity on endpoints, namely hosts, depending on the data collecting method. In other words, System resources including memory, CPU, and disk I/O are monitored by HIDS, as well as programs to look for unusual behavior. To that degree, their jurisdiction extends to the host on which they function. The majority of HIDS search for indications of a danger in locations such as operating system log files or the audit logs of another piece of software (Bhattacharyya & Kalita, 2019). Alarms are generated based on specified criteria. Due to the fact that they function according to rules, their performance in detecting known intrusion attempts is very good. They are, however, ineffective in detecting new assaults (Buczak & Guven, 2015). On the other hand, there are modern public data sets for IDS research created by universities and/or research groups. Recognizing the need for a modern IDS data set, Moustafa and Slay proposed UNSW-NB15 data set (Moustafa & Slay, 2015). As with earlier examples, it was produced in a lab setting using fake malicious and benign instances generated using a commercial network simulation device. To be more precise, such tools allow the simulation of current attacks by automatically gathering data from Common Vulnerabilities and Exposures (CVE) web sites and then developing and delivering network assaults in response.

3. Methodology

Anomaly-based intrusion detection machine learning approaches have no inherent advantages or disadvantages. Researchers may be influenced by a variety of factors when choose which technique to use. The amount of computer power available, the availability of field experts to manually intervene in the data, and the amount of data to be processed in a second are some of the issues a researcher should consider to choose

the method of choice. To summarize, the effectiveness of a particular strategy should be assessed on a case-by-case basis. The flow chart of proposed method is shown in figure 2.




Fig. 2. Flowchart of proposed method

There are challenges in IoT network security because most IoT devices have limited power, in other words, their limited computing power makes it impossible to support strong security systems. Due to the weakness of the objects connected to the IoT network, it is difficult to encrypt and authenticate to prevent malicious cyber-attacks on this type of network. An intrusion detection system logically as a leading security solution can be of great help in solving this challenge. Network intrusion detection can be based on the non-intelligent mechanism of blacklisting or it can be based on anomalous learning methods. Machine learning and anomaly detection mechanisms play an essential role in protecting networks against various malicious activities. In this study, they applied different machine learning algorithms to effectively identify anomalies in the Internet penetration data network, and their results show that machine learning methods are highly accurate in penetration detection.

4. Conclusion

This study is investigated especially true in the DDoS detection, where previous hacks had cascading effects. Securing the network and maximizing its security While IoT devices may cause havoc on networks, they also provide a

level playing field for users to adopt security measures that protect all connected devices.

References

- Bhattacharyya, D. K., & Kalita, J. K. (2019). *Network anomaly detection: A machine learning perspective*. Chapman and Hall/CRC.
- Buczak, A. L., & Guven, E. (2015). A survey of data mining and machine learning methods for cyber security intrusion detection. *IEEE Communications Surveys & Tutorials*, 18(2), 1153–1176.
- Chakravarty, S. (2020). Feature selection and evaluation of permission-based Android malware detection. *2020 4th International Conference on Trends in Electronics and Informatics (ICOEI)*(48184), 795–799.
- Cup, K. D. D. (1999). <http://kdd.ics.uci.edu/databases/kddcup99/kddcup99.html>. *The UCI KDD Archive*.
- Haddadpajouh, H., Mohtadi, A., Dehghantanaha, A., Karimipour, H., Lin, X., & Choo, K.-K. R. (2020). A multikernel and metaheuristic feature selection approach for IoT malware threat hunting in the edge layer. *IEEE Internet of Things Journal*, 8(6), 4540–4547.
- Liu, K., Xu, S., Xu, G., Zhang, M., Sun, D., & Liu, H. (2020). A review of android malware detection approaches based on machine learning. *IEEE Access*, 8, 124579–124607.
- Moustafa, N., & Slay, J. (2015). UNSW-NB15: a comprehensive data set for network intrusion detection systems (UNSW-NB15 network data set). *2015 Military Communications and Information Systems Conference (MilCIS)*, 1–6.
- Pardini, K., Rodrigues, J. J. P. C., Kozlov, S. A., Kumar, N., & Furtado, V. (2019). IoT-based solid waste management solutions: a survey. *Journal of Sensor and Actuator Networks*, 8(1), 5.
- Sharafaldin, I., Lashkari, A. H., & Ghorbani, A. A. (2018). Toward generating a new intrusion detection dataset and intrusion traffic characterization. *ICISSp*, 1, 108–116.
- Tavallae, M., Bagheri, E., Lu, W., & Ghorbani, A. A. (2009). A detailed analysis of the KDD CUP 99 data set. *2009 IEEE Symposium on Computational Intelligence for Security and Defense Applications*, 1–6.

Deep Learning Neural Network for Alzheimer's Disease Predictions

Alyaqoobi, H. I.^{a,*}, Lopez-Lopez, J. M.^b, Akbar, O. A.^c, Rahebi, J.^d

^a Systems and Automatic Control Department, University of the Basque Country (UPV/EHU), Spain

^b Systems and Automatic Control Department, University of the Basque Country (UPV/EHU), Spain

^c Systems and Automatic Control Department, University of the Basque Country (UPV/EHU), Spain

^d Department of Software engineering, Istanbul Topkapi University, Istanbul, Turkey.

To cite this article: Alyaqoobi, H. I., Lopez-Guede, J. M., Akbar, O. A., Rahebi, J., 2022. Deep Learning Neural Network for Alzheimer Disease Predictions. XVII Simposio CEA de Control Inteligente

Abstract

Alzheimer's disease is a dangerous and progressive disease that affects the nervous system and brain of people. An important and effective approach to treating Alzheimer's disease is to diagnose the disease early so that more effective treatments can be offered. One practical way to diagnose Alzheimer's disease is to use magnetic resonance imaging to detect plaque and affected areas. In this paper, a new method based on the Harris Hawks optimization method is presented for Alzheimer's disease diagnosis. This method uses the best features that obtain from the MRI images and uses it in deep learning to classify the healthy and non-healthy images.

Keywords: Deep Learning, Harris Hawks, Neural Network, Alzheimer's Disease Predictions.

1. Introduction

Although CT scans are still used regularly for diagnostic assessments and to study the relationship between the brain and behavior, they are mainly used when MRI is prohibited; Because MRI is currently the method of choice for evaluating neurodegenerative diseases. Patients with cognitive impairment can be detected up to 3 years before the onset of clinical symptoms, compared with controls. In patients with Alzheimer's, hippocampal atrophy (reduction of 10-50% (amygdala), reduction of up to 40% (and Para hippocampus) to 40% (compared to the control group in terms of age, homogenization was reported. There is convincing evidence that atrophy of the internal structures of the temporal lobe, especially the hippocampus and entorhinal cortex, early in the course of the disease and even before the onset of symptoms It occurs clinically (Soininen et al., 1982)(Tartaglia et al., 2011). In structural MRI, entorhinal cortical atrophy is now seen in MCI. By the time the mild symptoms of the disease appear, the volume of the hippocampus may have decreased by more than 25%. Hippocampal volume is associated with the severity of clinical signs and symptoms of memory loss, the patient's score on cognitive evaluation tests and pathological findings (Soininen et al., 1982). However, another group believes that there is no clear association between lesions in the course of dementia, including lesions of hyperexcitability of white

matter on MRI, and the severity of symptoms of cognitive impairment after adjustment for age.

2. Literature review

According to the figure 1, it can be seen that there are damaged areas and plaques of Alzheimer's disease in the end areas of nerve cells, which interfere with the transmission of messages between cells.




Fig. 1. The structure of the brain and nerve cells of an Alzheimer's patient (Breijyeh & Karaman, 2020)

One of the most important methods in diagnosing Alzheimer's disease is the use of brain imaging techniques. One of the most important methods in brain tissue analysis is the use of magnetic resonance imaging of the brain, which uses a magnetic field to image brain tissue. In this method, the effect

of the magnetic field of the brain and the external magnetic field is investigated and based on the intensification of protons in the tissues of the tissues, images of brain tissues can be created.

In figure 1, the damaged areas of brain tissue due to diseases such as Alzheimer's are shown in magnetic resonance imaging of the brain and are distinguished by an axial area with yellow lines. One way to diagnose diseases such as Alzheimer's and Alzheimer's disease plaques with magnetic resonance imaging of the brain is to use methods such as image processing and methods such as machine learning and deep learning. In order to be able to identify plaques of Alzheimer's patients in magnetic resonance imaging of the brain, zoning methods are needed in the images. Zoning methods are an attempt to separate different types of brain tissue and try to isolate damaged areas of brain tissue from healthy areas. According to the figure 1, it is observed that first the magnetic resonance images of the brain are considered as input and then the images are pre-processed such as normalization. In the third phase, the image zoning is done normally and finally the important features of the image are extracted. So far, several methods have been proposed to diagnose Alzheimer's disease using image processing and data analysis methods, and most studies have been performed using in-depth learning because these methods have high accuracy in data analysis. Some sources, such as (Day et al., 2022), use data collected over a period of time to diagnose Alzheimer's disease in patients, but these methods are prone because they use most statistical and non-visual data. On the other hand, the statistical population of these methods is limited and Alzheimer's disease can be misdiagnosed with other diseases. In some studies, such as research (Salehi et al., 2020), a combined method based on deep learning and machine learning has been used to diagnose Alzheimer's disease.

Experiments, on the other hand, show that Kapoor entropy is more accurate for the multi-level threshold of the color image. In the study (Shanker & Bhattacharya, 2020) in 2020, they introduced a computer-aided automation system for classifying MR images using texture features and gravitational search algorithms. Nowadays, segmenting and classifying magnetic resonance imaging images of the brain is an important and challenging task for radiologists, and conventional methods for analyzing brain images are time-consuming and inaccurate in decision making. Therefore, to overcome these limitations, a computer-aided automation detection system has been proposed for accurate classification of normal and abnormal brain MR images. The proposed system has the ability to assist radiologists in detecting abnormalities in brain MR images in the early stages of the abnormality. In this study, to improve the quality of images before segmentation, histogram adjustment with limited contrast has been used. The division of the region of interest is obtained using the Otsu multi-level threshold algorithm. In addition, the proposed system selects the most important and relevant features from the contextual and multimedia features. Multi-solution properties are extracted using discrete wavelet transform, fixed wavelet transform and fast discrete curve conversion. In addition, a binary and local pattern is used to extract texture properties from images. These features are used to classify brain MR images using a nutritional neural network

classifier in which various meta-heuristic optimization algorithms such as genetic algorithm, particle optimization, gravitational search algorithm and gravitational search algorithm are improved. Error reduction used.

3. Methodology

In this paper, a new method based on Harris hawk's optimization method is used to feature the selection of the Alzheimer's MRI image. This algorithm is inspired by nature and it uses the behavior of this bird. There are some behaviors of this bird that use to find the best-optimized value. In slow siege behavior, the fast jumps of each eagle slowly fly around the prey and move towards the prey at a suitable opportunity. It moves slowly towards the prey. In eagle optimization algorithms, each eagle can make decisions according to the gathering center of other eagles and determine their center of gravity. The desired behavior for moving an eagle with the help of the mean point can be seen in Figure 2, in which each eagle uses the average population position and its optimal position to approach the prey:




Figure 2: Fast dive behavior with the help of a spot point in the Eagle optimization algorithm

By repeating the eagle optimization algorithm consecutively, the position of the eagles and the rabbit or the current optimal answer is constantly updated, and finally, in the last iteration, the prey position is extracted as the optimal answer. Studies and experiments show that their proposed algorithm is more accurate than genetic algorithm, particle optimization algorithm, glow worm algorithm, bat algorithm, biogeography algorithm, cuckoo search and differential evolution.

An example of the inputs considered in this study is the following data shown in Figure 3 and Figure 4 in the DICOM VIEWER environment.




Figure 3. Data selection in the DICOM VIEWER environment



Figure 4. View of data in DICOM VIEWER environment

The simulation will be performed in MATLAB version 2021b and will be performed in a system with 7-core processor specifications with 6 MB of cache and 3.6 MHz and 8 GB of memory in Windows 10. When the simulation is performed, all OASIS-3 data are trained and tested using the proposed method. For visualization, a sample of images is shown to examine the results of the proposed approach step by step. First, an input image like Figure 5 is given to the system.




Figure 5. Input image

It is necessary to first make an initial noise reduction in all OASIS-3 data images, using a middle filter in which the image is read in rows, columns and diagonally without any repetition to reduce noise. The schematic of this output is shown in Figure 6.




Figure 6. Application of noise reduction algorithm with middle filter in linear, columnar and diagonal without repetition

4. Conclusion

The main issue of this research is how to use magnetic resonance imaging to accurately identify the affected areas of Alzheimer's disease. The issue can be considered from two aspects. The first aspect of the problem is the nature of the classification and it must be determined which image has the symptoms of Alzheimer's disease and which image does not have the symptoms of Alzheimer's disease.


References

- Breijyeh, Z., & Karaman, R. (2020). Comprehensive review on Alzheimer's disease: Causes and treatment. *Molecules*, 25(24), 5789.
- Day, B. L., Ocal, D., Peters, A., Bancroft, M. J., Cash, D., Kaski, D., Crutch, S. J., & Yong, K. X. X. (2022). Altered visual and haptic verticality perception in posterior cortical atrophy and Alzheimer's disease. *The Journal of Physiology*, 600(2), 373–391.
- Salehi, A. W., Baglat, P., & Gupta, G. (2020). Alzheimer's disease diagnosis using deep learning techniques. *Int. J. Eng. Adv. Technol.*, 9(3), 874–880.
- Shanker, R., & Bhattacharya, M. (2020). An automated computer-aided diagnosis system for classification of MR images using texture features and gbest-guided gravitational search algorithm. *Biocybernetics and Biomedical Engineering*, 40(2), 815–835.
- Soininen, H., Puranen, M., & Riekkinen, P. J. (1982). Computed tomography findings in senile dementia and normal aging. *Journal of Neurology, Neurosurgery & Psychiatry*, 45(1), 50–54.
- Tartaglia, M. C., Rosen, H. J., & Miller, B. L. (2011). Neuroimaging in dementia. *Neurotherapeutics*, 8(1), 82–92.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Machine Learning and Metaheuristic based for Alzheimer's Disease Diagnosis

Akbar, O. A.^a, Lopez-Guede, J. M.^b, Alyaqoobi, H. I.^c, Rahebi, J.^d

^a Systems and Automatic Control Department, University of the Basque Country (UPV/EHU), Spain

^b Systems and Automatic Control Department, University of the Basque Country (UPV/EHU), Spain

^c Systems and Automatic Control Department, University of the Basque Country (UPV/EHU), Spain

^d Department of Software engineering, Istanbul Topkapi University, Istanbul, Turkey.

