

ABSTRACT

Various desalination systems powered by renewable energy sources and using reverse osmosis technologies have been proposed to provide fresh water in remote, arid coastal locations. One approach used in some designs has been to maximize exploitation of the renewable energy source and minimize the need to use energy storage systems. With this in mind, several strategies have been considered which aim to optimize the non-steady state operation of seawater reverse osmosis (SWRO) desalination plants. In this PhD thesis a prototype of SWRO desalination plant is designed and developed for continuous adjustment of its energy consumption to the widely varying power generated by a stand-alone wind turbine. An innovative control system, based on artificial intelligence techniques is implemented and applied to manage the variable operation of the SWRO plant. Also, three machine learning techniques have been compared with a view to determining which technique best simulates the performance of the system. Finally, a simulation of the desalination plant prototype was done to work under variable conditions, adapting its energy consumption to the varying nature of the energy generated by a wind turbine used to power it. The obtained results in this thesis validate the feasibility of increasing the energy consumption flexibility in a widely used process like a reverse osmosis desalination process. The results also validate the great value of the use of machine learning techniques for that. Likewise, it is verified that the use of these techniques allow the simulation of the process. The results of this simulation demonstrated that the variable operation reduces the number of interruptions in the process against the use of a constant rate operation strategy in desalination plant.

TESIS DOCTORAL

Group for the Research on Renewable Energy Systems



GESTIÓN INTELIGENTE DE UN SISTEMA DE DESALACIÓN POR ÓSMOSIS INVERSA ACCIONADO CON ENERGÍA EÓLICA

SMART ENERGY MANAGEMENT SYSTEM FOR A WIND-DRIVEN
REVERSE OSMOSIS DESALINATION PLANT

Pedro Cabrera

Las Palmas de Gran Canaria, diciembre de 2017



UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA
ESCUELA DE INGENIERÍAS INDUSTRIALES Y CIVILES
DOCTORADO EN INGENIERÍAS QUÍMICA, MECÁNICA Y DE FABRICACIÓN

TESIS DOCTORAL

GESTIÓN INTELIGENTE DE UN SISTEMA DE
DESALACIÓN POR ÓSMOSIS INVERSA ACCIONADO
CON ENERGÍA EÓLICA

Pedro Cabrera

Directores:

Prof. Dr. D. José Antonio Carta González

Dr. D. Jaime González Hernández

LAS PALMAS DE GRAN CANARIA, DICIEMBRE 2017



UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA
Escuela de Doctorado

LA DRA. DÑA. MARÍA DOLORES MARRERO ALEMÁN, SECRETARIA DEL PROGRAMA DE DOCTORADO EN INGENIERÍAS QUÍMICA, MECÁNICA Y DE FABRICACIÓN DE LA UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA,

CERTIFICA,

Que la Comisión Académica del Programa de Doctorado tomó el acuerdo de dar el consentimiento para su tramitación a la tesis doctoral titulada *Gestión inteligente de un sistema de desalación por ósmosis inversa accionado con energía eólica*, presentada por el doctorando D. Pedro Cabrera y dirigida por los Doctores D. José Antonio Carta González y D. Jaime González Hernández.

Y para que así conste, a efectos de lo previsto en el reglamento de Estudios de Doctorado de esta Universidad, firmo la presente en Las Palmas de Gran Canaria, a 11 de diciembre de 2017.

Fdo.: Dra. Dña. María Dolores Marrero Alemán



UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA
ESCUELA DE INGENIERÍAS INDUSTRIALES Y CIVILES
DOCTORADO EN INGENIERÍAS QUÍMICA, MECÁNICA Y DE FABRICACIÓN

GESTIÓN INTELIGENTE DE UN SISTEMA DE
DESALACIÓN POR ÓSMOSIS INVERSA ACCIONADO
CON ENERGÍA EÓLICA

Memoria presentada, en cumplimiento de los requisitos para optar al título oficial de DOCTORADO EN INGENIERÍAS QUÍMICA, MECÁNICA Y DE FABRICACIÓN por el Ingeniero Industrial e Ingeniero en Automática y Electrónica Industrial,
Pedro Cabrera

Trabajo dirigido por el Prof. Dr. D. José Antonio Carta González y el Dr. D. Jaime González Hernández

El autor

Los directores

Las Palmas de Gran Canaria, diciembre 2017

Gestión inteligente de un sistema de desalación por ósmosis inversa accionado con energía eólica –*Smart energy management system for a wind-driven reverse osmosis desalination plant*. Tesis con mención internacional.

Autor: D. Pedro Jesús Cabrera Santana

Directores: Prof. Dr. D. José Antonio Carta González

Dr. D. Jaime González Hernández

Text printed in Las Palmas de Gran Canaria
First edition, diciembre 2017

A mis tres *referencias*,
Daura, Alonso y Amalia.

Resumen

Con el objetivo de suministrar agua potable en zonas áridas-remotas y costeras se han propuesto diversos sistemas de desalación con tecnologías de ósmosis inversa accionados mediante fuentes energéticas renovables. En algunas de estas propuestas se ha buscado el aprovechamiento del máximo recurso energético renovable, tratando de minimizar la implementación de sistemas de almacenamiento de energía. Para ello, se han planteado diversas estrategias que buscan facilitar la operación en régimen variable de estas plantas desalinizadoras.

En esta tesis se desarrolla un prototipo de planta desalinizadora que emplea la tecnología de ósmosis inversa y que ha sido diseñado para adaptar, de forma variable, su consumo energético a una amplia variación de energía producida por una turbina eólica. Se implementa un sistema de control novedoso, basado en técnicas de inteligencia artificial, que consigue la variación de los parámetros de operación de la planta y logra el ajuste energético buscado. También, se evalúan tres técnicas de *machine learning* para señalar la que mejor modela el comportamiento del prototipo. Con ella se simula el funcionamiento de la planta desalinizadora en estudio y se compara su desempeño con el funcionamiento de otro prototipo similar pero integrado en una micro-red eléctrica que emplea baterías y opera en régimen constante.

Con los resultados obtenidos, se demuestra la viabilidad de flexibilizar el consumo energético en un proceso tan ampliamente utilizado como es el proceso de ósmosis inversa y se comprueba la gran utilidad que ofrecen las técnicas de *machine learning* para ello. Asimismo, se demuestra que el uso de estas técnicas permite la simulación del proceso de forma eficaz. Al simular el prototipo desarrollado se demuestra que el modo de operación variable reduce la interrumpibilidad del prototipo frente a la operación de la planta desalinizadora en régimen constante.

Abstract

Various desalination systems powered by renewable energy sources and using reverse osmosis technologies have been proposed to provide fresh water in remote, arid coastal locations. One approach used in some designs has been to maximize exploitation of the renewable energy source and minimize the need to use energy storage systems. With this in mind, several strategies have been considered which aim to optimize the non-steady state operation of seawater reverse osmosis (SWRO) desalination plants.

In this PhD thesis a prototype of SWRO desalination plant is designed and developed for continuous adjustment of its energy consumption to the widely varying power generated by a stand-alone wind turbine. An innovative control system, based on artificial intelligence techniques is implemented and applied to manage the variable operation of the SWRO plant. Also, three machine learning techniques have been compared with a view to determining which technique best simulates the performance of the system. Finally, a simulation of the desalination plant prototype was done to work under variable conditions, adapting its energy consumption to the varying nature of the energy generated by a wind turbine used to power it .

The obtained results in this thesis validate the feasibility of increasing the energy consumption flexibility in a widely used process like a reverse osmosis desalination process. The results also validate the great value of the use of machine learning techniques for that. Likewise, it is verified that the use of these techniques allow the simulation of the process. The results of this simulation demonstrated that the variable operation reduces the number of interruptions in the process against the use of a constant rate operation strategy in desalination plant.

Agradecimientos

En determinados momentos, todos recordamos alguna historia que escuchamos en nuestra infancia. Dependiendo de la habilidad que posea el interlocutor, seremos capaces de recordar viejas historias que, pudiendo ser banales, se transmitieron con una intensidad y una emoción dignas de recuerdo. Todas las historias que mi padre me contaba, o contaba en mi presencia, eran dignas de recuerdo. Siempre divertidas, emocionantes y exageradas, todas estimulaban mi curiosidad por el mundo que nos rodea. Lo más destacable para mí, quizás, era que en ellas siempre intervenía la expresión que alguno de los sentidos hacía en la naturaleza. Era común verlo detener la trama para escuchar atentamente el sonido de un pájaro en un acantilado, sentir el frío aire de la brisa marina cerca de la costa o saborear el salado café hecho con la última agua extraída de los fondos de un pozo playero.

En algunas zonas de Canarias, nuestros antepasados e, incluso, algunos de nuestros padres han pasado por épocas en las que el café tenía sabor a sal. Afortunadamente, para mí, la historia del café salado es sólo una historia, un cuento de la infancia. Que así sea, se debe gracias a personas como mi padre. Pero también gracias a personas como mis dos directores de tesis, José Antonio Carta y Jaime González. A ambos, les debo una fortuna en cafés (estos hechos con agua potable), pero el agradecimiento que quiero expresarles en estas líneas no es por todas las veces que me han invitado. Puedo señalar que esos cafés, las charlas de cada mañana, sus esfuerzos, sus palabras de aliento y su inspiración, me han servido para ilustrarme y para forjar una relación sincera de amistad con ellos. Sin embargo, mi sentimiento de gratitud va un poco más allá pues considero que, en esta tierra inhóspita en conocimiento, han conseguido crear un oasis con sus propios medios y me han enseñado a continuar con su labor. En este sentido, quiero resaltar especialmente el compromiso que José Antonio ha mostrado conmigo desde el primer día y siento la necesidad de agradecerle personalmente todo su ímpetu para que yo me desarrolle y progrese como persona y como investigador.

Se puede decir que investigar, hoy en día, es una tarea ultracompetitiva que exige incontables y costosos recursos. Desde aquí, con una infraestructura mínima, con multitud de trabas y sin aspavientos, no sólo se han logrado resultados de primer nivel, sino que se está construyendo una fuente abundante de conocimiento.

Durante este tiempo he sido testigo de como se ha creado de la nada el *Group for the Research on Renewable Energy Systems (GRRES)*, al cuál además de José Antonio -su impulsor- y Jaime, se han unido investigadores como Sergio Velázquez, Julieta Schallenberg, Ana M^a Blanco-Marigorta y Alexis Lozano. Sin lugar a dudas todos ellos disponen de grandes aptitudes investigadoras pero también destacan como personas. Este grupo de investigación está vinculado al Departamento de Ingeniería Mecánica de la ULPGC, del cual también me siento afortunado de formar parte. Me gustaría destacar especialmente el apoyo que he recibido por parte de Óscar Martel y la ayuda que me ha prestado Alberto Cuadrado, en determinadas etapas del doctorado. Asimismo expreso mi gratitud hacia Ricardo Ibañez, por ayudarme con la puesta a punto de varios equipos y hacia Ana Fortes y Eduardo López, por el diverso trabajo administrativo realizado.

No sin esfuerzo, también en el Instituto Tecnológico de Canarias (ITC) existen personas que dedican su día a día a construir unas bases sólidas que generen conocimiento aplicado, transferible y útil para que el crecimiento de las Islas Canarias no se limite al sector turístico. Allí, desde hace varios años, el Departamento de Agua, dirigido por Baltasar Peñate, viene desarrollando una labor encomiable que mantiene viva una continua colaboración con nuestro equipo de investigación. Gracias a ello, he podido ver como ambas instituciones han sorteado innumerables escollos para ir de la mano en convocatorias regionales, nacionales y europeas y lograr proyectos gracias a los cuales se han construido prototipos experimentales como el analizado en esta tesis. Del equipo humano que forma el ITC, me gustaría resaltar la importante y desinteresada contribución que ha hecho Gustavo Melián a esta tesis. Él se ha convertido en un gran amigo, sin el cuál hubiera sido mucho más difícil - si no imposible - terminar este trabajo. También quisiera agradecer la paciencia que Antonio Suárez tuvo conmigo y el trato, siempre atento, recibido por parte de Juan Antonio de la Fuente y de Vanessa Millán, preocupada de darle gran difusión a este trabajo.

Por suerte, dentro del ámbito científico-académico también existen islas que, como la isla de Utopía de Tomás Moro, pueden servirnos como ideal a los que queremos dedicar nuestros esfuerzos a la I+D. Desde ellas ya brota un conocimiento exquisito hacia las sociedades que las nutren y hacia el mundo en su conjunto. Una de estas islas utópicas es la Universidad de Aalborg (Dinamarca). Desde allí, el Prof. Henrik Lund junto con todo el equipo de *planners* que forman el *Sustainable Energy Planning Research Group* generan un conocimiento indispensable para que este planeta se convierta en un lugar más habitable. Aparte de que, la generosidad de Henrik ha sido increíble -ya que en mi estancia en Dinamarca me acogió como a uno más de su equipo y me trató como a un verdadero amigo- él y su teoría de la Elección Consciente (*Choice Awareness Theory*) me ayudaron a romper muchas de las fronteras que han limitado mi conocimiento en el campo de la planificación

energética. Por todo ello le doy las gracias. También a todo su equipo de Aalborg: Jakob Zinck Tellufsen, Søren Djørup, Peter Sorknæs, Steffen Nielsen, Silas Petersen, Louise Jensen y Hanna Mareike. A Frede Hvelplund, por las interesantes conversaciones mantenidas durante los almuerzos. Además, quiero destacar toda la ayuda que me brindaron Paulina y Karl, no sólo en Aalborg sino posteriormente también.

Finalmente, deseo darle las gracias a aquellas personas que, no contribuyendo directamente a mi formación doctoral, sí han resultado esenciales para que ella se produjera. En este sentido, quiero expresar la enorme gratitud que siento hacia Nieves Hernández y hacia Roque Suárez, quienes se han convertido en un pilar fundamental para nuestra pequeña familia. Sin su ayuda, completamente desinteresada, sin sus consejos y sin su apoyo, esto hubiera sido sencillamente imposible.

Por otro lado, quiero enfatizar el agradecimiento especial que siento hacia mis amigos: Domingo Alemán, Juan Sánchez, Rafa López, Gustavo Hernández, Gustavo Melián, Josué Suárez, Adán León, Francisco Santana y al Dr. Rosales-Asencio.

En un plano más personal, no encuentro suficientes palabras de agradecimiento para Daura, mi mujer. Cuando pienso en toda la paciencia que ha tenido y en su capacidad para manejar el día a día con entereza, no puedo dejar de expresar mi más absoluta admiración hacia su persona. Cada día me demuestra con hechos que el amor, la disciplina, la constancia, la cordura y la paciencia pueden mejorar el mundo, el nuestro y el de los afortunados niños que pasan por su vida. Sólo su presencia hace este mundo mejor.

No me olvido del tiempo que les he tomado prestado a mis dos hijos, Alonso y Amalia, y agradezco la fortuna que siento siempre que llego a casa y me reciben con esa alegría que les caracteriza. Además, quiero destacar la magnífica aportación que han hecho a esta tesis con el dibujo que se observa a continuación. En él se expresa el punto de vista que ellos tienen de mi trabajo durante los últimos años.



Pedro,
diciembre 2017

Índice general

Índice de figuras	XV
Índice de tablas	XXIII
1. Introducción	1
1.1. Objetivos generales de la tesis doctoral	5
1.2. Metodología	6
1.3. Estructura de la tesis doctoral	6
1. Introduction	11
1.1. Overall aims of the PhD thesis	15
1.2. Methodology	17
1.3. PhD thesis structure	17
2. Revisión de los sistemas de desalación de ósmosis inversa accionados con energía eólica	21
2.1. Introducción	21
2.2. Propuestas de plantas desalinizadoras accionadas con energía eólica que operan en régimen variable	24
2.3. Utilización de técnicas de <i>Machine Learning</i> en sistemas de desalación	33
3. Descripción de los equipos utilizados para el desarrollo y la gestión variable de un prototipo de planta desalinizadora	41
3.1. Introducción	41
3.2. Descripción del prototipo	42
3.2.1. Descripción del prototipo inicial. Materiales de partida	42
3.2.2. Esquema general del sistema completo	45
3.2.3. Nuevo sistema de desalinización propuesto. Diseño del prototipo empleado	47

3.3. El esquema de control utilizado	51
4. Estudios preliminares que permiten la implementación de estrategias de gestión inteligente en el prototipo de planta desalinizadora desarrollado	57
4.1. Introducción	57
4.2. Determinación de los límites teóricos admisibles de operación del prototipo de planta de ósmosis inversa	58
4.3. Estrategias de operación para lograr la producción de agua en régimen variable	61
4.4. Análisis de las potencias eléctricas de origen eólico	69
4.5. Aplicación de funciones de regresión polinómicas para generar las consignas que permiten gestionar la potencia eléctrica consumida por el prototipo y adaptarla al recurso eólico variable	72
4.5.1. Generación de las presiones y caudales de referencia	73
4.5.2. Ensayos experimentales de operación variable de la planta desalinizadora incorporando modelos de regresión no lineales en el sistema de control	77
4.5.3. Análisis de resultados obtenidos de los ensayos experimentales realizados	79
5. Descripción de las técnicas de <i>Machine Learning</i> consideradas en este trabajo de investigación	85
5.1. Introducción	85
5.2. Redes Neuronales Artificiales (ANNs)	86
5.3. Máquinas de Vectores Soporte (SVMs)	93
5.4. <i>Random Forests</i> (RFs)	98
6. Redes Neuronales Artificiales para la gestión variable del prototipo de planta desalinizadora considerado	103
6.1. Introducción	103
6.2. Materiales	105
6.2.1. Equipamiento utilizado	105
6.2.2. Equipos adicionales instalados en el sistema para modificar las características del agua de alimentación y estudiar nuevas estrategias de gestión inteligente	106
6.2.3. Intervenciones del sistema de control	106
6.3. Metodología	109
6.3.1. Descripción del proceso de obtención de datos operativos de la planta desalinizadora	109
6.3.2. Selección, entrenamiento y evaluación de los modelos ANN	111

6.3.2.1.	Arquitectura de la red neuronal seleccionada . . .	113
6.3.2.2.	Métricas utilizadas para evaluar los diferentes modelos estudiados	115
6.3.2.3.	Proceso de diseño, optimización y evaluación de las redes neuronales seleccionadas	116
6.3.3.	Aplicación experimental de los modelos ANN seleccionados	123
6.4.	Análisis y discusión de los resultados obtenidos	127
6.4.1.	Análisis de los modelos ANN seleccionados	127
6.4.2.	Análisis de los errores generados en los ensayos experimentales	128
7.	Comparación de tres técnicas de <i>Machine Learning</i> usadas para modelar y simular del funcionamiento del prototipo considerado	143
7.1.	Introducción	143
7.2.	Materiales	144
7.2.1.	Variables y modelos a implementar	144
7.2.2.	Datos utilizados	145
7.3.	Metodología empleada en el entrenamiento, ensayo, validación y evaluación estadística de los cuatro modelos de simulación considerados	147
7.3.1.	Validación cruzada con ajuste de hiperparámetros	149
7.3.2.	Ensayo de hipótesis estadística de las métricas obtenidas por cada uno de los modelos para determinar si existe diferencia significativa entre modelos	150
7.4.	Análisis y discusión de los resultados obtenidos	151
8.	Simulación del prototipo empleando una técnica de <i>Machine Learning</i> y comparación de su funcionamiento en régimen variable y en régimen constante	159
8.1.	Introducción	159
8.2.	Materiales	163
8.2.1.	Descripción de las micro-redes	163
8.2.2.	La técnica de <i>Machine Learning</i> considerada para realizar la simulación	166
8.2.3.	Características de los datos de viento usados en las simulaciones	167
8.3.	Metodología	167
8.3.1.	Simulación de la operación de la MG-2	167
8.3.2.	Simulación de la operación de la MG-1	170
8.4.	Análisis y discusión de los resultados alcanzados al comparar el funcionamiento de las dos micro-redes	171

9. Conclusiones	179
9.1. Aportaciones que hace esta tesis doctoral al cuerpo del conocimiento	179
9.2. Conclusiones	182
9.3. Líneas futuras de investigación propuestas	183
9. Conclusions	189
9.1. Contributions of this PhD thesis to the body of knowledge	189
9.2. Conclusions	191
9.3. Future proposed research lines	193
Bibliografía	199
A. Papers published during PhD	223
B. Conferences contributions	229
C. Book chapter	233

Índice de figuras

1.1.	Clasificación de las soluciones existentes en la literatura científica para accionar plantas de ósmosis inversa mediante energía eólica. . .	3
1.2.	Esquema metodológico del trabajo de investigación realizado. . .	7
1.3.	Estructura de la tesis y cómo las distintas contribuciones se relacionan con los capítulos.	9
1.1.	Current solutions found in scientific literature for operating seawater reverse osmosis desalination plants using wind energy (fluctuating renewable energy source)	13
1.2.	Methodological diagram of the research work developed in this PhD.	18
1.3.	Structure of PhD thesis and how the appendices relates to chapters.	20
2.1.	Clasificación de Lai et al. [1] de las soluciones en la literatura científica para accionar plantas de ósmosis inversa mediante energía eólica.	23
2.2.	Márgenes operativos calculados por Feron en 1985 [2].	26
2.3.	Esquema del sistema autónomo propuesto por Feron en 1985 [2] para desalinizar agua de mar accionando una planta de ósmosis inversa mediante energía eólica y haciendo operar dicha planta en régimen variable con una velocidad del viento V (V_c y V_f , son las velocidades de corte inferior y superior de la turbina, respectivamente).	27
2.4.	Márgenes operativos calculados por Warfel et al. [3].	28
2.5.	Diagrama de flujos energéticos del sistema propuesto por Thomson et al. [4] y Miranda & Infield [5] para accionar una planta de OI y adaptar su funcionamiento a una potencia eólica variable.	29
2.6.	Área operativa calculada por Pohl et. al [6].	30
2.7.	Análisis llevado a cabo por Pohl et. al [6] al simular las cuatro estrategias propuestas para operar un sistema de desalación de agua en régimen variable dentro de un área operativa segura (SOW). . .	31