To cite this article: Akbar, O. A., Lopez-Guede, J. M., Alyaqoobi, H. I., Rahebi, J. 2022. Machine Learning and Metaheuristic based for Alzheimer's Disease Diagnosis. XVII Simposio CEA de Control Inteligente.

Abstract

Alzheimer's disease was first described in 1907 by Alois Alzheimer. It is a progressive neurological disorder with a gradual onset of dementia. Although Alzheimer's was initially a rare disease, it is now one of the most common diseases in the elderly and is the fourth most common cause of death in this age group in the rankings. In this paper, we present a new methods of group intelligence to improve image threshold in Alzheimer's diagnosis. The challenge of this method is the uncertainty of meta-heuristic methods in solving optimization problems.

Keywords: Alzheimer's Disease Diagnosis, Machine Learning, Feature selection, Fishier Mantis Optimizer (FMO).

1. Introduction

Spontaneous activities of Tosa straw rs-fMRI are measured, summarized by a number of distinct resting-state networks (RSNs) with similar temporal properties (Moussa et al., 2012). SMRI-based images have been used (Howseman & Bowtel, 1999)(Moussa et al., 2012)(Wolz et al., 2011). In sMRI images, structural adaptations refer to physical or synaptic networks that form a bunch of neurons or neural elements together.

Graph theory is a good tool for studying the organization of brain network topology based on rs-fMRI data. In addition to the power of interconnection, the study of the brain network can also determine the directions of interconnection. Graph theory is a method that analyzes the networks in the brain and examines them and has many applications in identifying different diseases (Supekar et al., 2008). Recent studies have shown that the combination of graph theory and machine learning methods based on functional images leads to accurate isolation of Alzheimer's patients (Armstrong et al., 2016).

The use of structural images in the diagnosis of Alzheimer's disease has been the focus of researchers from the past to the present. However, the use of these images has been problematic for researchers due to the limited extraction features and the subsequent accuracy of the prediction. In this article, we try to achieve an acceptable percentage of accuracy

by extracting the most and most effective features from these images by using sMRI images.

2. Literature review

In (Wolz et al., 2011), Mr. Cheng et al. Used a combination of sMRI and PET images and experimental samples taken from cerebrospinal fluid to isolate patients who developed Alzheimer's disease and patients who remained mildly disturbed. In this study, an attempt was made to improve the prediction accuracy by combining information containing several diagnostic methods. Separation accuracy was reported at 73% in this paper.

No studies have been performed on the prediction of Alzheimer's disease based on rs-fMRI-based Alzheimer's disease. Rs-fMRI imaging is a powerful tool for mapping and evaluating the function of different brain networks (Van Den Heuvel & Pol, 2010). In recent years, many resistances to the diagnosis of Alzheimer's disease based on this type of imaging have been examined (Khazaei et al., 2016)(Khazaei et al., 2015)(Liu et al., 2012)(Greicius et al., 2003).

In (Khazaei et al., 2016)(Zhang et al., 2012), Mr. Khazaei studied the basics of diagnosing and isolating Alzheimer's patients from normal people and people with mild behavioral disorders. In this study, Mr. Khazaei tried to create an automated method for separating these three groups of samples by using the graph theory method based on functional images.

The most important feature of this paper is to provide an accurate and automated method for predicting Alzheimer's disease based on Garaf's theoretical method and structural statistical estimates of the brain. In addition, in this study, the features that have the highest separation power between groups are found using soft computational algorithms. Another innovation of this study is the use of an rs-fMRI and its combination with sMRI in which it is from two different atoms to define network nodes and structural areas of the brain. Previous AD or MCI studies have used structural equations, which provide a segmentation based on overlapping structural units. Brain segmentation based on structural features cannot adequately represent the functional network of the brain. This study presents a segmentation based on 111 general functional regions for rs-fMRI data. In the feature selection section, for the first time in the prediction of Alzheimer's disease, the creation of a single and two-objective algorithm for selecting the best features has been used and good results have been obtained.

It is a general term that refers to the reduction of the ability of "dementia" or mental, to the extent that it interferes with daily life (memory loss is a clear symptom of this disease). Alzheimer's is the most common form of dementia (Con Hokke et al., 2012). In general, there are several factors in the incidence of Alzheimer's disease, which are shown in Figure 1:




Fig. 1. Different factors in the incidence of Alzheimer's disease (Breijyeh & Karaman, 2020)

According to the above figure, it can be said that there are various factors in the incidence of Alzheimer's disease, including lifestyle, cardiovascular disease, head or brain surgery, age, gender, genetic factors, infection, environmental factors. He mentioned underlying diseases such as diabetes and so on. In Alzheimer's disease, spherical protein structures form outside the neurons in some areas of the brain, as well as filamentous protein structures in the cell body of neurons. The spherical protein structures that result from Alzheimer's disease are called amyloid bodies. In Alzheimer's disease, brain tissue is damaged and parts of nerve neurons become deformed. Figure 1 shows the structure of brain tissue that is asymptomatic of Alzheimer's and it can be seen that the size of the gray area of the brain is normal in a healthy person. For a better comparison in Figure 2, it can be seen that the structures of a person with Alzheimer's disease are damaged, the gray

area of the brain is reduced, and areas of plaque appear in nerve neurons:




Fig. 2. The structure of a healthy person's brain and nerve cells (Breijyeh & Karaman, 2020)

3. Methodology

Mantis is known as one of the predatory insects. Moths are green, locust-like insects with long legs, large heads, and two pairs of wings (Figure 3, a). Mantis lives in the tropics, and some live in temperate regions. When the mantis stands quietly, he holds his front legs forward like two hands, and in this position, it is like reciting a prayer. After mating, the female moth hunts and feeds on the opposite sex. Some types of mantis can rotate their head at an angle of 180 degrees and use it to scan the environment. Most of these insects live in the foliage of trees and disguise themselves as small branches to deceive their prey. Mantis is arthropod hunters. Most mantis is ambush hunters who feed only on the live prey available to them. They disguise themselves and stay still and wait for the victim to approach. They can chase their victim with slow movements. Sometimes mantis eats smaller ones. They also eat small vertebrates such as lizards, frogs, fish, and birds. A type of mantis is famous for its strange behavior in hunting fish. These fish-eating moths have been hiding in a pond continuously for five days, waiting to catch a fish at the right time. The mantis can hunt two ebony fish every day. They can catch up to nine fish in five days and eat their prey over time. Figure 3, b, shows a fish-eating mantis camouflaging and hunting fish:




Fig. 3. a) mantis and b) fish-eating mantis

The fishier mantis has a set of intelligence hunting behaviors. These insects can consider several situations and move in these situations. The optimal position for the mantis is the location of the prey or fish. The fishier mantis also has homogenous behaviors. The fishier mantis has behaviors in preparation for attacking or giving up hunting in its current state, which is described below.

In the fishier mantis optimizer algorithm, a fishier mantis first considers a number of random situations in the problem space.

Each of these situations is assumed to be a solution, and the fishier mantis tries to put you in a position that is closer to the optimal solution. The initial positions or solutions in Equation (1) are formulated and using the objective function, each of the situations can be evaluated according to Equation (2):

$$Mantis = \begin{bmatrix} X_{11}, X_{12}, X_{13}, \dots, X_{1d} \\ X_{21}, X_{22}, X_{23}, \dots, X_{2d} \\ X_{31}, X_{32}, X_{33}, \dots, X_{3d} \\ \vdots \\ X_{n1}, X_{n2}, X_{n3}, \dots, X_{nd} \end{bmatrix} \quad (1)$$

In this equation, X_{ij} is the solution of its i -th solution and then its j -th. In the first iteration, a random population is created from solutions such as Equation (2) (Patibandla & Narayana, n.d.):

$$F(Mantis) = \begin{bmatrix} Fitness(X_{11}, X_{12}, X_{13}, \dots, X_{1d}) \\ Fitness(X_{21}, X_{22}, X_{23}, \dots, X_{2d}) \\ Fitness(X_{31}, X_{32}, X_{33}, \dots, X_{3d}) \\ \vdots \\ Fitness(X_{n1}, X_{n2}, X_{n3}, \dots, X_{nd}) \end{bmatrix} \quad (2)$$

In the equation, $Mantis$ and $F(Mantis)$ are the matrices of solutions or situations and their degree of competence, respectively. In the equation in question, X_i is equal to the last i , and this solution has d dimensions such as $X_{i1}, X_{i2}, X_{i3}, \dots, X_{id}$. Equation (3) is used to create random solutions:

$$X_i = L + (U - L) \times rand(0,1) \quad (3)$$

In this equation, $rand(0,1)$ is a random vector between zero and one with a uniform distribution. L and U are the lower and upper ranges of the problem space, respectively.

In the proposed method, several innovations for the diagnosis of Alzheimer's disease are presented based on magnetic resonance imaging of the brain. In the proposed method, two layers of classification and zoning are considered for images. In the zoning layer, Atsu multi-level thresholding is used to find damaged areas of brain tissue, and in order to reduce the time of implementation of this algorithm in high-thresholds, new group intelligence methods introduced in 2021 The presented is used as a mantis algorithm.

The reason for using Fishier Mantis Optimizer algorithm is that the algorithm is more accurate in finding optimal solutions due to its strong modeling. Several stages are also used in the classification phase. First, with the improved methods of the middle filter, the noise of the magnetic resonance images of the brain is eliminated and the feature selection phase is performed with the mantis algorithm, and then the images are considered as input of several learning methods. Images can be classified into malignant and benign.

4. Conclusion

In this paper a new method based on group learning that used the Fisher mantis is presented to Alzheimer disease diagnosis. This algorithm used from the inspired nature of the fisher mantis behavior. In this paper, the Alzheimer disease diagnosis presented based on magnetic resonance imaging of the brain. In the proposed method, Otsu multi-level thresholding is used to find damaged areas of brain tissue, and this algorithm is used in order to reduce the time of implementation.

References

- Armstrong, C. C., Moody, T. D., Feusner, J. D., McCracken, J. T., Chang, S., Levitt, J. G., Piacentini, J. C., & O'Neill, J. (2016). Graph-theoretical analysis of resting-state fMRI in pediatric obsessive-compulsive disorder. *Journal of Affective Disorders*, 193, 175–184.
- Breijyeh, Z., & Karaman, R. (2020). Comprehensive review on Alzheimer's disease: Causes and treatment. *Molecules*, 25(24), 5789.
- Co n o e .E. Elting . . inen rg .A. . n S ieten .C. (2012). Genetics of dementia: update and guidelines for the clinician. *American Journal of Medical Genetics Part B: Neuropsychiatric Genetics*, 159(6), 628–643.
- Day, B. L., Ocal, D., Peters, A., Bancroft, M. J., Cash, D., Kaski, D., Crutch, S. J., & Yong, K. X. X. (2022). Altered visual and haptic verticality perception in posterior cortical atrophy and Alzheimer's disease. *The Journal of Physiology*, 600(2), 373–391.
- Greicius, M. D., Krasnow, B., Reiss, A. L., & Menon, V. (2003). Functional connectivity in the resting brain: a network analysis of the default mode hypothesis. *Proceedings of the National Academy of Sciences*, 100(1), 253–258.
- Howseman, A. M., & Bowtel, R. W. (1999). Functional magnetic resonance imaging: imaging techniques and contrast mechanisms. *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, 354(1387), 1179–1194.
- Khazae, A., Ebrahimzadeh, A., & Babajani-Feremi, A. (2015). Identifying patients with Alzheimer's disease using resting-state fMRI and graph theory. *Clinical Neurophysiology*, 126(11), 2132–2141.
- Khazae, A., Ebrahimzadeh, A., & Babajani-Feremi, A. (2016). Application of advanced machine learning methods on resting-state fMRI network for identification of mild cognitive impairment and Alzheimer's disease. *Brain Imaging and Behavior*, 10(3), 799–817.
- Liu, Z., Zhang, Y., Bai, L., Yan, H., Dai, R., Zhong, C., Wang, H., Wei, W., Xue, T., & Feng, Y. (2012). Investigation of the effective connectivity of resting state networks in Alzheimer's disease: a functional MRI study combining independent components analysis and multivariate Granger causality analysis. *NMR in Biomedicine*, 25(12), 1311–1320.
- Moussa, M. N., Steen, M. R., Laurienti, P. J., & Hayasaka, S. (2012). *Consistency of network modules in resting-state FMRI connectome data*.
- Patibandla, R. S. M. L., & Narayana, V. L. (n.d.). Computational Intelligence Approach for Prediction of COVID-19 Using Particle Swarm Optimization. In *Computational Intelligence Methods in COVID-19: Surveillance, Prevention, Prediction and Diagnosis* (pp. 175–189). Springer.
- Salehi, A. W., Baglat, P., & Gupta, G. (2020). Alzheimer's disease diagnosis using deep learning techniques. *Int. J. Eng. Adv. Technol*, 9(3), 874–880.
- Supekar, K., Menon, V., Rubin, D., Musen, M., & Greicius, M. D. (2008). Network analysis of intrinsic functional brain connectivity in Alzheimer's disease. *PLoS Computational Biology*, 4(6), e1000100.
- Van Den Heuvel, M. P., & Pol, H. E. H. (2010). Exploring the brain network: a review on resting-state fMRI functional connectivity. *European Neuropsychopharmacology*, 20(8), 519–534.
- Wolz, R., Julkunen, V., Koikkalainen, J., Niskanen, E., Zhang, D. P., Rueckert, D., Soininen, H., Lötjönen, J., & Initiative, A. D. N. (2011). Multi-method analysis of MRI images in early diagnostics of Alzheimer's disease. *PloS One*, 6(10), e25446.
- Zhang, D., Shen, D., & Initiative, A. D. N. (2012). Predicting


Akbar, O. A. et al. / XVII Simposio CEA de Control Inteligente (2022)

future clinical changes of MCI patients using longitudinal and multimodal biomarkers. *PloS One*, 7(3), e33182.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Intelligent battery management implementation for electric vehicles

Núñez-Donoso, F.A.^{a,*}, Lopez-Guede, J.M.^b

^a *Technological University of Chile INACAP, Department of Innovation, Osorno, Chile.*

^b *University of the Basque Country (UPV/EHU), Vitoria-Gasteiz, Spain.*

To cite this article: Núñez-Donoso, F.A., Lopez-Guede, J.M., 2022. Intelligent battery management implementation for electric vehicles. XVII Simposio CEA de Control Inteligente.