2.8. Diagrama equemático del sistema de membranas accionado por energía eólica desarrollado por Park et. al [7] y empleado en los estudios [7–12].	32
2.9. Plannta desalinizadora de ósmosis inversa empleada por Al-Shayji & Liu [13] y procedimiento propuesto por los autores para configurar las redes neuronales que predicen el comportamiento de dicha planta.	35
2.10. Procedimiento que siguen Jafar & Zilouchian [14, 15] para configurar las redes neuronales que utilizan.	36
2.11. Estructura de la ANN empleada por Murthy & Vora [16] para modelar y simular el comportamiento de una planta desalinizadora por ósmosis inversa.	37
2.12. Diagrama del diseño empleado por Abbas & Al-Basaki [17] para capturar los datos de entrenamiento que sirven para la configuración de las ANNs empleadas por los autores.	38
2.13. Diagrama esquemático de la ANN utilizada por Lee et al. [18]	39
3.1. Localización de los elementos principales del proyecto en la parcela de Pozo Izquierdo.	42
3.2. Esquema del sistema eólico para desalación de agua de mar denominado AEROGEDESA.	43
3.3. Esquema hidráulico de de la planta desalinizadora empleada en el proyecto AEROGEDESA.	45
3.4. Diagrama general del sistema eólico global para la desalación de agua de mar en régimen variable. De este sistema global, que se encuentra en desarrollo, se muestra el subsistema objeto de análisis en esta tesis encerrado en líneas discontinuas.	46
3.5. Sistema global con interruptores A y B que posibilitan la conexión y desconexión a la red eléctrica convencional del subsistema objeto de análisis en esta tesis.	47
3.6. Esquema hidráulico general del nuevo prototipo de planta desalinizadora empleado en esta tesis.	48
3.7. Diagrama del esquema de control empleado en la planta desalinizadora.	52
3.8. Curva de potencia del aerogenerador Vergnet 10/15.	53
3.9. Estados operativos de la planta desalinizadora.	54
3.10. Diagrama de flujo de la toma de decisiones del sistema de control empleado.	55

4.1. Área teórica de operación de un tubo y dos tubos de presión de la planta desalinizadora cuando los TDS y la temperatura del agua de mar a la entrada de las membranas son 37332 mg/l y 25°C, respectivamente.	59
4.2. Área teórica de operación de la planta de OI representada en un sistema de ejes cartesianos, donde se observan la potencia demandada por la planta de OI y el caudal de agua producida (Concentración de agua de mar=37332 mg/l; Temperatura=25°C; Rendimiento del sistema=70 %)	60
4.3. Área teórica de operación de la planta de OI representada en un sistema de ejes cartesianos, donde se observan la potencia demandada por la planta de OI y el consumo específico de energía (Concentración de agua de mar=37332 mg/l; Temperatura=25°C; Rendimiento del sistema=70 %)	63
4.4. Límites teóricos de presión y caudal de alimentación admisibles de la planta desalinizadora en función de las combinaciones más extremas de los intervalos de temperaturas y concentraciones (20°C-39800 mg/l y 25°C-35200 mg/l).	64
4.5. Límites teóricos de la potencia de accionamiento admisible por planta desalinizadora en función de las combinaciones más desfavorables de los intervalos de temperaturas y concentraciones (20°C-39800 mg/l y 25°C-35200 mg/l), estimado un rendimiento del 70 %.	65
4.6. Caudal producto teórico producido por la planta desalinizadora en función de las combinaciones más desfavorables de los intervalos de temperaturas y concentraciones (20°C-39800 mg/l y 25°C-35200 mg/l), considerando un rendimiento del 70 %.	66
4.7. Concentración del agua producto y consumo específico de energía teóricos de la planta desalinizadora en función de las combinaciones más desfavorables de los intervalos de temperaturas y concentraciones (20°C-39800 mg/l y 25°C-35200 mg/l), considerando un rendimiento del 70 %.	67
4.8. a) Curva de potencia de la turbina eólica Vergnet- GEV10/15 utilizada para la simulación de la generación de potencia eólica. b) Histograma experimental de las velocidades de viento registradas en el lugar y funciones de densidad de probabilidad ajustadas al mismo.	70

4.9. Frecuencias de varios intervalos (0-0.5 m/s a 1.5-2.0 m/s) de las diferencias absolutas $\Delta_i = v_i - v_{i+1} $ obtenidas entre los datos consecutivos de la serie de velocidades medias (cada minuto) del viento registradas en el año 2010 en la zona de estudio, en función de varios intervalos (4-4.5 m/s a 10-10.5 m/s) de la velocidad del viento v_i	72
4.10. Representación de las funciones de transferencia experimentales de la planta desalinizadora, que relacionan la potencia consumida con las presiones y caudales de alimentación para una tasa de recuperación comprendida en el intervalo 13.5 % y 13.6 % y una concentración y temperatura del agua de alimentación a la entrada a las membranas de 37170 mg/l TDS y 23°C, respectivamente. . .	74
4.11. Representación del rendimiento experimental del sistema en función de la potencia consumida, para una tasa de recuperación comprendida en el intervalo 13.5 % y 13.6 % y una concentración y temperatura del agua de alimentación a la entrada a las membranas de 37170 mg/l TDS y 23°C, respectivamente.	76
4.12. Representación del factor de potencia experimental del sistema en función de la potencia consumida, para una tasa de recuperación comprendida en el intervalo 13.5 % y 13.6 % y una concentración y temperatura del agua de alimentación a la entrada a las membranas de 37170 mg/l TDS y 23°C, respectivamente.	77
4.13. Evolución de la concentración del flujo de permeado según se incrementa el intervalo de tiempo en que la planta de OI opera con dos tubos de presión en condiciones de potencia generada (con presión y caudal de referencia de 50.5 bar y 5.3 m ³ /h, respectivamente) y condiciones del agua de alimentación (23°C, 37160 mg/l) constantes.	78
4.14. Evolución en el tiempo de la temperatura del motor eléctrico, cuando éste trabaja a baja velocidad de rotación con un solo tubo de presión conectado, y cuando funciona a más alta velocidad de rotación, con la planta de OI operando con los dos tubos de presión conectados.	79
4.15. a) Potencias objetivo y oscilaciones medidas de la potencia consumida por la planta desalinizadora en función del tiempo de operación. b) Presiones de referencia y oscilaciones respecto de las mismas de las presiones de operación medidas en la planta desaladora en función del tiempo de operación. c) Caudales de agua de mar alimentación de referencia y oscilaciones respecto de los mismos de los caudales reales de operación medidos en la planta de OI en función del tiempo de operación.	80

4.16. a) Caudales de permeado y de rechazo medidos durante el tiempo que ha operado la planta de OI bajo las condiciones representadas en la Figura 4.15. b) Tasa de recuperación de permeado registrados durante el tiempo que ha operado la planta de OI bajo las condiciones representadas en la Figura 4.15. c) Concentración instantánea del flujo de permeado registrada durante el tiempo que ha operado la planta de PI bajo las condiciones representadas en la Figura 4.15.	81
5.1. Esquema de una unidad de proceso típica [19].	87
5.2. Esquema de una red neuronal artificial (ANN) de tres capas y una salida.	88
5.3. Esquema de transformación de espacios de una SVM. Fuente: [20].	93
5.4. Ajuste de un problema lineal empleando regresión mediante una SVM. Fuente: [21].	94
5.5. Arquitectura de la Máquina de Vector Soporte. Fuente: [22]. . . .	96
5.6. Ejemplo de árbol resultante de un algoritmo CART que estima el porcentaje de supervivencia de un pasajero a bordo del Titanic en función de su edad, género, la clase en la que viajaba y el tamaño de la unidad familiar. Fuente: [23].	98
5.7. Diagrama explicativo de la técnica de <i>Bagging</i>	101
6.1. Planta desalinizadora de ósmosis inversa usada para los estudios descritos en este apartado.	105
6.2. Esquema hidráulico del nuevo prototipo de planta desalinizadora con los equipos adicionales instalados para el estudio de nuevas estrategias de gestión inteligente.	107
6.3. Diagrama de actuación del sistema de control de la planta desalinizadora.	109
6.4. Entradas, salidas y datos de entrenamiento de los cuatro modelos de cada técnica de <i>Machine Learning</i> implementado.	113
6.5. Diagrama esquemático de la arquitectura de red neuronal empleada, con tres neuronas en la capa de entrada, dos capas ocultas (con NHN-1 y NHN-2 número de neuronas, respectivamente) y una neurona en la capa oculta (presión de referencia o caudal de referencia).	114
6.6. Diagrama de bloques con la representación esquemática de la metodología empleada en el diseño y la evaluación de las ANNs seleccionadas.	119
6.7. Factor de características del agua de alimentación.	124
6.8. Factor de características del agua de alimentación y factor de potencias de operación de referencia.	124

6.9. Obtención de la muestra aleatoria de potencias operativas usando la función de distribución de viento que representa el régimen eólico en la localización del prototipo.	126
6.10. Nivel L-1. a) Potencias consumidas de referencia y oscilaciones medidas de la potencia consumida por la planta de OI vs. tiempo de operación. b) Presiones de referencia y oscilaciones de las presiones reales medidas en la planta de OI vs. tiempo de operación de la planta. c) Caudales de referencia y oscilaciones de los caudales reales medidos en la planta de OI vs. tiempo de operación de la planta. d) Tasa de recuperación de permeado registrada para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c). e) Caudales de permeado y rechazo registrados para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c).	129
6.11. Nivel L-2. a) Potencias consumidas de referencia y oscilaciones medidas de la potencia consumida por la planta de OI vs. tiempo de operación. b) Presiones de referencia y oscilaciones de las presiones reales medidas en la planta de OI vs. tiempo de operación de la planta. c) Caudales de referencia y oscilaciones de los caudales reales medidos en la planta de OI vs. tiempo de operación de la planta. d) Tasa de recuperación de permeado registrada para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c). e) Caudales de permeado y rechazo registrados para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c).	130
6.12. Nivel L-3. a) Potencias consumidas de referencia y oscilaciones medidas de la potencia consumida por la planta de OI vs. tiempo de operación. b) Presiones de referencia y oscilaciones de las presiones reales medidas en la planta de OI vs. tiempo de operación de la planta. c) Caudales de referencia y oscilaciones de los caudales reales medidos en la planta de OI vs. tiempo de operación de la planta. d) Tasa de recuperación de permeado registrada para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c). e) Caudales de permeado y rechazo registrados para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c).	131