Resumen

Mediante la disposición de un laboratorio para el manejo de baterías en vehículos eléctricos, los autores presentan una experiencia universitaria chilena. Se presentan los diversos compromisos académicos e institucionales, para desarrollar una metodología de optimización y cálculos de eficiencia energética en baterías de vehículos eléctricos utilizados para el reparto de productos de última milla. Los ejercicios del mismo centro de investigación han ayudado a ver la importancia de la asociación directa en la unión de negocios, academia y gobiernos locales en Osorno, Chile.

Palabras clave: electromovilidad, reparto de última milla, financiamiento para investigación.

Intelligent battery management implementation for electric vehicles

Abstract

Through the provision of a laboratory for the management of batteries in electric vehicles, the authors present a Chilean university experience. The various academic and institutional commitments are presented, to develop an optimization methodology and energy efficiency calculations in electric vehicle batteries used for the distribution of last mile products. The exercises of the same research center have helped to see the importance of direct association in the union of business, academia, and local governments in Osorno, Chile.

Keywords: electromobility, last-mile delivery, research financing

1. Introduction

Since 2011, multiple million electric vehicles have been sold worldwide, with China, the US, and Japan representing the more significant part of this interest (Figure 1). Electric vehicles ought to turn into the global norm in providing new vehicles by 2030 [1]. Different countries and organizations are steering steps toward this path: Manufacturers, for example, Volvo, declared that they would never again deliver vehicles involving petroleum or diesel as their only fuel from 2019 [2]. European urban areas fixed traffic limitations for the focal point of their urban areas except for electric vehicles and proposition motivating forces, for example, free leaving for them; and nations like Norway, UK, and France plan not to acknowledge the commercialization of inside burning vehicles from the year 2025, 2040 and 2040 individually [3]. As per the

Chilean Ministry of Energy (MEC), north of 300 electric vehicles has been added to the Chilean vehicle armada by 2017 [4]. It is assessed that there will be almost 5 million electric vehicles in the country by 2050, addressing 40% of the all-out market. The MEC introduced its electric portability system for Chile in August 2017 to drive this innovative development. Its objectives incorporate diminishing CO₂ emanations to meet the global commitments of the marked environment insurance strategy, advancing energy productivity and the set energy-saving targets and making the vehicle area more serious. The vehicle area is a significant player in the public economy, representing 33% of the country's energy utilization and 20% of its CO₂ emanations [5].

This work seeks the assembly of new advances and scholarly projects. As quality exploration subsidizing is scant in emerging nations, it is of central interest to make a great

illustration of different positive results from a solitary financing authority.




Figure 1. Global EV sales growth in last decade [6].

The introduced scholarly encounters should fill the exploration need and, by implication, reach out to proficient execution and local area manageability programs. This paper sums up the exploration offices and the principal exercises coming about because of the preliminary examination work on EV retrofits and the battery proficiency of the executives. From that point onward, extended scholarly utility is shown through standard profession programs, supplemented by the understudies' close cooperation in the examination research facility.

2. Last-mile delivery problem.

The limits of independence are yet expected to be met for the business utilization of electric vehicles. Once more, the energy stockpiling innovation in batteries should be improved for the conveyance of items and administrations on these vehicles to be dependable [7].

The item conveyance market has developed consistently since web-based business in the last part of the 1990s. Web organizations like eBay or Amazon have become quicker than retail goliaths like JCPenney or Walmart, which base their business on the crowd entering their stores in shopping centers [8]. The new plan of action of these arising associations relies upon tremendous circulation places and the resulting appropriation of their buy solicitations too far off beneficiaries. These organizations have an advanced plan of action, however their dispersion and conveyance organization to the end client, known as Last-Mile Delivery (LMD) is not completely tackled at this point. Their endeavors to get packages to their clients inexpensively via mail, hikers, bikes, and different means, for example, flying robots are notable, in any event, offering free delivery as an optimal deal.

The primary advances in electric vehicles deals have been focused on traveler or sports vehicles, drove by the American organization Tesla. This organization has demonstrated starting around 2008 that, an electric vehicle can be a favored choice over a gas-powered motor vehicle, inciting the other

makers to contend in this fragment and shield their pieces of the pie [9]. In any case, the deals of heavier vehicles are gradually developing behind. In this fragment of light cargo vehicles, lies a chance for innovative work.

At long last, there is an association among electromobility and LMD as a future chance for Chile's vehicle industry.

3. Academia collaboration

There is anything but a current car fabricating industry in Chile. There are unfamiliar get-together plants in Latin America that need extreme human preparation and innovative experience, aggregated more than a hundred years of improvement from European and North American brands [10]. This absence of Chilean information in the auto business addresses a critical hindrance to the section that can be presently tended to by neighborhood advanced education schools, with demonstrated R&D ability to review and carry out these innovations to close existing holes in their understudies.

Scholarly groups from University of Chile and INACAP can address the electromobility theme through research on energy capacity in its batteries as a component of the LMD plan of action. Given the condition of charge of the battery and the support of its utilization time, through a fleet, the board framework for electric vehicles empowers the enhanced conveyance of items. Another workroom is expected to oblige the examination group and gear at the Osorno INACAP grounds (Figure 2). Each square foot of property is sought after in an all-around packed building. Standard classrooms and labs for understudies are essential for the establishment. In any case, this administration-supported research project, joined by massive speculation from conspicuous nearby business firms, put suitable accentuation on looking for the ideal area [11].



Figure 2. Initial workroom for e-mobility.

Carrying out an e-portability standard lab addresses a vast improvement and challenge to the customary office. The new office is essential for the automotive scholastic field currently present nearby, in standard gas-powered motor support or auto mechanic's shop. A piece of the new lab comprises an encased space with new electrical instrumentation for battery the board and DC frameworks, detached devices, a vehicle lift crane, and different instruments, as in figure 2 shown. As per neighborhood norms, security rules are executed with outlined regions for electrical and mechanical techniques. While

working with electric battery charging stations and raised vehicles, wellbeing methodology is a critical concern while working with young students (Figure 3).




Figure 3. Electric vehicle garage setting.

4. Continuous work

This new system for executing scholarly examination, pointed toward receiving however many comparative rewards as could reasonably be expected from a special open door, has made a beginning stage for formal investigations on electric versatility. For this situation, INACAP is sending off new vocation courses spent significant time in electric versatility, and this task surely assists with setting its very own illustration.

This undertaking suggests beginning conversation starters for conceivable undergraduate research subjects on charging frameworks for electric vehicles through sustainable power lattice associations in other related regions. Automobile fabricating methods by changing fuel burning over completely to electric vehicles and natural procedures executing e-portability are valuable yearnings for polluted urban areas like Osorno.

5. Conclusions

The paper introduced, addresses a business-related accomplishment of a college grounds in the southern part of Chile in understanding numerous advantages from a solitary subsidizing. In a concentrated nation where most speculations are made in Santiago, the capital of Chile, the included venture helps set an illustration of energy-proficient innovation rehearses. With an e-portability lab execution in an unassuming community that could somehow, or another have not been the best option. This execution might be applicable to the neighborhood economy and general local area, who could feel nearer to the advantages of future environmentally friendly power frameworks connected with e-versatility undertakings, for example, sunlight based, wind, and battery stockpiling frameworks.

Proceeding with training in innovative fields is currently a reality for far off studies. Corresponding exercises got from an administration supported venture might help advanced education foundations. Prepared employees, who approach subsidizing for state-of-the-art innovation research on energy-

related issues, give a wellspring of financing to institutional financial backers and new offices.

To act as an illustration of a drawn-out scholarly system, the future exercises of the new lab might relate to exploration and understudy work programs. Extended research subsidizing in cutting edge regions for unassuming community scholastic establishments is vital for non-industrial nations. Nearby organizations intrigued by hardware productivity and environmentally friendly power hotspots for modern cycles or vehicle transportation are presently a nearer reality.

Acknowledgements

Much valued help for FONDEF ID 18/10379 by the endorsement of the Concurso Idea de Investigación y Desarrollo 2018 call by the Chilean National Commission for Research in Science and Technology CONICYT.


References

- [1] World Economic Forum, 2017. "Countries are announcing plans to phase out petrol and diesel cars."
- [2] NBC news, 2017 "Volvo Is First Automaker to Offer Electric or Hybrid Only".
- [3] United Kingdom Government, 2018. "Electric Vehicles," City of Westminster.
- [4] Ministerio de Energía, Gobierno de Chile, 2017. "Chile ya se adapta a la Electromovilidad."
- [5] Revista Biobío, 2017. "Chile tendrá casi 5 millones de autos eléctricos en 2050: el 40% del parque vehicular". Chile.
- [6] Global EV Sales for 2021
- [7] Jensen, A. F., Mabit, S. L., 2017. "The use of electric vehicles: A case study on adding an electric car to a household," Transp. Res. Part A Policy Pract., vol. 106, pp. 89–99.
- [8] CNN, 2017 "Amazon vs. Walmart: Rest of retail fights for crumbs."
- [9] Inc.com, 2017. "Tesla Has a New Competitor in the World's Biggest Electric Car Market."
- [10] Desrueda, 2018. «blog.desrueda.com,» "Sabías que en Chile se fabricaron automóviles conócelos aquí"
- [11] Comisión Nacional de Investigación Científica y Tecnológica CONICYT, 2019. "Inauguran Primer Laboratorio de Electromovilidad en la Región de Los Lagos", Fondo de Fomento al Desarrollo Científico y Tecnológico FONDEF



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Optimización de trayectorias para AGVs mediante algoritmos genéticos.

Bayona, E.^{a,*}, Sierra-García, J.E.^b, Santos, M.^c

^a Departamento de Ingeniería, Electromecánica, Universidad de Burgos, Burgos, España.

^b Departamento de Ingeniería, Electromecánica, Universidad de Burgos, Burgos, España.

^c Instituto de Tecnología del Conocimiento, Universidad Complutense de Madrid, Madrid, España.

To cite this article: Bayona, E., Sierra-García, J.E., Santos, M.. 2022. Trajectory optimisation for AGVs using genetic algorithms. XVII Simposio CEA de Control Inteligente.

Resumen

La búsqueda de la eficiencia y la mejora continua de los procesos productivos está aumentando su automatización. Los vehículos de guiado automático (AGV) usados para transporte, son elementos clave a la hora de cumplir esta función, siendo fundamental el desarrollo y mejora de sus sistemas de navegación y posicionamiento. Así, en este trabajo se propone el uso de una técnica evolutiva, los algoritmos genéticos (AG), con el fin de obtener los parámetros óptimos de un método de generación de trayectorias. Se utiliza un modelo de mapa de ocupación para el diseño del entorno con el fin de verificar posibles eventos de colisión con el AGV. Se simulan diferentes escenarios donde se busca optimizar la longitud de la trayectoria generada evitando colisiones. Los resultados de la simulación muestran que el algoritmo es capaz de minimizar la longitud de las trayectorias generadas evitando las posibles colisiones.

Palabras clave: Soft Computing, Algoritmos Genéticos, Vehículos Guiados Automáticamente (AGV), Industria 4.0, Trayectorias.

Optimization of trajectory generation for automatic guided vehicles by genetic algorithms

Abstract

Continuous improvement of industrial and production processes for efficiency optimization has led to an increase in the need for automatization. Automatic guided vehicles (AGV) are key transport elements when it comes to fulfilling this function, as well as the development and improvement of their navigation and positioning systems. Thus, in this work the use of a Soft Computing evolutive technique, genetic algorithms (GA), is proposed in order to obtain the optimal parameters of a trajectory generation method. An occupancy map model for the environment layout is used in order to check collision events with the AGV. Different scenarios have been simulated to optimize the trajectory length avoiding collisions if possible. Simulation results show that the algorithm is able to minimize the length of the path successfully.

Keywords: Soft computing, Automatic Guided Vehicle (AGV), Genetic Algorithms (GA), Industry 4.0, Trajectories.

1. Introducción

Los procesos productivos están en constante cambio y estudio para evaluar su eficiencia y posibilidad de optimización tanto en términos de productividad como de seguridad. De esta necesidad de mejora continua surge la intención de automatizar partes de un proceso donde la presencia física de una persona no es necesaria. Un aspecto clave de los procesos productivos es la intralógica o logística interna, para ello

existen diferentes tipos de soluciones que permiten automatizar el transporte interno de materia prima, productos, mercancías, etc. (Echeverri and Escolar, 2012), (Vis, 2006). Los vehículos de guiado automático (AGV) cumplen con esta función, y tienen un campo de aplicación amplio en constante aumento. Los sectores comerciales en los que se puede utilizar AGV incluyen terminales de transporte de contenedores, líneas de producción, almacenes logísticos, agricultura, operaciones militares, gestión de la salud, entre otros (Bechtsis *et al.*, 2017), (Bostelman and Messina, 2016). Los AGV son robots móviles

capaces de auto-dirigirse dentro de un entorno siguiendo caminos físicos o virtuales, y aportan una notable mejora en los procesos productivos, reduciendo costes, aumentando la producción y optimizando la seguridad en los mismos (Espinosa and Sierra-García, 2021).

Mediante el uso de diferentes tecnologías de sensado y monitorización del movimiento, los AGV son capaces de realizar diferentes funciones en paralelo a sus principales funciones de movimiento, como cargar y descargar mercancías o interactuar con otros agentes dentro de su entorno operativo, como seres humanos u otros robots. Utilizando diferentes sensores de navegación y guiado para obtener información de su estado, los AGV son capaces de usar controladores (normalmente PID) para seguir caminos marcados y trayectorias correctamente (Zhang *et al.*, 2018). Algunos trabajos anteriores se han centrado en la definición de las curvas de movimiento que definen esas trayectorias (Farouki, 2000).

Para generar las trayectorias que debe seguir el AGV, en este trabajo se utilizan métodos numéricos basados en fórmulas de Frenet-Serret. Este método ajusta una curva continua polinómica de cuarto y quinto orden de forma suave a lo largo de una serie de puntos de referencia previamente definidos. Estos puntos de paso determinan la forma final de la trayectoria. Reducir la longitud del trayecto, reduciendo así el tiempo de viaje, tiene un impacto directo en los tiempos de producción y por tanto en la productividad de los procesos donde se implementan soluciones de transporte automatizado con estos AGVs. Por ello, este trabajo se centra en la optimización mediante algoritmos genéticos del trayecto a seguir por el AGV hasta llegar a un destino sorteando obstáculos.

Estas técnicas evolutivas ya se han utilizado con éxito en trabajos anteriores. En (Larrazabal and Peñas, 2016) los algoritmos genéticos se utilizan para optimizar el control del timón de un barco no tripulado. En (Alouache and Wu, 2018), se utilizan para mejorar el seguimiento de una trayectoria de un robot móvil. En (Abajo *et al.*, 2021) se propone un método de optimización para el ajuste de un controlador PID de AGV que ordena al robot que siga diferentes trayectorias.

Las técnicas de *Soft Computing* se han venido aplicando con éxito para modelar y controlar sistemas físicos (Sierra-García and Santos, 2021), (Santos and Cantos, 2010). En este trabajo, se utilizan algoritmos genéticos para optimizar la ruta del AGV desde un punto inicial hasta un punto final. El algoritmo tiene en consideración si existe un evento de colisión entre el AGV y algún elemento del entorno físico. La función de coste está diseñada con dos objetivos en mente: minimizar la longitud total del camino entre los puntos inicial y final, y evitar que el AGV colisione con los elementos en el mapa de ocupación. Por lo tanto, la trayectoria con el valor de función de coste más bajo será aquella más corta posible que evita colisiones con el entorno. Esto puede ser de gran utilidad en la automatización del proceso de generación de rutas en una implementación de AGV en un escenario industrial.

El resto del documento está organizado de la siguiente manera. La sección 2 describe el modelo utilizado para simular el espacio de trabajo del AGV utilizando un mapa de ocupación. La Sección 3 explica la metodología y el algoritmo genético implementado para la optimización del proceso de generación

de trayectorias. En la Sección 4 se resumen y presentan los resultados de las simulaciones bajo tres escenarios diferentes. La última sección presenta las conclusiones y trabajos futuros.

2. Modelado del entorno de trabajo

La definición del entorno de trabajo que el algoritmo tiene en cuenta para detectar posibles colisiones se realiza mediante un mapa de ocupación binaria. Este tipo de mapas se utilizan para modelar y visualizar el espacio de trabajo del robot, creando una representación espacial de la ubicación de los obstáculos como una cuadrícula discreta. Las cuadrículas de ocupación se utilizan habitualmente en robótica para aplicaciones de mapeo y planificación de rutas. Cada celda de la cuadrícula tiene un valor que representa su estado de ocupación. La representación matemática de la cuadrícula de ocupación se muestra en (1)

$$a_{GRID} = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1m} \\ a_{21} & a_{22} & \dots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nm} \end{pmatrix} \quad (1)$$

Donde (n,m) son números enteros que representan las dimensiones del espacio de trabajo. Si una localización está ocupada en el mapa, se representa mediante un 1, si no lo está, se representa con un 0, tal y como se muestra en (2)

$$a_{nm} \in \mathbb{N} : a_{nm} = \begin{cases} 1 & \text{Occupied Location} \\ 0 & \text{Free Location} \end{cases} \quad (2)$$

Este mapa se utiliza como restricción en el método de generación de la trayectoria, comparando los puntos de la misma con cada posición del mapa de ocupación. Cuando un punto de la trayectoria $t(x,y)$ se encuentra con una celda ocupada del mapa a_{nm} , se considera un evento de colisión y la trayectoria no será factible.

$$\text{For } x,y \in t \mid \begin{cases} a_{xy} = 0 \Rightarrow \text{No Collision} \\ a_{xy} = 1 \Rightarrow \text{Collision} \end{cases} \quad (3)$$

3. Descripción del proceso de optimización de trayectorias a partir de algoritmos genéticos.

3.1. Metodología de optimización.

El objetivo del método de generación de trayectorias es obtener el camino continuo más corto que se ajuste a una serie de puntos de paso sin eventos de colisión. En este trabajo, los puntos de paso predefinidos son el punto de inicio y el punto final de la trayectoria. Los puntos de paso intermedios son determinados por el algoritmo genético para minimizar la longitud de la trayectoria, l_t , y evitar obstáculos. La arquitectura del método de generación de trayectorias que se utiliza se muestra en la Figura 1. El algoritmo es capaz de generar múltiples puntos de paso intermedios, pero en este

trabajo consideraremos solamente escenarios de simulación con un único punto de paso adicional.




Figura 1. Metodología de generación de funciones

La trayectoria generada viene dada por las ecuaciones de Frenet, que representan una curva plana en $\mathbb{R}^2$ donde el vector tangente T y el vector normal N satisfacen (4). Estas ecuaciones se conocen como ecuaciones de Frenet de una trayectoria (Alencar *et al.*, 2022).

$$\begin{cases} T'(s) = k(s)N(s) \\ N'(s) = -k(s)T(s) \end{cases} \quad (4)$$

Donde s es la distancia al origen de cada punto, k es la curvatura de la trayectoria a la distancia s , $T(s)$ es el vector tangente a la distancia s , $N(s)$ es el vector normal a la distancia s , y el símbolo $'$ denota el vector perpendicular.

Basándose en la definición de una curva de Frenet, la longitud del arco puede ser calculada en coordenadas cartesianas, donde la trayectoria será una curva plana en $\mathbb{R}^2$ con la forma $y = f(x)$ donde f es una función continua y diferenciable. La longitud de cada uno de los segmentos infinitesimales de la curva se expresan en (5).

$$ds = \sqrt{dx^2 + dy^2} = \sqrt{1 + \left(\frac{dy}{dx}\right)^2} dx \quad (5)$$

Esto lleva a la expresión matemática de la longitud del arco de la trayectoria calculada (s) basada en (5) y expresada en (6).

$$s = \int_{(x_i, y_i)}^{(x_f, y_f)} \sqrt{1 + \left(\frac{dy}{dx}\right)^2} dx \quad (6)$$

3.2. Algoritmo genético

Los algoritmos genéticos son una técnica computacional evolutiva usada en problemas de optimización. Se basa en la evolución de una población inicial de individuos. Su correcta codificación y la correcta elección de los operadores genéticos (mutación y cruce) son claves para la convergencia del algoritmo hacia la mejor solución (Abajo *et al.*, 2021).

Las posibles soluciones para este problema se definen como un vector de 3 componentes $[x, y, \theta]$, siendo x e y las coordenadas cartesianas de los puntos de paso intermedios de la trayectoria y θ su ángulo de entrada y salida. En este trabajo se considera únicamente un único punto de paso intermedio, aunque se podría considerar múltiples puntos si fuera necesario. Los dos primeros elementos pueden ser cualquier número entero dentro de las dimensiones del mapa de ocupación y el tercero es cualquier ángulo comprendido entre

$-\pi/2$ and $\pi/2$. Estas restricciones pueden expresarse formalmente en (7-9).

$$x \in [0, a_n] \quad (7)$$

$$y \in [0, a_n] \quad (8)$$

$$\theta \in \left[-\frac{\pi}{2}, \frac{\pi}{2}\right] \quad (9)$$

Si se considera $x = r \cos \theta$, $y = r \sin \theta$ en coordenadas polares, la longitud del arco de la trayectoria obtenida como solución se puede expresar en (10).

$$l_t = \int_{\theta_i}^{\theta_f} \sqrt{r^2 + \left(\frac{dr}{d\theta}\right)^2} d\theta \quad (10)$$

Por lo tanto, l_t es la variable a considerar por el algoritmo genético para la optimizar la trayectoria generada. Además para guiar al algoritmo genético hacia la solución óptima, se utiliza una función de coste que incluye el factor de colisión en el problema de optimización.

La función de coste se define en (11), como el producto entre la longitud de la trayectoria y el coeficiente de colisión C . Este coeficiente es 1 cuando no existen eventos de colisión y 1000 cuando sucede alguno de estos eventos, haciendo a la trayectoria no factible. Este coeficiente convierte a trayectorias más cortas que otras opciones en opciones no válidas debido a las colisiones con el mapa de ocupación. Las ecuaciones (11-12) definen la función de coste descrita y el valor del coeficiente de colisión.

$$f_{fitness} = l_t \cdot C \quad (11)$$

$$C = \begin{cases} 1, & \text{No collision Event} \\ 1000, & \text{Collision Event} \end{cases} \quad (12)$$

4. Simulación y resultados

Para las simulaciones del método de generación de trayectorias y su optimización se han usado las herramientas Matlab/Simulink. Se ha configurado un mapa de ocupación para verificar los eventos de colisión. Los puntos inicial y final y sus respectivos ángulos de salida y llegada se han fijado previamente. Asimismo se ha restringido el ángulo de entrada y salida del punto de paso intermedio a 0° . Las coordenadas del punto intermedio y el ángulo de entrada y salida son las variables utilizadas por el algoritmo genético para optimizar la longitud de la trayectoria en función de las restricciones.

Se han simulado tres escenarios diferentes para comprobar diferentes comportamientos del algoritmo genético optimizando la función de generación de trayectorias. El primero de ellos no limita la posición del punto de paso intermedio dentro de mapa de ocupación. El segundo escenario establece restricciones para la posición del punto de paso intermedio, restringiendo las posibles coordenadas del punto dentro de un área delimitada del mapa de ocupación y su ángulo de llegada y salida. El tercer escenario simula un caso en el que las restricciones de posición y ángulo de llegada y

salida no permiten que el algoritmo sea capaz de encontrar una trayectoria sin suceder una colisión.




Figura 2. Escenario 1: Trayectoria óptima sin restricciones de área

La Figura 2 muestra los resultados de la trayectoria optimizada para el primer escenario. En este caso no se han utilizado limitaciones para la posición del punto de paso intermedio, restringiendo el ángulo de entrada y salida a 0° . En rojo se muestra la trayectoria óptima y el punto de paso intermedio calculado por el algoritmo genético, así como los puntos inicial y final predefinidos. Se comprueba como en la búsqueda de optimizar la longitud de la trayectoria, el algoritmo genético apura el paso de la curva con los obstáculos del mapa de ocupación.




Figura 3. Escenario 2: Trayectoria óptima con restricción de área

Las Figuras 3 y 4 muestran los resultados para el segundo y tercer escenarios, respectivamente. En estos casos se ha restringido la posición del punto de paso intermedio y, en consecuencia, la forma de la trayectoria se adapta al camino más corto de acuerdo a esa condición.

En la Figura 3, se representa el segundo escenario, donde un cuadrado azul representa el área utilizada como restricción para la posición del punto intermedio de la trayectoria que se ha fijado entre $x \in [45,55]$, $y \in [33,40]$, restringiendo su ángulo de entrada y salida a 0° . Con esta restricción, el algoritmo busca las soluciones cuya posición esté dentro del espacio definido en el cuadrado azul. En este caso el algoritmo encuentra una trayectoria diferente al primer escenario para cumplir con los requisitos, alcanzando una mayor curvatura y un camino más largo que en caso del primer escenario sin restricciones. Esta situación es significativa cuando se consideran diferentes modelos de AGV con diferente capacidad de movimiento y curvaturas posibles, ya que dependiendo de las condiciones que se den a las puntos de paso intermedios, estos parámetros de la trayectoria pueden cambiar significativamente.




Figura 4. Escenario 3: Trayectoria óptima con restricción de área y colisión

La Figura 4 muestra el resultado para el tercer escenario. En esta simulación, el área restringida para el punto de paso intermedio de la trayectoria imposibilita al algoritmo genético encontrar un camino sin chocar con las posiciones ocupadas del mapa. En este caso, también se selecciona el camino más corto, aunque la función de coste dada por el algoritmo tendrá un valor muy alto acorde a esta situación. En este tercer escenario, la zona de posibles puntos intermedios se ha fijado entre $x \in [20,30]$, $x \in [25,33]$, restringiendo su ángulo de entrada y salida a 0° . Al igual que en el caso anterior, un cuadrado azul representa el área condicionada para el punto intermedio y un círculo azul marca el punto en el que la función reconoce que existe un evento de colisión.

Table 1. Resultados óptimos para los tres escenarios de simulación

Escenario	Restricciones Punto Intermedio	Mejor Individual	Función de Coste	Valido
1	$\theta = 0$	[31.61,44.04]	57.15	✓
2	$x \in [45,55]$ $y \in [33,40]; \theta = 0$	[45,40]	63.88	✓
3	$x \in [20,30]$ $y \in [25,33]; \theta = 0$	[30,33]	70783	X

Los resultados de la Tabla 1 muestran que, dependiendo de las restricciones que se establezcan para la trayectoria, el conjunto de parámetros optimizados devueltos por el algoritmo genético son diferentes. De hecho, en los casos en los que las condiciones son muy restrictivas (escenario 3), el algoritmo genético no puede encontrar una solución de parámetros de ajuste para una trayectoria óptima que no choque con el mapa de ocupación. Sin embargo, cuando no se especifica ninguna restricción, el algoritmo encuentra una trayectoria óptima sin eventos de colisión y con valor de función de coste, por tanto, mucho más bajo.

5. Conclusiones y líneas futuras

En este trabajo se han aplicado algoritmos genéticos en una función de generación de trayectorias para AGV para la optimización su longitud y evitar colisiones. Los eventos de colisión se comprueban entre un mapa de ocupación binaria y cada uno de los segmentos entre los puntos de la trayectoria. Un punto de paso intermedio de la trayectoria a generar es el parámetro utilizado por el algoritmo para el proceso de optimización. Se comparan y analizan tres escenarios con diferentes restricciones, extrayendo de los resultados las siguientes conclusiones.

Las restricciones de los puntos de paso intermedios de la trayectoria son una decisión importante, ya que afecta directamente a su longitud y su curvatura para evitar las posibles colisiones con el mapa de ocupación.

Esta aplicación se adapta perfectamente a casos de generación automática de trayectorias en procesos de implementación de AGV en industria o modificación de las rutas ya existentes, encontrando de forma automática la trayectoria óptima para este tipo de vehículos a partir de restricciones introducidas por usuario.

Como trabajos futuros, se propone la mejora de la metodología para poder considerar más parámetros y restricciones durante el cálculo de la solución óptima. Además, se propone asimismo la mejora del proceso de detección de

colisiones para poder considerar el modelo físico del AGV que se utilizará para seguir la trayectoria óptima calculada.