6.13. Nivel L-4. a) Potencias consumidas de referencia y oscilaciones medidas de la potencia consumida por la planta de OI vs. tiempo de operación. b) Presiones de referencia y oscilaciones de las presiones reales medidas en la planta de OI vs. tiempo de operación de la planta. c) Caudales de referencia y oscilaciones de los caudales reales medidos en la planta de OI vs. tiempo de operación de la planta. d) Tasa de recuperación de permeado registrada para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c). e) Caudales de permeado y rechazo registrados para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c).	132
6.14. Histograma y diagrama de bigotes de los valores instantáneos de tasa de recuperación de permeado obtenidos en los cuatro ensayos realizados.	134
6.15. Correlograma de cada una de las series de datos de los cuatro niveles del factor de características de agua de mar. a) Nivel L-1, b) Nivel L-2, c) Nivel L-3, d) Nivel L-4. Las figuras a la izquierda se construyeron usando los errores MAE y las de la derecha usando los errores MAPE.	140
6.16. Diagramas de probabilidad contruidos con los coeficientes de autocorrelación obtenidos con las series de datos de los cuatro niveles del factor de características de agua de mar. a) Nivel L-1, b) Nivel L-2, c) Nivel L-3, d) Nivel L-4. Las figuras a la izquierda se construyeron usando los errores MAE y las de la derecha usando los errores MAPE.	141
6.17. Diagrama de bigotes hecho con las muestras de datos de los bloques del factor de potencias de operación de referencia. a) Errores MAE, b) errores MAPE. Las figuras de la izquierda corresponden a la muestra de los bloques con numeración impar. Las figuras de la derecha corresponden a la muestra de los bloques con numeración par.	142
7.1. Variables de entrada, modelos y variables de salida obtenidas para cada uno de los parámetros a modelar.	146
7.2. Representación esquemática de la metodología empleada para comparar las tres técnicas de Machine Learning consideradas en esta tesis.	156
7.3. Representación esquemática de la validación cruzada con el ajuste de hiperparámetros llevado a cabo.	157

7.4. Valores medios y desviaciones estándar de las métricas MAE y MAPE obtenidas de la validación cruzada cuando se han estimado las variables objetivo con los cuatro modelos analizados (con las tres técnicas de ML consideradas), en el caso de usar uno o dos tubos de presión.	158
8.1. Esquema general del la micro-red llamada AEROGEDESA.	164
8.2. Esquema general del la micro-red llamada MG-2.	165
8.3. a) Histogramas de frecuencias de velocidades de viento, b) velocidades medias horarias, c) velocidades medias mensuales y d) patrón intra-día de velocidades de viento.	168
8.4. Diagrama de bloques representativo del proceso seguido para simular el comportamiento temporal anual de la MG-2.	169
8.5. Diagrama de bloques representativo del proceso seguido para simular el comportamiento temporal anual de la MG-1.	170
8.6. Porcentajes de operación mensual del prototipo de planta desalinizadora en función de la micro-red (MG-1 o MG-2) en la que esté integrado.	172
8.7. Relación entre las frecuencias de arranques/paradas de la planta desalinizadora de la MG-1 y las frecuencias de arranques/paradas de los tubos de presión de la planta desalinizadora de la MG-2.	173
8.8. Caudales medios mensuales de agua producto obtenidos en las simulaciones realizadas con las dos micro-redes.	174
8.9. Conductividades medias mensuales obtenidas en las simulaciones realizadas con las dos micro-redes.	175
8.10. Presiones de operación medios, máximos y mínimos registrados cada mes.	175
8.11. Caudales de operación medios, máximos y mínimos en cada mes.	176
8.12. Simulación del comportamiento de las micro-redes (MG-1 y MG-2) en un día con una velocidad media del viento elevada.	177

Índice de tablas

2.1. Sistemas de desalación de ósmosis inversa (OI) accionados por energía eólica [24, 25].	22
3.1. Resumen de las principales características de la planta desalinizadora empleada en el proyecto AEROGEDESA.	44
3.2. Características de las membranas Toray utilizadas en el prototipo.	50
3.3. Características del convertidor de frecuencia utilizado (Omron Varispeed F7).	50
4.1. Parámetros de la mezcla de distribuciones de Weibull y normal truncada simple.	71
4.2. Parámetros de las curvas de tendencia.	74
6.1. Muestra de datos registrados al operar la planta desalinizadora de OI con uno y dos tubos de presión. Estos datos fueron usados para llevar a cabo el entrenamiento, la validación y el ensayo de los modelos ANN empleados (*)	112
6.2. Factor de características de agua de alimentación	123
6.3. Factor de potencias de referencia	125
6.4. Arquitecturas de los cuatro modelos ANN seleccionados	128
6.5. Consignas de presión y caudal de operación y consumo de energía específico (SEC) obtenidos cuando la planta desalinizadora opera siguiendo el procedimiento descrito en la sección 6.3.3.	133
6.6. Errores MAE y MAPE obtenidos cuando la planta desalinizadora opera siguiendo el procedimiento descrito en la sección 6.3.3.	135
6.7. Coeficientes de correlación entre los errores de los niveles del factor de características de agua de alimentación.	138
6.8. Análisis de diferencias estadísticas para las métricas MAE y MAPE. Test de Friedman	138

7.1. Modelos considerados para estimar los parámetros del prototipo de planta desalinizadora	145
7.2. Muestra de datos registrados al operar la planta desalinizadora de OI con uno y dos tubos de presión. Estos datos fueron usados para llevar a cabo el entrenamiento, la validación y el ensayo de los modelos de ML empleados (*)	148
7.3. Hiperparámetros de cada uno de los modelos configurados	152
7.4. Análisis de las diferencias estadísticas de las métricas MAE. p-valores*	153
7.5. Análisis de las diferencias estadísticas de las métricas MAPE. p-valores*	154

Introducción

El problema de acceso a un agua potable, segura y de calidad se revela como uno de los principales retos globales para los próximos años [26–33]. La escasez de agua se considera un problema complejo que no solo se origina por la falta de agua sino que dispone de una serie de particularidades espaciales, temporales e institucionales que vuelven vulnerables, incluso, a aquellas regiones que tienen recursos hídricos naturales suficientes [30–33].

Con el objeto de ofrecer soluciones que mitiguen el impacto de la escasez de agua sobre la población mundial, la actividad investigadora en el área del tratamiento de aguas se ha intensificado durante las últimas décadas [26]. Desde esta rama del conocimiento destacan propuestas como la producción de agua potable a partir de la purificación del agua salada. El potencial que ofrecen estas técnicas es enorme considerando que aproximadamente el 97.5 % del agua existente en la Tierra es agua salada [26] y que casi la mitad de la población mundial vive a menos de 100 km de un océano [34]. Por ello, durante las últimas décadas ha crecido notablemente la instalación de plantas desalinizadoras a lo largo de todo el planeta [34–44].

Las tecnologías de desalinización más empleadas son aquellas que utilizan métodos de separación de sales por membranas y las que usan métodos térmicos

para destilar el agua [26]. De todas ellas, es la técnica de ósmosis inversa (OI) la que domina el mercado global actual aglutinando, sólo ella, más del 55 % de la capacidad total instalada [34, 45]. Esta tecnología presenta como ventaja competitiva principal un menor consumo energético específico [34, 45, 46]. A pesar de ello, cualquiera de los métodos de desalación conocidos requieren de un consumo intensivo de energía, lo que repercute negativamente en los costes de producción de agua [26, 47].

Dada la tradición, la abundancia de equipamiento, la flexibilidad y la comodidad que supone el uso de combustibles fósiles, todavía hoy resulta habitual el uso de los mismos para el accionamiento de plantas desalinizadoras industriales. Sin embargo, la tendencia al alza de sus costes, el potencial contaminante que disponen este tipo de combustibles y el fomento de políticas globales que impulsan el desarrollo de fuentes energéticas de origen sostenible, han intensificado la búsqueda de otro tipo de abastecimientos energéticos. Entre ellos, se encuentran la energía nuclear, que últimamente se ha barajado como opción viable para desalar grandes volúmenes de agua sin emisión de contaminantes a la atmósfera [48–54]. No obstante, los riesgos asociados a este tipo de energía, los problemas que originan sus residuos y su alto rechazo social dificultan el desarrollo de estos proyectos. Así, otro tipo de alternativas como el uso de fuentes energéticas de origen renovable para la desalación de agua, son cada vez más numerosas [1, 5, 34, 55–82].

Las distintas propuestas que fomentan el uso de energías renovables para la desalación de agua contienen proyectos que combinan generación de origen renovable y generación convencional, pero también proyectos con abastecimiento energético de origen puramente renovable. En los sistemas alimentados con fuentes energéticas convencionales es habitual que los subsistemas de control actúen exclusivamente sobre la generación para adaptarla a la demanda y mantener el balance energético [83]. Si generación y demanda difieren, el subsistema de control actúa reduciendo o aumentando la generación. En un sistema accionado mediante energía renovable, sin embargo, no es posible realizar este proceso. Por ello, si no se busca una solución, se originarían desajustes energéticos nada convenientes para los equipos eléctricos que componen el sistema de desalación. Esto ha contribuido a que, hasta el momento, no hayan prosperado los proyectos que usan sistemas re-

novables aislados para accionar tecnologías de desalación de media y gran capacidad [84–88]. La mayoría de prototipos aislados desarrollados hasta la fecha se han integrado en micro-redes eléctricas que se abastecen de energía solar fotovoltaica o energía eólica. En términos generales, son prototipos orientados a la desalación de agua a pequeña escala (hasta 50 m³/día) localizados en zonas remotas [89, 90]. Los trabajos que han abordado el problema de la operación de plantas de ósmosis inversa accionadas por energía eólica se han visto obligados a proponer una serie de estrategias de operación innecesarias en otro tipo de proyectos. Estas propuestas pueden dividirse en los tres bloques principales señalados en la Fig. 1.1.



Fig. 1.1: Clasificación de las soluciones existentes en la literatura científica para accionar plantas de ósmosis inversa mediante energía eólica.

En un primer bloque pueden considerarse aquellas propuestas en las que se hace trabajar a la planta de OI en régimen constante de presión y caudal de alimentación [2, 3]. Este grupo resuelve el desajuste entre potencia generada y potencia consumida mediante el almacenamiento de energía o la participación de fuentes convencionales de energía para equilibrar el sistema. Un segundo bloque lo componen propuestas de plantas desalinizadoras diseñadas por módulos para que éstos actúen en paralelo e independientemente uno del otro. La idea es que cada uno de

los módulos funcione en régimen constante en su punto óptimo de caudal y presión. Conectando o desconectando módulos se ejerce un control sobre la potencia demandada por la planta de ósmosis inversa y se logra un ajuste discreto entre esta y la potencia ofertada por la turbina eólica [2, 3, 84, 86, 91]. Por último, un tercer bloque recoge estrategias divulgadas en la literatura científica que plantean hacer funcionar una planta desalinizadora de agua de mar por OI variando de forma continua sus condiciones de operación [1, 6, 92]. Algunos de estos estudios proponen el acople directo de la generación renovable a la planta desalinizadora cuando la potencia generada supere el mínimo requerido para un funcionamiento satisfactorio. Siguiendo este planteamiento, la planta adapta continuamente sus parámetros operativos a las nuevas situaciones energéticas que va marcando la fuente de origen renovable. Así, si sube la velocidad del viento, aumenta la potencia generada y, por tanto, se actúa sobre la planta desalinizadora para que eleve la producción de agua que, a su vez, provoca un mayor consumo energético.