Referencias

- Abajo, M. R., Sierra-García, J. E., & Santos, M. (2021, September). Evolutive Tuning Optimization of a PID Controller for Autonomous Path-Following Robot. In International Workshop on Soft Computing Models in Industrial and Environmental Applications (pp. 451-460). Springer, Cham.
- Alencar, H., Santos, W., & Neto, G. S. (2022). Differential Geometry of Plane Curves (Vol. 96). American Mathematical Society.
- Alouache, A., & Wu, Q. (2018, September). Genetic algorithms for trajectory tracking of mobile robot based on PID controller. In 2018 IEEE 14th International Conference on Intelligent Computer Communication and Processing (ICCP) (pp. 237-241). IEEE.
- Bechtsis, D., Tsolakis, N., Vlachos, D., & Iakovou, E. (2017). Sustainable supply chain management in the digitalisation era: The impact of Automated Guided Vehicles. *Journal of Cleaner Production*, 142, 3970-3984.
- Bostelman, R., & Messina, E. (2016). Towards development of an automated guided vehicle intelligence level performance standard. *Autonomous Industrial Vehicles: From the Laboratory to the Factory Floor*, 1-22.
- Echeverri Estrada, J. M., & Escobar Murcia, P. A. (2012). Caracterización de un AGV (vehículo guiado automáticamente) en el sistema de manufactura flexible, caso Centro Tecnológico de Automatización CTAI de la Pontificia Universidad Javeriana.
- Espinosa, F., Santos, C., & Sierra-García, J. E. (2021). Multi-AGV transport of a load: state of art and centralized proposal. *Revista Iberoamericana de Automática e Informática Industrial*, 18(1), 82-91.
- Farouki, R. T. (2000). Curves from motion, motion from curves. California Univ. Davis Dept. of Mechanical and Aeronautical Engineering.
- Kühnel, W. (2002). Differential Geometry. Student Mathematical Library, vol. 16. American Mathematical Society, Providence, RI.
- Larrazabal, J. M., & Peñas, M. S. (2016). Intelligent rudder control of an unmanned surface vessel. *Expert Systems with Applications*, 55, 106-117.
- Santos, M., & Santos, A. J. (2010). Classification of plasma signals by genetic algorithms. *Fusion Science and Technology*, 58(2), 706-713.
- Sierra-García, J. E., & Santos, M. (2021). Switched learning adaptive neuro-control strategy. *Neurocomputing*, 452, 450-464.
- Vis, I. F. (2006). Survey of research in the design and control of automated guided vehicle systems. *European Journal of Operational Research*, 170(3), 677-709.
- Zhang, H., Wu, D., & Yao, T. (2018, September). Research on AGV trajectory tracking control based on double closed-loop and PID control. In *Journal of Physics: Conference Series* (Vol. 1074, No. 1, p. 012136). IOP Publishing.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Web-based HMI for renewable energies microgrid through Grafana environment

Folgado, F.J.^a, González, I.^a, Orellana, D.^a, Calderón, D.^a, Calderón, A.J.^{a,*}

^a *Departamento de Ingeniería Eléctrica, Electrónica y Automática, Escuela de Ingenierías Industriales, Universidad de Extremadura. Avenida de Elvas s/n, 06006 Badajoz, España.*

To cite this article: Folgado, F.J., González, I., Orellana, D., Calderón, D., Calderón, A.J. 2022. Web-based HMI for renewable energies microgrid through Grafana environment. XVII Simposio CEA de Control Inteligente.

Abstract

Smart Grids and Microgrids require continuous monitoring and visualization of the operational state of its generation and consumption equipment. The use of Internet of Things (IoT) technology for monitoring purposes can solve limitations of traditional solutions. This paper presents a web-based Human Machine Interface (HMI) developed in the IoT software Grafana to visualize in real-time the operation of a Smart Microgrid. Photovoltaic generation is combined with hydrogen production and consumption in the microgrid. The main magnitudes of the components are measured and graphically displayed through a user-friendly web interface. Experimental results are reported to prove the suitability of the developed HMI.

Keywords: HMI, Web, IoT, Microgrid, Monitoring, Database, Grafana.

1. Introduction

The monitoring and continuous visualization of an automated process is an essential task in all scientific processes. In particular, for renewable energy facilities, its relevance is acquiring an increasing attention from researchers and practitioners, as emphasized in many recent papers. For instance, in (Ferreira et al., 2015) it is asserted that deploying distributed monitoring and control systems is one of the main challenges in the scope of Smart Grids. In a similar sense, for Smart Grids and Microgrids, according to (Vargas-Salgado et al., 2019) and (Portalo et al., 2021), the monitoring task is of paramount importance.

Traditional software suites for process monitoring involve proprietary suites such as LabVIEW of National Instruments, iFix of General Electric, or WinCC of Siemens. In this sense, conventional monitoring and supervisory systems for microgrids are expensive due to the need for data loggers, controllers, sensors and other devices (Vargas-Salgado et al., 2019). Even more, these solutions have high costs and limited options for programming at low level. Additionally, most of monitoring systems for plants involving renewable energies are implemented in LabVIEW over a PC, allowing only local monitoring (Pereira et al., 2018).

The licensing expenditures and restricted local access of classic monitoring systems are limitations that must be overcome in order to stimulate the real implementation of Smart Microgrids (Portalo et al., 2021).

Aiming at addressing these drawbacks, Internet of Things (IoT) software for monitoring tasks is a valuable solution. In general, IoT software is also open-source, which provides the user the ability to modify and customize it at deep level. Indeed, these suites are commonly low-cost or free, which reduces the associated expenses. On the other hand, remote access to real-time data through the network is easily achieved thanks to the native support of online connections provided by IoT software packages.

In fact, a prominent trend in the deployment of monitoring systems relies on using IoT technology (González et al., 2022). Particularly, to support microgrid applications, IoT technologies provide great opportunities for sensing, communication, processing, and actuating (Eltamaly et al., 2021).

Among the available IoT software suites, web platforms that are gaining popularity are ScadaBR, Angular, Thinger.io and Grafana. The latter one is an IoT web environment developed in 2014 that provides an easy-to-use and intuitive environment to deploy web-based dashboards including instant values and time-series. Data is fed from a database, so the user can observe real-time data or historical information.

This paper presents a web-based Human Machine Interface (HMI) developed in Grafana to visualize in real-time the operation of a Smart Microgrid. Such microgrid is a renewable energy facility which combines photovoltaic generation with hydrogen production and consumption. The most relevant magnitudes of the components are sensed and graphically displayed through a user-friendly web interface.

The presence of Grafana in scientific papers demonstrates its versatile and powerful functionalities. For example, Grafana is used as display environment in the CERN, the European Organization for Nuclear Research, one of the world largest centres of scientific research (Beermann et al., 2020). Computation resources and memory consumption are monitored by Grafana for software deployment in the cloud in et al. 2022. Resource monitoring via Grafana is reported in (Chan et al., 2022) as part of a cluster-based heterogeneous edge computing system. The visualization of the status and power consumption of automated guided vehicles and drones is proposed in (Tsung et al., 2022). Condition monitoring for industrial autonomous transfer vehicles is solved by means of Grafana in (Gültekin et al., 2022). In the scope of Industrial IoT, this software is used for data query and visualization in (Liu et al., 2022).

Regarding energy-related applications, interesting contributions are found in recent literature. In (Portalo et al., 2021), the temperature of a photovoltaic generator is tracked by means of Grafana. The operation of a photovoltaic array and a Lithium-ion battery for water pumping purposes is visualized through this software in (Gimeno-Sales et al., 2020). A grid-connected photovoltaic plant is monitored via Grafana in (De Arquer Fernández et al., 2021). In (Barroso et al., 2022) Grafana is used to visualize data of water and energy consumption in the context of a SmartCampus.

The structure of the rest of the manuscript is as follows. The second section expounds the main features of the software Grafana. Section 3 describes the smart microgrid where the web-based HMI is applied. Implementation results are shown in the fourth section. Finally, the main conclusions of the work are addressed together with further guidelines.

2. Grafana main features

Grafana is IoT software focused on the information monitoring by means of queries in various databases. For this purpose, the environment provides a web-based HMI consisting of panels or dashboard that include graphical elements such as displays or charts to represent instantaneous values or time-series. Its principle of operation is based on communication with multiple data sources, such as InfluxDB, MariaDB, SQLite or MySQL. The Grafana and databases interconnection is carried out simultaneously, offering the possibility to represent different values from different data sources in the same graph. In addition, these databases can be located on devices other than the one running the Grafana web server. Figure 1 illustrates the principle of operation of Grafana, highlighting its connectivity with various data sources.




Figure 1: Principle of operation of Grafana. Interaction with databases.

Read data are represented in dashboards, where the graphical elements that contains the information are placed. These panels are characterised for its ease of configuration and user-friendly representation which facilitates the design and implementation of monitoring interfaces for a wide range of applications, as it has been stated in the previous section.

Another outstanding advantage of Grafana is its multiplatform character, offering the possibility of running Grafana on multiple operating systems such as Windows, MacOS or Linux. At the same time, it presents low computational requirements, which promotes its use in devices of diverse specifications such as personal computers, single board computers like Raspberry Pi, or even Android devices through an app that provides a Grafana client. This diversity of available devices and functions is due to its open-source approach, which encourages the development of plugins and additional functions by the Internet community under the Do It Yourself (DIY) philosophy.

Grafana has an intuitive and simple interface that guides the user through all the necessary steps for its operation. First, the connection to the environment is made locally or via Ethernet, depending on where the Grafana server is hosted. Once connected, the user logs in with a username and password. Then, the dashboard or element to be visualised and the specific time range are selected. After this, the program sends the request to the databases and, finally, the values received are represented in the graphical displays. The flowchart in figure 2 summarises the sequence of steps required for the visualisation of values in Grafana.




Figure 2: Flowchart of steps required for the visualisation of values in Grafana.

3. Smart Microgrid description

The monitored microgrid consists of a hybrid renewable energies system, formed by loads and generators. The Smart connotation refers to the self-management capacity of the system, based on devices dedicated to this function, such as programmable controllers.

As part of the generation subsystem, the microgrid includes an array of interconnected Solar Photovoltaic (SPV) panels controlled by a Maximum Power Point Tracker (MPPT) driver that optimises its operation and maximises current output. In addition, a Membrane-Based Fuel Cell (MBFC) is installed to generate electric current from an input hydrogen flow.

Within the load subsystem, an Electronic Programmable Load (EPL) is used to simulate different energy demand profiles. Also, a Membrane-Based Electrolyzer (MBEL) produces hydrogen by means of an electrical current provided by the SPV array. The stored hydrogen is used to fulfil the gas flow needed for the MBFC operation.

Lastly, a Lithium-Ion battery allows the electrical storage and stabilisation of the DC bus to which the rest of the devices are connected. Figure 3 depicts the interaction between the elements that make up the Smart Microgrid.




Figure 3: Components of the monitored Smart Microgrid.

Each of the abovementioned elements is accompanied by a set of sensors and actuators to collect information about the operation of the device and to act according to the energy management criteria. Some of these variables, such as the generated current by the SPV panels or the hydrogen flow rate produced by the MBEL, are directly related to the behaviour of the device. On the other hand, to maintain a smooth, efficient and safe operation, it is required to monitor variables associated with the operating status of the devices, such as the temperature of the MBFC or the State of Charge (SoC) of the Li-Ion battery. Figure 4 depicts all the elements involved in the monitoring system and their interactions.




Figure 4: Elements concerned in the monitoring system and interactions.

4. Implementation

The developed web-based HMI groups a set of graphs on a single dashboard. This design provides the user with a global overview of the status of the microgrid from a single screen. For this purpose, the used graphs represent multiple variables of the microgrid, which combined analysis provides further information on the state of the system. As an example, Figure 5 shows the evolution, for a selected time frame of the currents from the SPV panels, the battery and the EPL, together with the inclined irradiance measured on the panels.




Figure 5: SPV-Batt-EPL current and irradiance for a selected time interval.

The current generation by the SPV array depends on the irradiance, as can be seen in the homomorphism of both curves. The time interval depicted shows the behaviour of the microgrid in an operating case where the EPL does not demand current. Thus, the battery current has the same form as the panel current, whose positive value indicates that the battery is charging.

Other types of used graphs display variables associated with device performance within a nominal and safe range. These parameters determine the overall operation of the microgrid and result in changes in the operating modes of the devices involved through the installed actuators. In this context, a noteworthy feature of Grafana is the definition of alarms associated with variables, detecting deviations from setpoints or operating intervals. Even database disconnections can be detected. The user is warned of these situations graphically so the appropriate actions can be conducted. As an example of this feature, an alarm has been defined for the battery SoC. As previously mentioned, the battery is a critical element in the operation of the microgrid as it performs the functions of energy storage and DC bus stabilisation. Consequently, the rest of the microgrid components depend on the proper state of this device, so it is essential to monitor certain parameters such as the SoC or the current flow of the battery. Due to this importance, a specific curve has been implemented to visualise these variables, as shown in figure 6.



Figure 6: SoC and battery current for a selected time interval.

As shown in the figure, an alarm associated to the SoC variable has been implemented, in order to notify the operator when the value drops below 20%. This setpoint has been selected considering the properties of the installed battery. Li-Ion batteries are intended to operate in a nominal range from 20% to 80% SoC. Discharges below the lower limit are critical as they affect the health of the battery due to degradation effects.

The alarm signal allows the user to detect this unwanted situation and to act accordingly. In this case, it is desired to cut off the current consumption of the battery in order to prevent it from in-depth discharging. By doing so, all the current generated will be stored in the battery, increasing the SoC value to the nominal operating range.

Numerical indicators are used to represent the values of the microgrid in real time. The set of elements that make up the dashboard allows the user to visualise two types of data simultaneously: historical data through the graphs and real-time values by means of the indicators.

Taking MBEL values as an example, two types of indicators are used: simple and with value range. The first type is used for variables whose value is not critical for the system, as in the case of hydrogen flow. On the other hand, the value-range indicators display values such as the working pressure, which should not exceed a maximum limit in order to ensure correct operation of the MBEL. If this maximum is reached, the indicator changes colour to alert the operator. Figures 7a and 7b shows the appearance of the simple and value-range indicator described above.




Figure 7a. Simple indicator. Figure 7b. Value-range indicator.

Figure 7. MBEL hydrogen flow and working pressure indicators.