Dentro de este tercer enfoque, se encuentra un estudio teórico que propone ajustar el consumo de energía de la planta regulando el caudal de agua de alimentación y la presión de operación (entre los límites admisibles de operación del sistema de membranas) mientras se mantiene el índice de recuperación constante. Esta estrategia, propuesta por Pohl et al. [6] siguiendo los estudios previos realizados por Ferón [2], es la que proporciona mejores resultados, en cuanto a consumo específico de energía, calidad del agua producida y márgenes de variación de la presión de alimentación se refiere. Pohl et al. [6] señalan que los resultados obtenidos deben ser verificados por la experiencia práctica o por experimentos especiales.

Por tanto, analizando la información recogida hasta este punto, se puede decir que este trabajo de investigación parte de las siguientes hipótesis:

1. una primera hipótesis teórica fundamental que invita a la posible regulación de la potencia consumida por una planta de ósmosis inversa para adaptarla a una potencia de alimentación variable. Con ello se plantea el incremento en la flexibilidad de este proceso, que es ampliamente utilizado en el mundo, y se despeja el camino hacia el accionamiento de estas plantas con energía proveniente de una fuente energética de origen eólico.

2. una segunda hipótesis teórica, planteada por Pohl et al. [6] que indica que la mejor estrategia para lograr dicho propósito es aquella en la que el sistema de control ajusta el caudal de agua de alimentación y la presión de operación (entre los límites admisibles de operación del sistema de membranas) manteniendo el índice de recuperación constante.
3. una tercera hipótesis, que invita al uso de alguna técnica de inteligencia artificial para generar las consignas de presión y de caudal de alimentación en las plantas de OI y que dicha generación de consignas no sólo tenga en cuenta el ajuste de potencia sino también otras variables que influyen directamente en la regulación, como son la temperatura y la conductividad del agua de mar de alimentación. Ello abre un nuevo camino hacia la optimización del aprovechamiento energético de las plantas desalinizadora en tiempo real.

1.1 Objetivos generales de la tesis doctoral

En este trabajo de investigación se presenta un prototipo de planta desalinizadora de agua de mar por ósmosis inversa, de pequeña escala, que ha sido diseñado para adaptar continuamente su consumo energético a la variación de la potencia eólica suministrada por una turbina eólica, prescindiendo del almacenamiento energético masivo en baterías.

Se pretende investigar dicho sistema con el fin de que opere de forma aislada de la red eléctrica convencional y, para lograrlo, se han marcado los siguientes objetivos:

- investigar la viabilidad técnica de gestionar la carga como medio principal para conseguir el equilibrio entre generación y demanda,
- realizar un estudio teórico de las posibles estrategias de operación del sistema y seleccionar aquella que permita un máximo aprovechamiento del recurso energético,
- desarrollar un sistema de control avanzado que permita la correcta gestión energética de la planta desalinizadora,

- implementar técnicas de control inteligentes, extraídas del área de la Inteligencia Artificial, para dotar al sistema de control que gobierna la planta desalinizadora de cierta capacidad de autoajuste y que pueda reaccionar ante los posibles cambios en el proceso, generando una consigna apropiada en cualquier circunstancia previsible.
- implementar técnicas de Machine Learning, extraídas del área de la Inteligencia Artificial, para simular e investigar el funcionamiento del sistema en su conjunto. Asimismo se pretende comparar el modo de operación variable con respecto al funcionamiento en régimen constante.

El prototipo de desalinización contendrá dos tubos de membranas en paralelo. Cada tubo será controlado para que puedan variarse la presión y el caudal dentro de unos márgenes admisibles que son analizados. De esta manera, la demanda de potencia del sistema puede variar de forma continua (no discreta como en el caso de trabajos previos como el proyecto SDAWES [91]) y se adapta a la potencia eólica disponible en cada instante.

1.2 Metodología

Tal y como se observa, la magnitud del proyecto es considerable e involucra niveles diferentes de aplicación de distintas áreas de la ingeniería. No sólo se plantea un estudio teórico sino que se diseña un prototipo y se llevan a cabo ensayos experimentales para validar las estrategias propuestas. Su desarrollo, por tanto, exige una metodología estricta que permita la satisfactoria consecución de los objetivos planteados. Por ello, se considera abordar el problema por niveles, o fases escalonadas, tal y como se refleja en el diagrama mostrado en la Fig. 1.2.

1.3 Estructura de la tesis doctoral

Este documento de tesis se encuentra estructurado en 9 capítulos, considerando el presente.

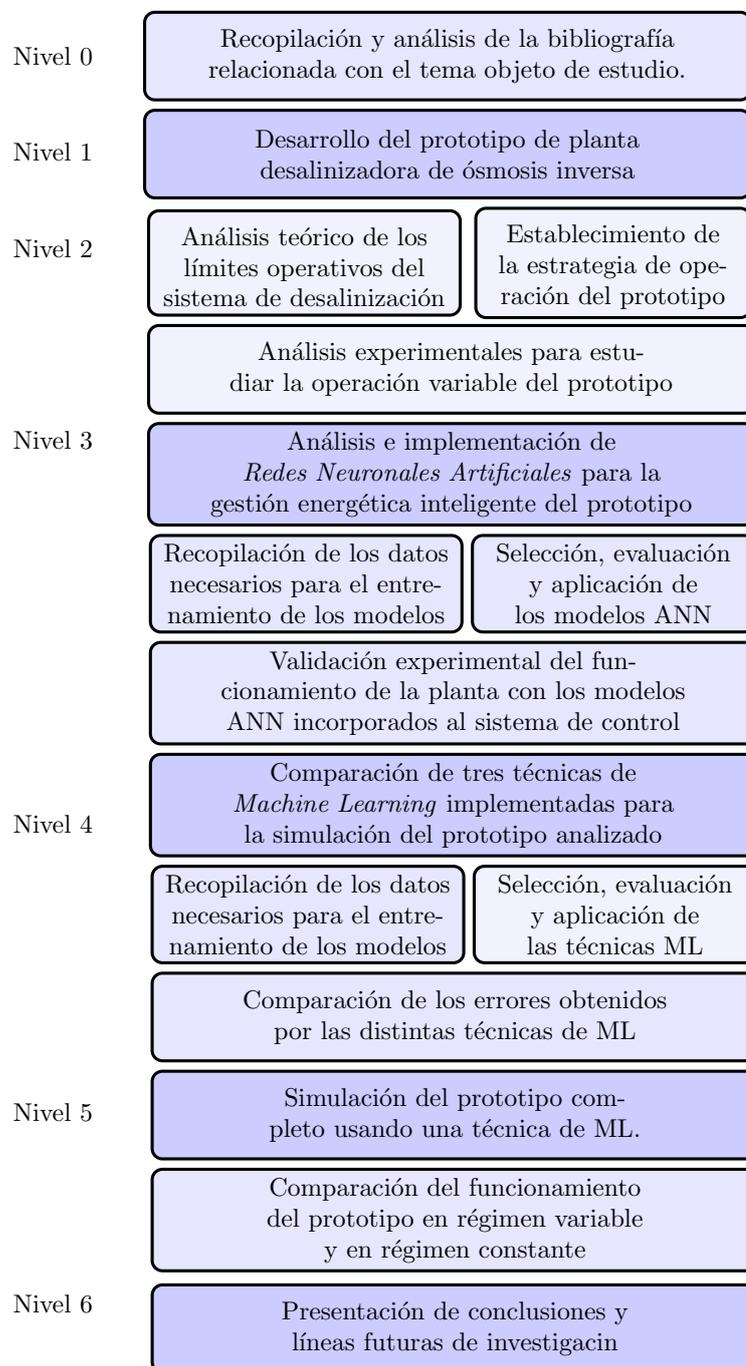


Fig. 1.2: Esquema metodológico del trabajo de investigación realizado.

En el capítulo 2 se hace una revisión de los sistemas de desalación de ósmosis inversa que han sido diseñados para ser accionados mediante energía eólica. El capítulo se centra, sobretodo, en aquellos proyectos que han trascendido el plano teórico y han sido probados experimentalmente. Asimismo, en dicho capítulo se mencionan las propuestas de plantas desalinizadoras que operan en régimen variable. También se hace un barrido por aquellos proyectos que utilizan técnicas de *Machine Learning* en plantas desalinizadoras.

En el capítulo 3 se describen todos los equipos utilizados para el desarrollo del prototipo involucrado en esta tesis. Se define el prototipo de partida, el nuevo diseño propuesto para controlar la planta desalinizadora de forma variable y la configuración del sistema de control para alcanzar los objetivos planteados.

En el capítulo 4 se describen todos los estudios teóricos y preliminares realizados sobre el prototipo para lograr posteriormente el objetivo de gestionar de forma variable su funcionamiento y adaptar la potencia consumida por la planta desalinizadora al suministro de energía variable proporcionado por una turbina eólica.

En el capítulo 5 se describen las técnicas de *Machine Learning* empleadas a lo largo del trabajo de investigación.

En el capítulo 6 se analiza detalladamente la implementación y el uso de una de estas tres técnicas (las redes neuronales artificiales) para la gestión variable del prototipo de planta desalinizadora considerado.

Posteriormente, en el capítulo 7 se comparan las tres técnicas de *Machine Learning* propuestas para conocer cuál de ellas presenta un mejor rendimiento en la simulación del prototipo en estudio.

A continuación, en el capítulo 8 se utiliza la técnica que mejores resultados obtuvo en el capítulo 7 para simular el prototipo en estudio y comparar los resultados de dicha simulación con los resultados de la simulación de un prototipo similar pero que utiliza un sistema de almacenamiento masivo de energía.

Por último, en el capítulo 9 se exponen las aportaciones que hace esta tesis al cuerpo del conocimiento, las conclusiones de la misma y las líneas de investigación propuestas para el futuro derivadas de este trabajo.

La Fig. 1.3 muestra la estructura de la tesis y refleja el uso de de las distintas contribuciones que han creado el cuerpo y el fundamento científico de esta tesis.

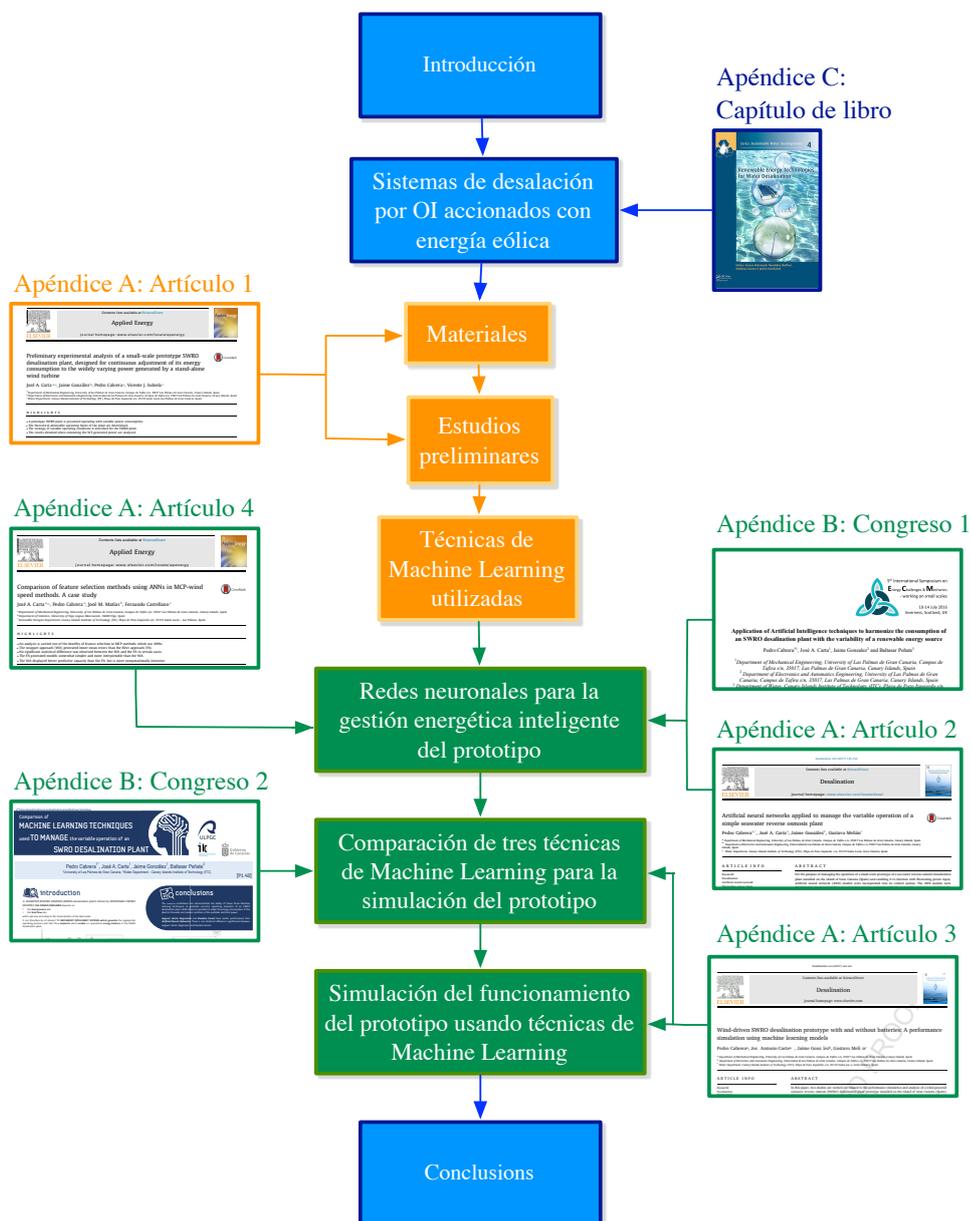


Fig. 1.3: Estructura de la tesis y cómo las distintas contribuciones se relacionan con los capítulos.

Introduction

The problem of access to clean, fresh and safe water is revealed as one of the main global challenges for the next years [26–33]. Water scarcity is considered a complex problem which is not only originated by the lack of water but it has a set of spatial, temporal and institutional particularities which turn vulnerable even in regions with enough hydrological resources [30–33].

With the aim of offering solutions to mitigate the impact of water scarcity over the global population, the research activity has been intensified in water treatment field over last decades [26]. From this field the fresh water production from seawater desalination is highlighted. The potentiality offered by these techniques is enormous if it is considered that these sources account for 97.5 % of all water on Earth [26]. Additionally, almost half of the world's population lives within 100 km of an ocean [34]. For these reasons, the worldwide interest in, and the practice of, seawater desalination have rapidly increased in last decades [34–44].

The major desalination technologies currently in use are based on membrane separation via Reverse Osmosis (RO) and thermal distillation (multistage flash (MSF) and effect distillation (ED)) [26]. Among all of them, RO dominates the global desalination market accounting for over 55 % of the total installed capacity [34, 45].

This technology has, as main competitive advantage, a lower specific energy consumption (SEC) [34, 45, 46]. However, desalination of all types is often considered an energy-intensive process and this has negative repercussions in water production costs, though [26, 47, 93].

Given the traditional use and the flexibility in fossil fuels use, they are presently the most commonly used energy source to power the different desalination technologies at industrial scale, but their rising price trend and associated problems with atmospheric contamination have led to the proposal for the use of alternative or complementary energy sources. Among them, it can be found the nuclear energy which has been proposed lately as a viable option to desalinate big volumes of water without emissions into the atmosphere [48–54]. Nevertheless, the associated risks of this type of energy, the problem originated by its waste and the very high social rejection of this type of energy hamper the development of these projects. A significant number of authors have underlined the benefits that can be obtained from water desalination through the use of hybrid energy sources (conventional-renewable) [83, 84, 89, 90, 94–97] and exclusively renewable sources [1, 5, 34, 55–82, 98], with particular emphasis given to these latter sources being clean, cheap and inexhaustible.

In systems which use conventional energy sources it is common that control subsystems act over generation for adapting it to energy demand and for keeping in balance the energy system [83]. If energy generation and energy demand differ, the control subsystem acts reducing or increasing the generation. In a renewable energy system, however, it is not possible to make this process. For this reason, if a solution is not found, it would originate energy mismatches which are not convenient for the electric equipments involved in the desalination process. This has meant a drawback to the development of projects which use isolated renewable systems for driving desalination technologies of medium/large-scale [84–88, 98].

Most of the studies undertaken have focussed on the application of photovoltaic solar energy and wind energy for small-scale water desalination (maximum capacity of 50 m³/day) in remote areas using RO (reverse osmosis) technology [99–102].

The previous research works that have tackled the problem operating seawater reverse osmosis desalination plants (SWRO-DPs) driven by fluctuating energy sources have been forced to propose a set of operating strategies unnecessary in other projects. These proposals can be divided into the three main groups highlighted in Fig. 1.1.

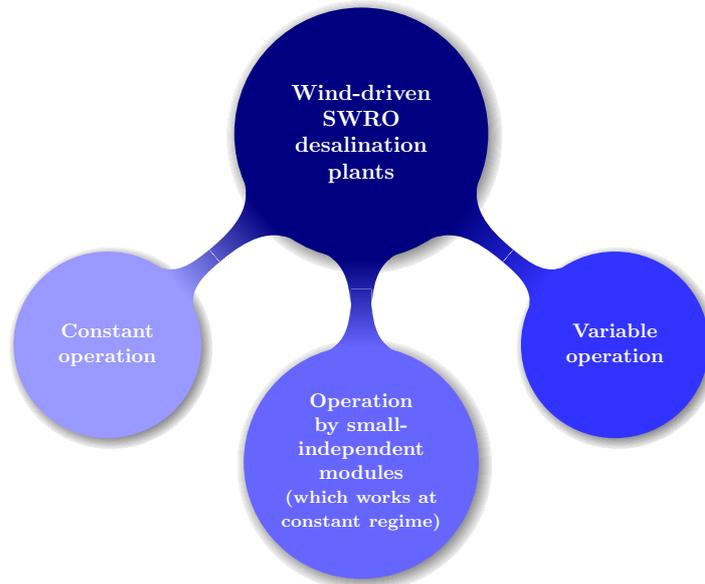


Fig. 1.1: Current solutions found in scientific literature for operating seawater reverse osmosis desalination plants using wind energy (fluctuating renewable energy source)

With a few exceptions, practically all the prototypes and projects that have been developed have used batteries or hybrid system (combining renewable energy sources and conventional generators) to supply energy to the RO plant and stabilize the system and, consequently, the RO membranes have normally operated at constant pressure and flow rate (constant operation group of Fig. 1.1) [24, 102–104].

Secondly, some projects have designed desalination plants by modules with the aim of operating each module in parallel and independently. In this way each module works at constant regime in the nominal point of pressure and flow rate. With the connection and disconnection of modules the demanded power is adjusted by discrete steps to the power generated by a wind turbine (WT) [2, 3, 84, 86, 91].

Finally, a very few projects have been developed involving adaptation of the power consumed by the desalination system to variation in the wind power supply and have used flow/pressure stabilizer systems [105, 106], energy recovery systems [107] or have controlled the input flow to the RO plant [5] (variable operation group of Fig. 1.1). Similarly, RO prototype plants have been developed which, connected to a conventional power grid, have been used to assess operational feasibility when the pressure and flow parameters are outside the design point [108]. In this last group (variable operation in Fig. 1.1) when the wind speed increases the generated power is increased as well and, thus, the control system act over SWRO-DP to increase the water production and, hence, to increase the power consumption.

In this sense Pohl et al. [6], following the idea originally presented by Feron [2] and subsequently used by other authors [3, 5], presented a diagram of feed pressure as a function of feed seawater flow rate which defined an area in which operation was admissible of an SWRO desalination system comprised of a pressure vessel with four membranes in series (SW30-HR400i, DOW FilmTec™). Based on this diagram, the authors proposed four different operating strategies: (a) constant feed pressure and variable feed seawater flow rate, (b) constant feed seawater flow rate and variable feed pressure, (c) variable pressure and feed flow rate, such that the permeate recovery rate (sometimes referred to as the «*conversion rate*»), defined as the percentage of feed flow converted into permeate (or product water) flow, remains constant, (d) variable pressure and feed flow rate, such that the brine flow rate remains constant.

Pohl et al. [6], based on theoretical studies that had been performed, concluded that when the SWRO desalination plant needs to be adapted to a wide variation in power (as generated by a WT), the operating strategy with constant permeate recovery gave the best results in terms of specific consumption of energy, the quality of water produced and feed pressure variation margins. The authors reported that the results would need verification with specially designed experiments or practical experience.