5. Conclusions

This paper has presented the development and implementation of a web-based HMI devoted to monitor a renewable energy Smart Microgrid. The IoT software Grafana has been applied to design a dashboard which display in real-time the main magnitudes of the microgrid. Experimental results demonstrate the ability of this HMI to visualize such magnitudes through graphical time-series as well as instant values. Moreover, alarms can be defined for the continuous surveillance of critical variables, warning when values out of the proper range are reached. Future research guidelines deal with including advanced functionalities by means of additional plugins as well as with developing a digital twin of the microgrid components with the acquired data.

Acknowledgments

This project was co-financed by European Regional Development Funds FEDER and by the Junta de Extremadura (IB18041).


References

- Arquer Fernández, P. De, M. Angel Fernández Fernández, J. Luis, C. Candás, P. Arbolea Arbolea. 2021. An IoT Open Source Platform for Photovoltaic Plants Supervision. *Electrical Power and Energy Systems* vol. 125pp. 106540. <https://doi.org/10.13039/501100011033>.
- Barroso, S., P. Bustos, P. Núñez. 2022. Towards a Cyber-Physical System for Sustainable and Smart Building: A Use Case for Optimising Water Consumption on a SmartCampus. *Journal of Ambient Intelligence and Humanized Computing*, no. 0123456789. <https://doi.org/10.1007/s12652-021-03656-1>.
- Beermann, T., A. Alekseev, D. Baberis, S. Crépé-Renaudin, J. Elmsheuser, I. Glushkov, M. Svatos, A. Vartapetian, P. Vokac, H. Wolters. 2020. Implementation of ATLAS Distributed Computing Monitoring Dashboards Using InfluxDB and Grafana. *EPJ Web of Conferences* vol. 245pp. 03031. <https://doi.org/10.1051/epjconf/202024503031>.
- Chan, Y.-W., H. Fathoni, H.-Y. Yen, C.-T. Yang. 2022. Implementation of a Cluster-Based Heterogeneous Edge Computing System for Resource Monitoring and Performance Evaluation. *IEEE Access* vol. 10pp. 1–1. <https://doi.org/10.1109/access.2022.3166154>.
- Eltamaly, A.M., M.A. Alotaibi, A.I. Alolah, M.A. Ahmed. 2021. Iot-Based Hybrid Renewable Energy System for Smart Campus. *Sustainability (Switzerland)* vol. 13 (15), . <https://doi.org/10.3390/su13158555>.
- Ferreira, A., Á. Ferreira, O. Cardin, P. Leitão. 2015. Extension of Holonic Paradigm to Smart Grids. *IFAC-PapersOnLine* vol. 28 (3), pp. 1099–1104. <https://doi.org/10.1016/j.ifacol.2015.06.230>.
- Gimeno-Sales, F.J., S. Orts-Grau, A. Escribá-Aparisi, P. González-Altozano, I. Balbastre-Peralta, C.I. Martínez-Márquez, M. Gasque, S. Seguí-Chilet. 2020. Pv Monitoring System for a Water Pumping Scheme with a Lithium-Ion Battery Using Free Open-Source Software and Iot Technologies. *Sustainability (Switzerland)* vol. 12 (24), pp. 1–28. <https://doi.org/10.3390/su122410651>.
- González, I., A.J. Calderón, F.J. Folgado. 2022. IoT Real Time System for Monitoring Lithium-Ion Battery Long-Term Operation in Microgrids. *Journal of Energy Storage* vol. 51 (March), pp. 104596. <https://doi.org/10.1016/j.est.2022.104596>.
- Ite in . E. Cin r . n A. . 2022. Real-Time Fault Detection and Condition Monitoring for Industrial Autonomous Transfer Vehicles Utilizing Edge Artificial Intelligence.
- t . A. . Ionit . . Anton . t . 2022. Applied S ien es Analysis of Complexity and Performance for Automated Deployment of a Software Environment into the Cloud.
- Liu, C., Z. Su, X. Xu, Y. Lu. 2022. Service-Oriented Industrial Internet of Things Gateway for Cloud Manufacturing. *Robotics and Computer-Integrated Manufacturing* vol. 73 (February), . <https://doi.org/10.1016/j.rcim.2021.102217>.
- Pereira, R.I.S., I.M. Dupont, P.C.M. Carvalho, S.C.S. Jucá. 2018. IoT Embedded Linux System Based on Raspberry Pi Applied to Real-Time Cloud Monitoring of a Decentralized Photovoltaic Plant. *Measurement: Journal of the International Measurement Confederation* vol. 114 (January 2017), pp. 286–97. <https://doi.org/10.1016/j.measurement.2017.09.033>.
- Portalo, J.M., I. González, A.J. Calderón. 2021. Monitoring System for Tracking a Pv Generator in an Experimental Smart Microgrid: An Open-Source Solution. *Sustainability (Switzerland)* vol. 13 (15), . <https://doi.org/10.3390/su13158182>.
- Tsung, C.-K., F.-S. Chang, X.-Y. Liu. 2022. On the Construction of an Edge-Based Remote Sensing Framework: The Applications on Automated Guided Vehicles and Drones. *Electronics* vol. 11 (7), pp. 1034. <https://doi.org/10.3390/electronics11071034>.
- Vargas-Salgado, C., J. Aguila-Leon, C. Chiñas-Palacios, E. Hurtado-Perez. 2019. Low-Cost Web-Based Supervisory Control and Data Acquisition System for a Microgrid Testbed: A Case Study in Design and Implementation for Academic and Research Applications. *Heliyon* vol. 5 (9), . <https://doi.org/10.1016/j.heliyon.2019.e02474>.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Demand Model in an Automotive Supply Chain Company

Freijo, Fernando^{a,*}, Lopez-Guede, Jose Manuel^{b,c}

^a Faculty of Engineering of Vitoria, Basque Country University (UPV/EHU), Nieves Cano 12, 01006 Vitoria, Spain.

^b Department of Systems Engineering and Automatic Control, Faculty of Engineering of Vitoria, Basque Country University (UPV/EHU), Nieves Cano 12, 01006 Vitoria, Spain

^c Computational Intelligence Group, Faculty of Informatics, Basque Country University (UPV/EHU), Paseo Manuel de Lardizabal 1, 20018 San Sebastian, Spain.

To cite this article: Freijo, Fernando, Lopez-Guede, Jose Manuel. Demand Model in an Automotive Supply Chain Company. 2022. XVII Simposio CEA de Control Inteligente.

Resumen

En este artículo exponemos la implementación de un proyecto de predicción de la demanda asistido por Inteligencia Artificial en una PYME (pequeña y mediana empresa) del País Vasco. La empresa pertenece al sector del recambio del automóvil orientada principalmente al sector profesional (B2B) siendo sus principales clientes, talleres de reparación de automóviles. Cuenta con ocho oficinas que gestionan un amplísimo catálogo de primeras marcas ubicadas a nivel internacional. En este contexto, la operativa logística supone una actividad clave del negocio. Por otro lado, el flujo de mercancías entre sus almacenes, la gestión de compras y los costes de transporte son también áreas a optimizar. Consecuentemente, la gestión eficiente del stock es fundamental para los resultados del negocio. En este artículo; proponemos un modelo de predicción de la demanda asistido por un algoritmo de aprendizaje automático que ayude a la toma de decisiones empresariales. La información tratada procede de varias fuentes de datos como son el sistema ERP, la plataforma B2B y la base de datos del call center. El objetivo principal de este modelo es incidir sobre un punto débil generalizado en todas las empresas de este sector.

Palabras clave: Gestión de Procesos de Negocio, Procedimientos de Planificación de procesos, Modelo de asistencia a la toma de decisiones empresariales, Programación de tareas y actividades, Integración de aplicaciones empresariales, Empresa Digital.

Demand Model in an Automotive Supply Chain Company

Abstract

This paper expound the implementation of a project of demand forecasting powered by Artificial Intelligence (AI) in a small and medium-sized enterprise (SME) situated in Basque Country. The company works in automotive after-market segment, whose main clients are professional Car Workshops. Eight offices handle a massive product catalogue supplied by international leadership manufacturers located all over the world. Considering this scenario, the logistic operative is evidently a key business activity. On the other hand, the flow of goods among their warehouses, the purchasing management and freight costs must be also optimized. This means that an efficient stock management is equally crucial for the result of the company. In this paper, we propose a demand prediction model assisted by machine learning algorithms which facilitates crucial business decisions. The information gathering uses several sources such as the ERP; the B2B Platform and the call center Data Base. The main aim of this model is to reinforce a weak point detected not only in this company, but also in others competitor enterprises.

Keywords: Business Process Management, Procedures for process planning, Enterprise Modelling, Decision-making support, Job and activity scheduling, Enterprise Application Integration, Digital enterprise.

1. Introduction

Nowadays, AI is being applied to different knowledge areas (Dirican, 2015), especially in academic environments. Nevertheless, there are yet some issues to go through before all this progress reach the real economy and the industrial activity. In general, small and medium-sized enterprises lack economic resources and professional expertise to deal with these types of projects. Indeed, our approach takes a medium size particular company as starting point. Then, we implement a solution adapted to their specific necessity and finally, we will extend our result to other similar cases. Bear in mind that we will be able to generalize our research on condition we study a common problem in a specific sector.

2. Company Information

Our Company is a SME Company engaged to the automotive aftermarket attending more than 3,000 car workshops as main clients. The headquarters is lied in Etxebarri and they have seven offices around of the north of Spain. All of them have point of sales and warehouses.

Their commercial strategy is based on three sales channels:

- Telemarketing attended by a professional team.
- Direct sales in their 8 point of sales.
- On line sales: The Company boasts a B2B e-commerce platform where the clients can make orders in an efficient and agile way. Undoubtedly, it is the channel more promising with an accelerated growth in the last years.

The company is capable of delivering a product within 30 minutes after the customer makes the order. According to the opinion of their clients, this service is the most highly valuable. It means they must have an efficient system of distribution supported by an appropriated sized transport fleet.

To sum up, the company works in the professional market of the automotive supply chain. Consequently, Logistic Operative and Stock Management are the essential keys of this business, so, these are the main areas to address our project.

3. Supply Chain and AI Applications in Logistic Area

A Supply Chain refers to the network of companies that produce, sell and deliver product o services to a particular market (Icarte, 2016). The agents of this chain include Manufacturers, Suppliers, Warehouses, Retailers, Transport Companies among others. There is a wide range of opportunities to apply AI for the Logistic Function (Leporati, M., et al., 2019).

Deep Learning Algorithms and Expert Systems deal skillfully with scenario analysis and numerical analytics, both of which are crucial for logistic planning (Dilmegani, C., 2020). Smart warehouses (Zhen, et al., 2022) evolves rapidly with the integration of Autonomous Mobile Robots (AMR), (Li, et al., 2019) Automatic Guided Vehicles (AGV), (Correia, et al., 2020), Machine-Learning Techniques and Computer Vision Technology (Anhong Guo et al., 2015). The models of Route Optimization use algorithms to find the shortest and efficient ways for logistics movements (Paternina-Arboleda, C., et al., 2019). The predictive maintenance (Gama, J. et al., 2020) is improving significantly thanks to projects of IoT,

sensor development and Big Data Analysis. Customer service is a vital matter in logistics companies and the chatbot solutions handle quite dexterously some call center tasks (Albrecht et al., 2021). AI is an useful tool for demand prediction as well as enable data analysis in real time reducing errors significantly. The dynamic price system (Dube, et al., 2002) adjusts constantly the figures to the real demand. The respond to this fluctuation can be more accurate using machine-learning algorithms to analyse the market changes.

4. The European Strategy concerning Digital Transformation.

The European Commission is leading an ambitious plan for the Green and Digital Transformation (European Commission, 2020) in all the European territory. In this context, we can say that the project is closely aligned with the European political. For example, part of the EU plan is the Digital Europe Programme whose main objective is “bringing digital technology to businesses, citizens and public administrations”. This year a budget over €7.5 billion is available to boost in five key capacity areas: Supercomputing, Artificial intelligence, Cybersecurity, Advanced digital skills, and ensuring a wide use of digital technologies across the economy and society, including through Digital Innovation. According to the digital strategy of the EU, this plan “aims to accelerate the economic recovery and shape the digital transformation of Europe’s society and economy, bringing benefits to everyone, but in particular to small and medium-sized enterprises”.

5. The Demand Prediction Project

5.1 Previous works

In order to detect the key constraint of the daily operative of this business, we made previously a consulting plan project whose main output was a Digital Plan. This document is the basic supporting document for the final implementation of our solution. It is important to remark that because of this consulting process, we obtained a considerable number of actions to take, making this Digital Plan a more ambitious project that we expound on this paper.

Below we mention the stage of this consulting project:

- S-1: Analysis of the initial situation of the company's Business -Processes, including their main KPI's.
- S-2: Description of the company's Strategy.
- S-3: SWOT analysis of processes.
- S-4: Enumerative analysis of digitization projects, with the technological evaluation of the alternatives.
- S-5: Selection of Projects, considering the situation of the company and the market.
- S-6: Description of each project, including necessary resources, cost, technology, specific systems and planning.
- S-7: Sequenced Action Plan of the proposed digital itinerary.

5.2 The Demand Prediction Problem

In this business, the stock levels and the sale price along with their correlations are factors that determine to a large degree the result of the company. Both parameters require a

deep analysis of available data. However, the traditional method to manage stocks as well as to estimate the right sale price result notoriously inefficient.

The stock replenishment depends on many variables such as the future demand, acquisition prices, available merchandises, purchasing volume discounts, and the regional vehicle fleet, among others. Some of them are not easy to know. On the other hand, a product out of stock means an inadmissible opportunity cost. At the same time, although the sale price is limited by the market, it must guarantee a trade margin.

When new manufacturers offer our company the distribution of their catalogue, the Management studies the proposed agreement and make a decision about the incorporation of these products. In this case, an accurate information is crucial to reach a mutual beneficial agreement.

5.3 Prediction model

Our study concluded that an adequate solution is a model of demand prediction which handles historical company data along with information from external big impact factors. Indeed, this model collects information from several data sources such as the ERP, call center and B2B Platform.

The stage of this project are implicit in the Data Life Cycles model that is shows below.




Figure 1: Data Life Cycle, <https://pipelab.es/>

An initial process of technology watch concluded that multiple methodologies have been tested in demand forecasting. In fact, it is possible to find in the market several competent software that implement methodologies related to AI. Nonetheless, neither of them was considered an appropriated solution for this case.