Therefore, after the analysis of all information collected until now, it can be said that this research work begins with the following hypotheses:

1. a first theoretical and fundamental hypothesis which was thought-provoking was the possible regulation of power demanded by a seawater reverse osmosis desalination plant for being adjusted to a variable power generated by a fluctuating source. This is aimed at increasing the flexibility in this type of processes, widely used in the world. Additionally, in this way it is clearing the way for operating this plants directly connected to a renewable energy source as wind energy.
2. a second theoretical hypothesis, raised by Pohl et al. [6] which points the best strategy for achieving the proposal explained in the previous point. According to these authors, the best results in terms of specific consumption of energy, product water quality and feed pressure variation margins are obtained by the strategy with constant permeate recovery. They also add that the results obtained should be verified by practical experience or special tests.
3. a third hypothesis which thought-provoked the use of some technique of Artificial Intelligence field to achieve this variable regulation. In this way, one of these techniques can calculate the reference set-points of feed flow rate and operating pressure in the desalination plant taking into account the energy which it has to consume for the desalination process to match the power generated by a wind turbine but also the water characteristics which affect the process.

1.1 Overall aims of the PhD thesis

The present PhD research work presents a small-scale prototype SWRO desalination plant which has been designed to continuously adapt its consumption to the variable power supply of a wind turbine, dispensing with mass energy storage in batteries and proposing the use of a supercapacitor bank as a dynamic regulation system.

The aim is to research the best way to manage this system for achieving an optimal stand-alone operation which maximizes the renewable fluctuating energy provided by a wind turbine. To reach this, the following aims have been raised:

- to research the technical feasibility and the theoretical possibilities of managing the load (desalination plant) and increase the flexibility in the operation for achieving a continuous balance between a fluctuating energy generation and the energy demanded by the small-scale prototype developed.
- to develop an advanced control system which allows the best implementation of a smart energy management strategy in desalination plant.
- to carry out tests with the SWRO desalination plant connected to the conventional grid while controlling the number of pressure vessels that are connected/disconnected to/from the system at each moment and regulating their operating pressures and flow rates (within predetermined acceptable limits). The control strategy will attempt to maintain (following the strategy of maintaining a constant permeate recovery rate) adapting the energy consumption of the plant to a widely varying simulated wind energy supply and minimising the frequency of plant start-up/shut-downs.
- to investigate whether some techniques from the Artificial Intelligence field (*Machine Learning* techniques) are able to manage the feed flow and operating pressure setpoints of the SWRO desalination plant and allow the plant's energy consumption to adapt to the widely varying and random electrical power supplied (in this thesis simulated) by a stand-alone wind turbine.
- to implement some Machine Learning (ML) techniques for researching which technique best simulates the performance of the system analysed in the face of variation of these operating parameters. The three ML algorithms that are analysed are artificial neural networks (ANNs) with multilayer perceptron (MLP) architectures, support vector machines (SVMs) and random forests (RFs).
- To carry out, for the first time, a simulation (using ML algorithms) of the year-long performance of the SWRO-DP prototype working under variable pressure and flow conditions, adapting its energy consumption to the varying nature of the energy generated by a wind turbine (WT) used to power it. A comparison is also undertaken between the behaviour over time of this

type of microgrid and the behaviour of a microgrid which, in addition to the SWRO-DP and WT, includes a battery-based massive energy storage system and in which the desalination plant operates under constant pressure and flow conditions.

1.2 Methodology

As it can be intuited, the magnitude of this project is considerably wide and it involves different application levels of different engineering approaches. Not only is a theoretical study raised but also a prototype is developed and experimental analyses are carried out for validating the proposal strategies. The development of this PhD requires, thus, a strictly and rigorously methodology which allows the successful attainment of the raised aims. For this reason, it has been considered to tackle the problem by levels as it can be seen in the diagram of Fig. 1.2.

1.3 PhD thesis structure

This thesis is structured in nine chapters. The thesis first discusses, in chapter 2, the reverse osmosis desalination systems which have been designed for being driven by wind energy. It has made a special focus in those projects which have been tested experimentally and those which proposes the use of Machine Learning techniques in desalination processes.

In chapter 3, all materials and equipments used are defined and the new designs for managing the SWRO desalination plant in a variable way and the control system configurations as well.

In chapter 4 all preliminary studies over SWRO-DP prototype are described.

In chapter 5 the three machine learning techniques used in this thesis have been described.

After this, different techniques are applied to the investigation of the variable way of operation of the prototype. First, in chapter 6 it is analysed the implementation of ANNs for the smart energy managing in the prototype.

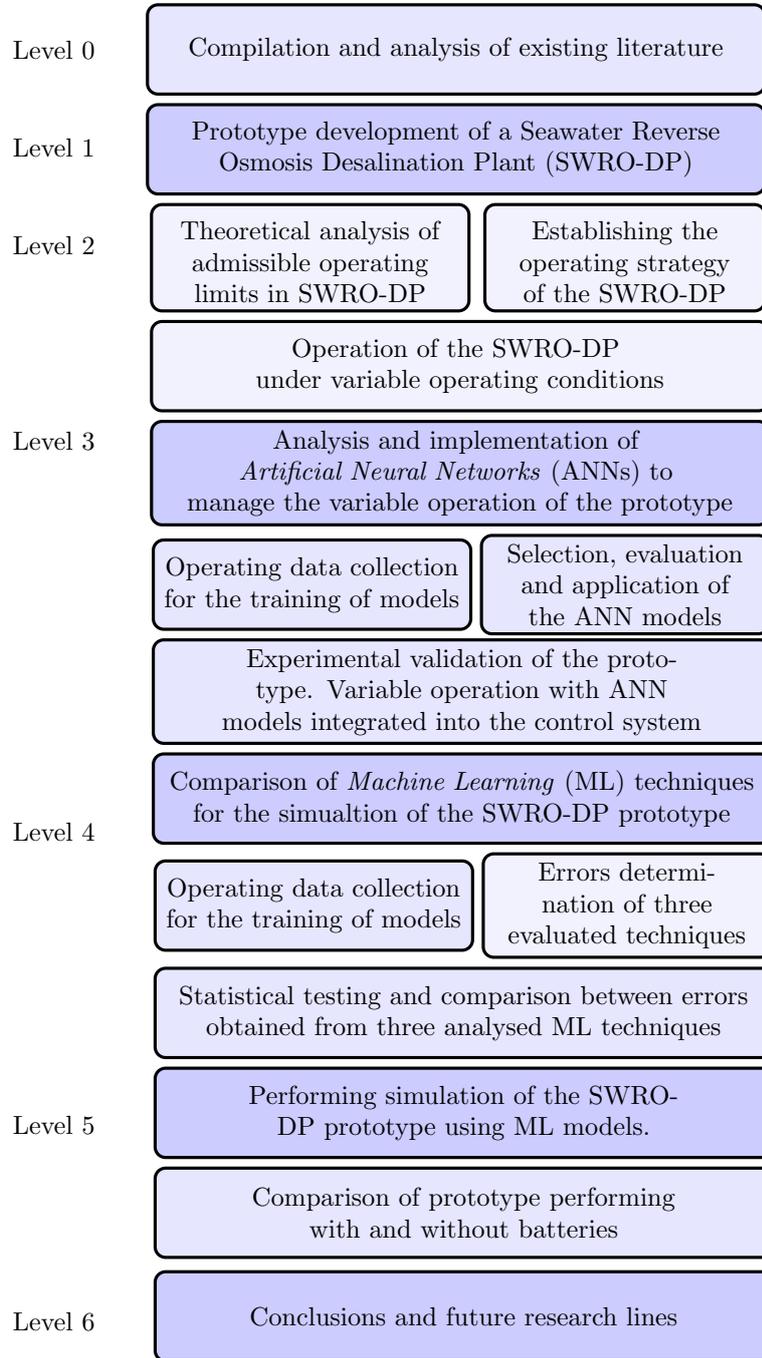


Fig. 1.2: Methodological diagram of the research work developed in this PhD.

Then, in chapter 7 the three machine learning techniques suggested are compared to research which technique best simulates the performance of the system analysed in the face of variation of these operating parameters.

In chapter 8 a simulation (using ML algorithms) of the SWRO-DP prototype working under variable pressure and flow conditions, adapting its energy consumption to the varying nature of the energy generated by a wind turbine is described.

Finally, the chapter 9 exposes the contributions that this thesis made to the body of knowledge, the final conclusions and the new research lines proposed to work in this topic in the future.

Fig. 1.3 shows the structure of the thesis and indicates the use of the different scientific contributions for creating the scientific foundation for the thesis.

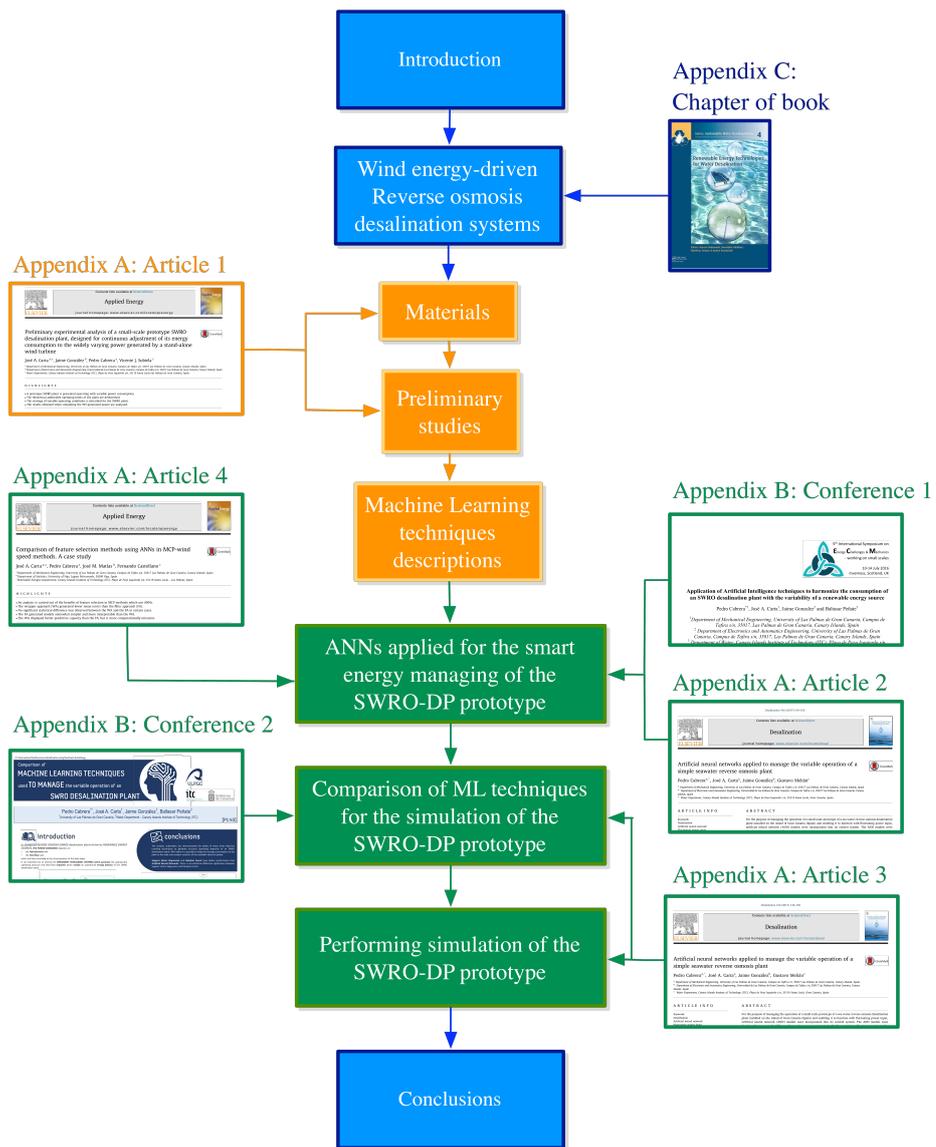


Fig. 1.3: Structure of PhD thesis and how the appendices relates to chapters.