6. Conclusion

In this paper, we describe the implementation process of an IA Solution for a company working in the Automotive Supply Chain. In a bottom-up approach, we study weak points of this business and design an appropriated solution to deal with. In detail, we develop a demand forecast model supported by IA Algorithms. This expert system proposes an efficient stock management including purchasing decision and sales prices configuration. The system inputs is a set of variables from multiple information sources such as ERP, B2B System and Call Center data. Having studied commercial software and different cases of technology application in Supply Chain, we conclude that our model responds more effectively to the objective of this particular sector.

References

- Dilmegani, C. (2020) "Top 15 Use Cases and Applications of AI in Logistics in 2022", <https://research.aimultiple.com>.
- Leporati, M., Morales, M. (2019) "Las claves de la implementación de la inteligencia artificial (IA) en la gestión de cadenas de suministro de extremo a extremo" in Management & Innovation, 18, <https://www.harvard-deusto.com>.
- Albrecht, T., Rausch, T. M. and Derra, N. D. (2021) "Call Me Maybe: Methods and Practical Implementation of Artificial Intelligence in Call Center Arrivals' Forecasting," Journal of Business Research, 123, pp. 267–278. doi: 10.1016/j.jbusres.2020.09.033.
- Anhong Guo et al. (2015) "Order Picking with Head-Up Displays," Computer, 48(6). doi: 10.1109/MC.2015.166.
- Correia, N. et al. 2020, "Implementing an AGV system to transport finished goods to the warehouse" in Advances in Science, Technology and Engineering Systems" (n.d.) DOAJ: Directory of Open Access Journals.
- Dirican Cüneyt (2015) "The Impacts of Robotics, Artificial Intelligence on Business and Economics," Procedia Social and Behavioral Sciences, 195, pp. 564–573. doi: 10.1016/j.sbspro.2015.06.134.
- Dube, P., Borkar, V. S. and Manjunath, D. (2002) "Differential Join Prices for Parallel Queues: Social Optimality, Dynamic Pricing Algorithms and Application to Internet Pricing," Proceedings /, 1, pp. 276–283.
- Icarte Ahumada G.A (2016) "Applications of Artificial Intelligence in Supply Chain Process: A Systematic Review," Ingeniare, 24(4), pp. 663–679. doi: 10.4067/s0718-33052016000400011.
- ICCL (Conference) (10th : 2019 : Barranquilla, Colombia) (2019) Computational logistics : 10th international conference, iccl 2019, barranquilla, colombia, september 30 october 2, 2019, proceedings. Edited by C. Paternina-Arboleda and S. Voss. Cham, Switzerland: Springer (Lecture notes in computer science, 11756). doi: 10.1007/978-3-030-31140-7.
- IoT Streams (Workshop) (2nd : 2020 : Online), ITEM (Workshop) (1st : 2020: Online) and ECML PKDD (Conference) (2020 : Online) (2020) Iot streams for data-driven predictive maintenance and iot, edge, and mobile for embedded machine learning : second international workshop, iot streams 2020, and first international workshop, item 2020, colocated with ecml/pkdd 2020, ghent, belgium, september 14-18, 2020 : revised selected papers. Edited by Gama João et al. Cham, Switzerland: Springer (Communications in Computer and Information Science, 1325). doi: 10.1007/978-3-030-66770-2.
- Li, M. P. et al. (2019) "2019 Winter Simulation Conference (wsc)," in Task Selection by Autonomous Mobile Robots in a Warehouse Using Deep Reinforcement Learning. IEEE, pp. 680–689. doi: 10.1109/WSC40007.2019.9004792.
- European Commission, (2020), Shaping Europe's digital future, <https://ec.europa.eu>.
- Zhen, L. and Li, H. (2022) "A Literature Review of Smart Warehouse Operations Management," Frontiers of Engineering Management, 9(1), pp. 31–55. doi: 10.1007/s42524-021-0178-9.

Autonomous flying in real-time with RPAS

Caballero, D.^{a,*}, Lopez-Guede, J. M.^b

^a Faculty of Informatics, Basque Country University (UPV/EHU), Paseo Manuel de Lardizabal, 1. 20018 San Sebastian, Spain.

^b Department of Systems Engineering and Automatic Control, Faculty of Engineering of Vitoria, Basque Country University (UPV/EHU), Nieves Cano 12, 01006 Vitoria, Spain

To cite this article: Caballero, D., Lopez-Guede, J.M. 2022. Autonomous flying in real-time with RPAS. XVII Simposio CEA de Control Inteligente.

Abstract

It is proposed to carry out several iterations of the SDLC (Systems Development Life Cycle) in order to develop an artificial intelligence algorithm capable of making decisions in real time in the field of RPAS (Remotely Piloted Aircraft System). It must be able to maintain the integrity and security of the environment, providing autonomy to one or several RPAS that make up a network to fulfil a common mission. Real-time vision and analysis of images obtained from the RPAS will be used for the algorithm to analyse and redirect them appropriately to the RPAS. On the other hand, it must also obtain the telemetry of each one of the RPAS in order to have an image of the positioning of each one of them, adopting the correct actions without endangering any of the RPAS that make up the network.

Keywords Artificial intelligence in RPAS, Real time image analysis, Autonomous flight with real-time decisions, RPAS, MATLAB, Multiple RPAS mission.

1. Introduction

The great evolution of technologies focused on artificial intelligence allows algorithms capable of making decisions in real time. It also provides autonomy to objects that initially need human supervision in order to carry out the mission for which they are intended. The artificial intelligence algorithms designed must be efficient and have a high success rate, this providing the system with reliability. In this way, they are able to ensure the correct functioning and integrity of the objects on which the decisions will affect. An optimal training set must be generated to train the neural network properly.




Figure 1: Artificial intelligence application.

Due to the rise of this technology, jobs can become more specialized and devote much more time to the research of new

functionalities that facilitate both the use and the autonomy of the objects to which this type of technology is applied.

2. Research proposal

It is proposed to carry out several iterations of the *SDLC* (Systems Development Life Cycle) in order to develop an artificial intelligence algorithm capable of making decisions in real time in the field of *RPAS* (Remotely Piloted Aircraft System). The decisions taken by the algorithm will directly affect the RPAS's flight behaviour by sending orders to modify its trajectories in order to fulfil the mission for which the algorithm is designed. To make such decisions, images of the environment will be obtained from the RPAS (Malburg, Alvarez-Cedillo and Herrera-Charles, 2020)(Malburg, Rieder, Seiger, Klein and Bergmann, 2021). The algorithm will analyse the received image and conclude with a decision to be fulfilled by the RPAS (Aibin, Aldiab, Bhavsar, Lodhra, Reyes, Rezaeian and Taer, 2021).

Initially, to ensure the security of the environment and the devices to be used, both training and testing will be carried out in a simulated environment using a single midrange RPAS

until the security and integrity of the designed algorithm is achieved.




Figure 2: Design phase 1.

After the final design of the algorithm, stabilising it and ensuring a percentage of success within the established ranges that guarantee the characteristics of the mission, the tests will be carried out with a highend RPAS with an almost total capacity for customisation and adaptation of the components.

In order for the algorithm to be efficient, it is intended to be fast in computational time in terms of decision making, since a delay in the resolution of the trajectory may cause irreversible damage to the RPAS or its environment.

As a second phase, the aim is to adapt the algorithm to be able to control a network of RPAS in real time using both the camera and all the telemetry provided by all the RPAS in the network in order to successfully carry out a joint mission with a common objective (Roth, Yang and Ahuja, 2000).




Figure 3: Design phase 2.

As a third phase, and after ensuring the efficiency of the algorithm and its correct functioning in the RPAS, it is intended to implement an automated surveillance network capable of identifying potential threats, establishing communication between the algorithm and the network of RPAS capable of carrying out this prototype mission.

Not all the RPAS must have the same model and the same characteristics, but each of them must have a purpose within the video surveillance network.

This is a handicap due to the fact that the development responsible for sending the orders to each of the members of the network, must be able to discriminate between the existing RPAS models and model a readable message according to the communications interface designed for the model in question.

On the other hand, based on this example, it could be extrapolated not only to the field of RPAS, but it would also be interesting to implement a video surveillance network with different aerial devices, terrestrial devices and cameras. In the latter case, we must ensure that they are devices with an implemented API that allows the reception of orders and sending of data to feed the designed algorithm (McCane, Caelli and DeVel, 1997).

When making this prototype, it is important to take into account the computation time consumed in sending the orders. Also, on the other hand, the communications must be good enough to be able to maintain the network of devices without losing control of them. If that were to happen, the model would be exposed to the possible loss of one of the devices or a loss of security of the network in charge of it.




Figure 4: Design phase 3.

3. Conclusion

Artificial intelligence is something intangible that cannot be seen or touched, but it has the great capacity to provide new uses and autonomy to objects that were not designed for it.

Focusing on the field of RPAS, initially, they were considered as an amusement that occupied our leisure time, but thanks to the evolution of artificial intelligence, we can provide them with autonomy to perform tasks such as autonomous surveillance.

Thanks to this, the aim is to develop an algorithm that is capable of directing a network of drones autonomously without the need for human intervention and ensuring the integrity of both the devices and their environment.


References

- Aibin, M., Aldiab, M., Bhavsar, R., Lodhra, J., Reyes, M., Rezaeian, F., Taer, M., 2021. Survey of RPAS autonomous control systems using artificial intelligence.
- Malburg, T., Alvarez-Cedillo, J. A., & Herrera-Charles, R., 2020. Recognition of objects based on deep learning in an RPAS. *Applications of Digital Image Processing Xliii*, 11510, 115100T.
- Malburg, L., Rieder, M., Seiger, R., Klein, P., & Bergmann, R., 2021. Object detection for smart factory processes by machine learning. *12th International Conference on Ambient Systems, Networks and Technologies (Ant) / the 4th International Conference on Emerging Data and Industry 4.0 (Edi40) / Affiliated Workshops*, 184, 581-588.
- McCane, B., Caelli, T., & DeVel, O., 1997. Learning to recognize 3D objects using sparse depth and intensity information. *International Journal of Pattern Recognition and Artificial Intelligence*, 11(6), 909-931.
- Roth, D., Yang, M. H., & Ahuja, N., 2000. Learning to recognize objects. *Ieee Conference on Computer Vision and Pattern Recognition, Proceedings, Vol I*, 724-731.
- Keohane, R., 1958.



XVII Simposio CEA de Control Inteligente

27-29 de junio de 2022, León



Fast start reciprocating engines in the flexible power generation

Del Valle, J.^a, Lopez-Guede, J. M.^b

^a Siemens Energy Engines R&D, Vitoria, Spain, javier.del_valle@siemens.com, University of the Basque Country (UPV/EHU), Faculty of Engineering of Vitoria-Gasteiz, Department of Systems Engineering and Automatic Control, 01006 Vitoria-Gasteiz, Spain, javier.delvalle@ehu.es, ORCID: <https://orcid.org/0000-0001-8485-7148>.

^b University of the Basque Country (UPV/EHU), Faculty of Engineering of Vitoria-Gasteiz, Department of Systems Engineering and Automatic Control, 01006 Vitoria-Gasteiz, Spain, jm.lopez@ehu.es, ORCID: 0000-0002-5310-1601.

To cite this article: Del Valle, J, Lopez-Guede, J. M. 2022. Fast start reciprocating engines in the flexible power generation. XVII Simposio CEA de Control Inteligente.

Abstract

The Energy transition towards renewable energy is going to need an increase in flexible power generating capacity. Different approaches are taken into consideration in different countries. The paper analyzes the Spanish case and the UK case. One of the technologies that could be key in providing this extra flexible capacity when needed are reciprocating engines that could make use of different fuels of that (hydrogen, sewage, landfill, natural gas, etc.). Reciprocating engines fast start and flexible capabilities are presented based on different engine tests already done. Reciprocating engines could be a proper renewable solution in the future if they are consuming hydrogen gas.

Palabras clave: CM, (Capacity Market)

1. Introduction

In the past the energy system could be characterized as a centralized energy system with big fossil fueled centralized power plants that by means of a transmission and distribution network supply the energy to the end user. Nowadays new technology and solutions are changing the way the energy system is operated. The importance of wind power renewable generation, new technologies and the CO₂ reduction importance are making a transition to a more distributed power generation system. This trend to renewables can be seen clearly in the top power generation companies.

The Spanish energy market and the UK energy market are shown as two alternative cases in this article. Two of the most promising flexible energy alternatives are shown. The reciprocating engines are studied as one of the possible alternatives for an increase in the flexible power generation that has been started to be used in the UK market.

2. Spain Energy System Overview

In Spain the total installed power capacity nearly doubles the maximum hourly demand. Although the installed wind power capacity is around 23% in the maximum hourly demand the

use of wind energy was reduced to 11.7% and that coal power generation was in fact an 18.5%. This means that although wind power or other ways of renewables power generation has been introduced the dependency of coal is still important due to the intermittent characteristics of renewables technologies.

Installed power capacity on the peninsula as at 31 december 2018 (%)

Nuclear	7.2%	Wind	23.4%
Coal	9.7%	Hydro	17.3%
Combined cycle	24.9%	Solar photovoltaic	4.5%
Cogeneration	5.8%	Solar thermal	2.3%
Non-renewable waste	0.5%	Other renewables	0.9%
Pumped-storage	3.4%	Renewable waste	0.1%




Figure 1: 2018 Energy power capacity (REE, 2018).

Electricity demand coverage. Maximum hourly demand coverage on the Peninsula. 2018 (%)

Nuclear	17.4%	Wind	11.7%
Coal	18.5%	Hydro	14.6%
Combined cycle	22.6%	Solar thermal	0.5%
Cogeneration	8.7%	Other renewables	1.1%
Non-renewable waste	0.8%	Renewable waste	0.2%
Pumped-storage ^[1]	2.1%	Import balance of international exchanges	1.8%

[1] Pure pumped storage + estimated mixed pumped storage.




Figure 2: 2018 Energy demand coverage (REE, 2018).

Looking at above figures in Spain it seems that if the renewables energy percentage is increased in order to cover 80% of total demand, then a 20% is left to Nuclear and combined cycle, if coal plants will be closed in the future before reaching 2050. The interconnections with other countries are considered as a storage source of energy by REE. The question is what could happen in a scenario where all the countries rely in the interconnections and power capacity of others with a similar energy mix. Probably it makes sense to diversify the energy flexible capacity and to provide some critical back-up system. It seems no clear the planned flexible capacity in Spain regarding other energy storage systems like batteries or the use of reciprocating gas engines as in the UK case.

In the Spanish Canary Islands the pumped storage plant of Soria-Chira it is being constructed. It will provide 200Mw of energy capacity that will be pumped with the extra energy produced by the wind in the Canary Islands.

3. UK Energy Overview

The UK energy systems has experienced a big change in the last years. For example, UK government has introduced a called Capacity Market to ensure the UK's electricity supply can meet the demand in cases when the renewable generation cannot be used due to low wind, etc. and in order to reach the decarbonization of the UK for 2050. So, the Capacity Market is planned to prevent possible future blackouts during times when demand is high, or renewable generation is low. Due to the increase of the renewables in the UK energy mix Aurora Energy Research has estimated a needed increase in flex capacity up to 2050 in relation to the percentage of renewable production (Aurora Research, 2018). Two technologies that are planned to provide the major part of the flexibility in the UK case are Batteries and Gas reciprocating engines.




Figure 3: Flex capacity needs vs % Renewable Energy production (Aurora Research, 2018).

If the flexibility energy generation capability is low, then the percentage of renewables can drop from 80% to 40%. The flexibility and energy storage have the potential to save between £2 billion and £7 billion per year on average by 2030.

4. Reciprocating Gas Engines Fast Start Capabilities

It seems that two of the most key technologies for providing flexible capacity are going to be batteries, able to maintain load for 1-4 hours, and reciprocating gas engines. There are also other interesting technologies like hydrogen produced with the excess of renewable energy that could be stored and then supplied to the gas line for providing energy for example to reciprocating gas engines.

Batteries starts to be a suitable energy storage solution to assist with these challenges. Companies like Fluence, Tesla, etc. provide these systems and Fluence for example nowadays have a capacity of more than 700Mw available.

One of the biggest problems with batteries is that the energy supply is limited to 1-4hour and it is not so uncommon to have a week without wind in the UK that could affect energy system. So, it seems that also gas engines could provide that flexibility power generation only when needed at a low cost. Compared against low ramping capabilities of big turbine based combined cycle gas power plants reciprocating gas engines can start and provide full power in less than 30-60 seconds. They are not as fast as batteries and not suitable for continuous fast frequency grid correction but once they run, they are not limited to a small number of hours. Also, on a site made of several reciprocating engines several could be stopped while others run at full power at their highest efficient point, so the flexibility and modularity of a reciprocating engines plant is interesting. There is potential for development and R&D in order that those engines could be modified in the future for using other renewable fuels like hydrogen.

Siemens Gas Engine business has developed last year specific engine configurations optimized for different fast start capabilities and increased efficiency levels due to the UK demand. Below can be seen the power capabilities of an SGE-56SL Engine delivering full power (1Mw) in less than 30seconds. One of the key components added to the engine is an increased water preheating system so that the engine water temperature is hot enough in order to facilitate the full power capabilities in a short time and to reduce big thermal changes on mechanicals components that could reduce their lifespan. The major pros of a power plant made of gas engines against a turbine power plant are:

- **Modularity:** A fault on one engine does not affect the load capabilities of the rest.
- **Fast start:** Combined cycle power turbines normally have full power time around 30 minutes and are not able to operate properly below 30-40% of their load capabilities.
- **Decentralization concept:** As gas engines operates with low pressure admission gas needs it is not needed compression gas and the infrastructure is reduced reducing as well the CAPEX and OPEX.
- **Reduced load operation:** it is possible to operate the engines at reduced load operation. This makes ideal for compensating the intermittent renewable power generation.

On the contrary, in case long full power generation is needed running a combined cycle power plant has higher efficiencies and it is normally more reliable due to the turbine rotating machine concept compared against the stroke mechanism of the gas engines.

Siemens has done extensive test and fine-tuning control optimization to find a good starting capability in gas engines. Below are shown some results in the case of SGE-56SL engine configuration. The minimum reached time is 19.2 seconds, the maximum 30.6 seconds and the average 24 seconds. In the starting profile three phases can be differentiated. Phase 1: time from zero speed until engine is over 300rpms. Phase 2: time from 300 rpms until the engine is synchronized against the grid. Phase 3: time once the engine is synchronized up to full power. In the worst case, adding the worst cases per phase, 34.6 seconds have been reached. The total time was 25.2 seconds for the first start at the morning day and 23.8 seconds for the rest of the starts done during testing. The average start time is 5 seconds.



Figure 4: Power-ramp actual profile SGE-56SL Engine (Siemens Gas Engines).

The synchronization time is the one that varies the most. The tests have been done with the local network frequency conditions in Spain, which may vary in England. The phase 3 rise time once synchronized up to full is 7.5 seconds on average. If we look at the normal distribution and the accumulated one, we see that in 99% of the cases the start and full load is reached in less than 30 seconds. In 87% of the cases in less than 27 seconds and in 65% in less than 25 seconds.




Figure 5: SGE-56SL starting phases time analysis




Figure 6: Full time normal distribution (Siemens Gas Engines).

5. Conclusions

The results demonstrate the fast-starting capabilities of reciprocating engines with times from starting to full power that are less than 30 seconds. In the future there is potential developments so that the engines could use hydrogen instead of natural gas. Further test could be done with hydrogen in order to compare fast start capabilities.

References

- REE, 2018. https://www.ree.es/sites/default/files/11_PUBLICACIONES/Documentos/InformesSistemaElectrico/2019/Avance_ISE_2018_en.pdf
- Aurora Research, 2018. <https://www.nic.org.uk/wp-content/uploads/Power-sector-modelling-final-report-1-Aurora-Energy-Research.pdf>

Modeling of reciprocating renewable gas engines

Del Valle, J.^a, Lopez-Guede, J. M.^b

^a Siemens Energy Engines R&D, Vitoria, Spain, javier.del_valle@siemens.com, University of the Basque Country (UPV/EHU), Faculty of Engineering of Vitoria-Gasteiz, Department of Systems Engineering and Automatic Control, 01006 Vitoria-Gasteiz, Spain, javier.delvalle@ehu.eus, ORCID: <https://orcid.org/0000-0001-8485-7148>.

^b University of the Basque Country (UPV/EHU), Faculty of Engineering of Vitoria-Gasteiz, Department of Systems Engineering and Automatic Control, 01006 Vitoria-Gasteiz, Spain, jm.lopez@ehu.es, ORCID: 0000-0002-5310-1601.

To cite this article: Del Valle, J., Lopez-Guede, J. M. 2022. Modeling of reciprocating renewable gas engines. XVII Simposio CEA de Control Inteligente.

Abstract

Sewage and landfill reciprocating gas engines have proven to be a reliable energy power generation system when a proper maintenance schedule is done. The intrinsic nature of the stroke mechanism that creates parts movements and reciprocating masses supposes a challenge in order to improve maintenances schedules, reliability and availability. In the case of sewage and landfill gases that could not be properly cleaned, the engine reliability is more concerned. Asset monitoring systems that monitor and creates alerts when some variables are out of some limits are highly desirable. In this paper authors show how to create a virtual twin model from real data that could be optimized and compared in real time with working variables of the actual engines in order to predict future maintenance schedules and increase the engine availability. In sewage and landfill reciprocating gas engines this could have a positive impact of increasing the reliability and due to this, also the customer satisfaction. An accurate computational model is created taking some inputs and outputs to use it in an online cloud asset monitoring system so that it could be used as an extra supervisor agent.

Keywords: ECU, (Motor Control Unit), RDS (Remote Diagnosis System)

1. Introduction

Today gas engines are used mainly for power generation (including co-generations) and mechanical drive applications like compressors or pumps. In the case of power generation there are also different type of engine applications:

Continuous power generation: In this case the engines are running all day and as many hours as possible during the year in order to provide power. The fuel used can be natural gas but also other forms of gases like sewage, landfill or even hydrogen in the future. In these applications is also quite common to have co-generations that make use of the heat produced by the engine in order to maximize the plant efficiency.

Backup power generation: the engines are running just when there is no power from the grid. This is the application case of engines in hospitals, etc. In this application the engine runs a few hours a year but should be ready whenever the situation demands.

One of the key components in the gas engines today is the control system.



Figure 1: Siemens containerized CHP gen-set solution for Johannesburg, South Africa © Siemens

2. Background

The control systems in gas engines today are using an increasing number of sensors, actuators and have also to be integrated with other gen-sets devices. The control challenges

are also increasing with extra complexity due to the new needs of operating the engines in the highest efficient points. Also, the demand for increasing complex predictive algorithms, condition monitoring and engines supervision requires that the ECUs implements a variety of communications protocols based on TCP/IP like Modbus, OPC, etc. so that other system can extract that valuable information that has the ECUs.

The reality is that all the predictive algorithms are not able to run or fit in the ECU that controls and protects the engine. A digital twin or virtual ECU is needed that allows to complement the ECU algorithms with others based also on historic operating date, etc. (Yuan, 2018). At the same time although data is stored in the cloud the sampling capabilities and traffic demand does not allow to store data that has been sampled at a high rate like five milliseconds or 100 milliseconds. This means that the actual control systems should be complemented locally by an edge device that allows to run complex algorithms that requires higher sampling. This edge device then could transfer to the cloud condition and predictive monitoring system the data from the ECU and also the result or post-processing of the complex algorithms calculations that are run in the edge device. In this way the condition monitoring system or digital twin will have sampled at a slower rate (seconds) and extra data already post-processed coming from the edge device.

The virtual ECU or digital twin will then be the responsible for running different models and comparing the results of these models against the real engine (Wang, 2018). In this way the digital twin would detect deviations from the expected engine behavior. The digital twin should be also capable of comparing itself against other digital twin models of other similar engines so that deviations from the expected behavior of one engine against other similar engine running on the same site or on other site could create or raise also deviation.

3. Gas engine control system – main components

The gas engine control system has the following main components:

- control ECU: It is the brain of the gas engine control. Receives the values of different sensors and digital/analog signals like power setpoints, start/stop. Etc. It controls different actuators like throttles in order to control the engine speed or engine generated power.
- power relay box: It is a cabinet or system that has higher power contactors, relays, etc. for the ECU to command the higher electrical devices like engine starter, pumps or preheating system.
- Engine electrical harness: Connects the ECU to the rest of the components (sensors, actuators, interface connectors to the customer, ignition coils, etc.).
- Engine instrumentation: Sensors for monitoring the most important variables in order to protect and guarantee the engine performance (emissions). The sensors can be basic sensors like pressure,

temperature but. nowadays more advanced sensors that were just restricted for testbench environments are able to be used in the production engines like NOx Sensors, Combustion pressure sensors, etc.

- Throttles like the Mixture throttle that the ECU commands in order to produce more power when the engine is connected to the grid. The Gas valve throttle that the ECU commands in order to control the Air Fuel Ratio and engine emissions. The bypass valve throttle that the ECU commands in order to operate the turbocharger in an optimum operation point.

In the gas engines the ECU is also responsible for providing the spark through an ignition coils and spark plugs. The ECU controls the ignition timing in order to operate the engine in the highest efficiency operating point but avoiding knocking (knock sensors).

The ECU implements also a variety of protocols like J1939, CANopen, Modbus /TPC, OPC in order to integrate with different devices.




Figure 2: Simplified Model of Gas Engine control system.



Figure 3: © Siemens Energy - Gas Engine

4. Diagnostics Service Center - Concepts

Nowadays in order to increase the engine availability the industry provides normally reactive technical supports that has the following flow: The control system detects an issue. A warning or shutdown alarm is generated. The customer contacts technical support in order to solve or troubleshoot the issue so that the engine can be restarted and again at full power the maximum time.

The industry is transitioning to a more proactive support in which a digital twin or extra algorithms are run in a cloud or virtual environment (GE, 2016). The digital twin is receiving real time data from the engine control system in a secure way. Extra algorithms or supervision is done in this digital twin environment, for example, checking values against similar engines running on the same site. Deviations are raised in the remote diagnosis center and a proactive approach is done so that the customer is advised before a shutdown takes place maximizing engine availability.

The main benefits of proactive support are:

- Train performance improvements: As extra algorithms that complements the control system are used, it is possible to detect deviations against the normal operation profile and analyze and understand in a better way the engine status by looking at online data and historic data.
- Forced outage avoidance: The deviations can prevent a possible shutdown in some weeks.
- Forced outage transformed into a planned activity: As engine hours, etc. are monitored an outage request can be automatically raised and an offer can be submitted to the customer with enough time for planning resources and parts

4. Data acquisition options

Different redundant data acquisition systems are already used in gas engines to record data:

- ECU email data: The ECU is able to send emails with periodic and mortem data to some mail server.
- CAN J1939 data logger: The ECU is connected to a J1939 bus in which a local data logger is connected. This logger is able to record data at a high sampling rate. The main drawback is that it requires also time for connecting to the logger and downloading the files.
- PLC data log System: The ECU is connected to a PLC device that add extra genset controls or site controls. The PLC is able to log files into an SD card. Data is stored always locally but when the SD card is full previous data is lost. It requires time to download the files and analyze them
- Remote diagnosis system: A data collector is used to transmits the data in a safe way to a cloud/datacenter environment. The data collector takes data from the PLC and the PLC takes the data from the ECU. It is possible to perform predictive algorithms in the cloud environment and monitor the data by using a browser without the need to download files




Figure 4. Different data adquisition systems

5. Conclusions

Digital Twins from provide an extra layer of predictive protection to an asset. It allows triggering new deviations before the ECU could have a real. This is happening nowadays and will become more important in the future as machine learning systems are democratized. Business that understands the importance of this predictive/proactive approach will have a competitive advantage from others that are focused only in reactive support.

References

- Yuan He, Junchen Guo, Xiaolong Zheng School of Software and BNRist Tsinghua University. 2018. From Surveillance to Digital Twin: Challenges and Recent Advances of Signal Processing for Industrial IoT, IEEE Signal Processing Magazine 35(5):120-12 DOI:10.1109/MSP.2018.2842228
- Wang, Jinjiang & Ye, Lunkuan & Gao, Robert & Li, Chen & Zhang, Laibin. 2018. Digital Twin for rotating machinery fault diagnosis in smart manufacturing. International Journal of Production Research. 1-15. 10.1080/00207543.2018.1552032.
- GE, 2016. https://www.ge.com/digital/sites/default/files/download_assets/Digital-Twin-for-the-digital-power-plant-pdf?gecid=extref_dig_gepowercom