Revisión de los sistemas de desalación de ósmosis inversa accionados con energía eólica

2.1 Introducción

Las primeras propuestas de sistemas de desalación accionados por energía eólica comenzaron a aparecer en la literatura científica a finales de la década de 1960 [109]. Luego, en la década de los setenta, Lising y Alward [110] estudiaron la viabilidad técnica de accionar una unidad de ósmosis inversa con una turbina eólica y concluyeron que el funcionamiento de las membranas con caudal de entrada variable no difería significativamente del funcionamiento en condiciones constantes. A partir de esa fecha comenzaron a surgir numerosos estudios a lo largo de todo el planeta que proponen sistemas que accionan plantas desalinizadoras mediante energía eólica [1, 24, 25]. De entre todos los estudios existentes en la literatura, destacan aquellos que trascienden el plano teórico y desarrollan e implementan prototipos para analizar experimentalmente las particularidades de cada sistema propuesto. En la Tabla 2.1 puede observarse una selección de estos estudios experimentales.

Tabla 2.1: Sistemas de desalación de ósmosis inversa (OI) accionados por energía eólica [24, 25].

Localización	Tipo de agua	Capacidad (m ³ /h)	Potencia instalada	Fuentes aux.	Fecha	Ref.
Isla de Planier, Francia	mar	0.5	4 kW		1982	[111]
Isla de Süderoog, Alemania	mar	0.25-0.37	6 kW		1983	[112, 113]
Isla de Helgoland, Alemania	mar	40	1.2 MW		1988	[114]
Isla de Saint-Nicolas, Francia	mar			diesel, baterías	1988	[115]
Isla de Drenec, Francia	mar		10 kW	diesel, baterías	1988	[115]
Oeste de Australia	salobre	0.02 - 0.4	Conversión mecánica	diesel	1990	[116]
Therasia, Grecia (APAS RENA)	mar	0.2	15 kW	440 Ah (baterías)	1995	[117]
Fuerteventura, España (Programa VALOREN)	mar	2.3	225 kW	160 KVA diesel, volante de inercia	1995	[95]
Gran Canaria, España (SDAWES)	mar	8 uds x 1.0	2 x 230 kW	volante de inercia	1995	[86, 91]
Tenerife, España (JOULE)	mar	2.5-4.5	30 kW		1997	[24, 25]
Syros, Grecia (JOULE)	mar	2.5-37.5	500 kW	Sist. autónomo, conectado a red	1998	[118, 119]
Gran Canaria, España (AERODESA I)	mar	0.42	Conversión mecánica		2000	[120, 121]
Gran Canaria, España (AERODESA II)	mar	0.625	Conversión mecánica/hidráulica		2000	[120, 121]
Keratea, Grecia (PAVET)	mar	0.13	900 W	4 kW PV, baterías	2001	[24, 25]
Isla de Coconut, EEUU	salobre	~ 1.0	Conversión mecánica		2002	[105, 122]
Rendsburg, Alemania (WindDeSalter®)	mar	100	Conversión mecánica		2003	[123]
Loughborough University, UK	mar	0.5	2.2 kW		2001	[4, 5]
Gran Canaria, España (AEROGEDESA)	mar	0.80	15 kW	190 Ah (baterías)	2003	[104]
Milos, Grecia (Programa OPC)	mar	2 x 41	850 kW	conectado a red	2007	[24, 25]
Irakleia, Grecia (Programa OPC)	mar	3.3	30 kW	offshore con baterías	2007	[24, 25]
University of Delft, Holanda	mar	0.2-0.4	Conversión mecánica		2007	[107]
Heriot-Watt University, UK	salobre	0.3	1kW	Supercondensadores	2010	[7-12]
Gran Canaria, España (Proyecto SODAMEE)	mar	1-6	15 kW	Supercondensadores	2011	[98]

Para este tipo de sistemas, es posible realizar varias clasificaciones atendiendo al tipo de solución empleada para amortiguar los efectos derivados de la intermitencia y la variabilidad eólica. Tal y como se señala en el capítulo 1 de este documento, en este trabajo se propone una clasificación atendiendo a las estrategias operacionales que proponen los distintos estudios (Fig. 1.1). Siguiendo este criterio se observan tres tipos de soluciones: (1) operación de la planta desalinizadora en régimen constante haciendo uso de almacenamiento energético, (2) operación de la planta desalinizadora por módulos para adaptar discretamente el consumo a la generación y (3) operación de la planta desalinizadora en régimen variable para ajustar continuamente su consumo al recurso eólico disponible. Por otro lado, Lai et al. [1] proponen una clasificación semejante en la que distribuyen las distintas soluciones tal y como se observa en la figura 2.1: (1) almacenamiento energético, (2) hibridación del sistema de generación renovable y (3) regulación de la planta desalinizadora para ajustar su consumo al recurso eólico disponible en tiempo real.

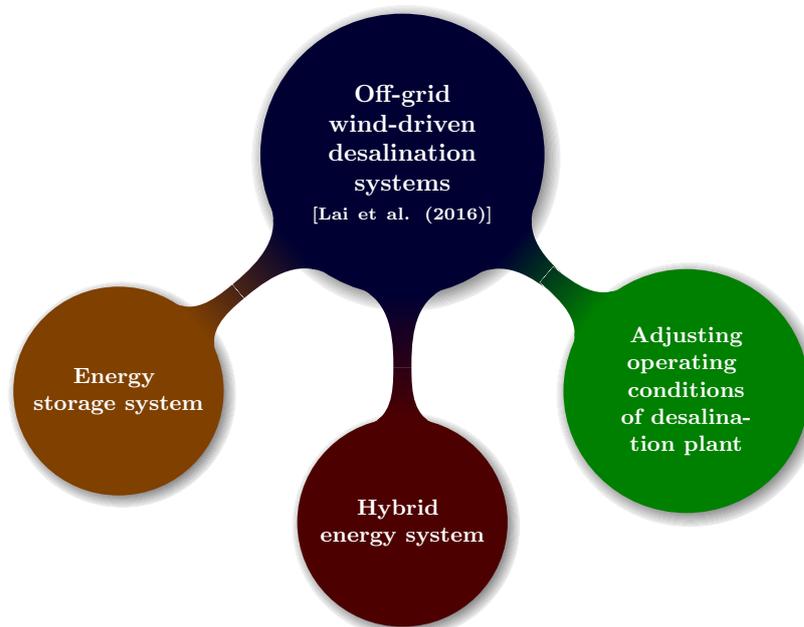


Fig. 2.1: Clasificación de Lai et al. [1] de las soluciones en la literatura científica para accionar plantas de ósmosis inversa mediante energía eólica.

En este trabajo se ha considerado más apropiado seguir la clasificación reali-

zada en el capítulo 1 (Fig. 1.1) ya que, con ella, es posible aislar las soluciones atendiendo al tipo de operación que se lleva a cabo en la planta desalinizadora y, en consecuencia, se puede identificar el tipo de regulación necesaria para cada caso. En la clasificación realizada por Lai et al. no existe un único tipo de regulación operacional por cada categoría. Se observa que, tanto en las soluciones del grupo (1) como en las del grupo (2), la planta de ósmosis inversa opera de la misma manera. Es decir, en ninguno de estos dos grupos se aplica regulación en tiempo real sino que se opera en régimen constante de presión y caudal. En el grupo (3), por contra, es posible emplear al menos dos estrategias de regulación para lograr el objetivo de la categoría: regulación discreta (operación por módulos) y regulación continua (operación en régimen variable). Por tanto, dado que la clasificación realizada en este trabajo conlleva un único modo de regular la producción de agua (consumo de potencia) por cada categoría, también podrían agruparse los estudios existentes en la literatura de la siguiente manera: (1) sin regulación (operación en régimen constante), (2) regulación discreta (operación por módulos) y (3) regulación continua (operación en régimen variable).

2.2 Propuestas de plantas desalinizadoras accionadas con energía eólica que operan en régimen variable

Esta tesis se centra en el desarrollo y estudio de un prototipo de planta desalinizadora por ósmosis inversa que adapta en tiempo real su producción de agua y, por tanto, su consumo de potencia eléctrica a una generación eólica variable. Por ello, la revisión bibliográfica realizada a continuación se centra en los estudios que, dentro de la literatura científica, se enfocan en variar el régimen operativo de una planta desaladora para adaptarlo a una generación eléctrica de origen eólico.

Uno de los primeros estudios que plantean la conexión directa de una turbina eólica y una unidad de ósmosis inversa fue el trabajo llevado a cabo por Lising y Alward en la década de los 70 [110]. En dicho estudio se analizó el impacto de las fluctuaciones de caudal en un sistema de ósmosis inversa (OI) con el objetivo de determinar si las variaciones de potencia obtenidas de una turbina eólica eran compatibles con dicho sistema. Se sometió el sistema a dos tipos de variaciones

senoidales de caudal distintas durante 7 días y se concluyó que el funcionamiento de las membranas con caudal de entrada variable no difería significativamente del funcionamiento en condiciones constantes. Por tanto, los autores, a partir de dichos resultados, asumieron que el accionamiento de un sistema de membranas mediante energía eólica es técnicamente viable.

Es obvio que, para adaptar la potencia consumida por una planta desaladora a las variaciones e intermitencias del viento (sin emplear ningún tipo de sistema de almacenamiento intermedio), es necesario variar las condiciones operativas del proceso. Para ello, dado que la potencia consumida es función de la presión y el caudal de entrada a las membranas, se deben ir modificando estas dos variables hidráulicas para ir acomodando el valor de potencia a los continuos cambios de la generación eólica. No obstante, dichas variaciones deben realizarse dentro de unos márgenes admisibles que minimicen el riesgo de degradación de las membranas.

Cada configuración hidráulica de un nuevo sistema de desalación dispone de unos márgenes operativos propios que deben ser calculados a partir de las especificaciones y datos técnicos que proporciona el fabricante de las membranas. El área operativa de la planta, situada dentro de dichos márgenes, suele denominarse ventana operativa de seguridad (SOW, de sus siglas en inglés Safe Operational Window) y el primero en introducir este término fue Feron [2] en 1985. Los límites de este área operativa se definen por los valores de:

- I) caudal máximo,
- II) índice de recuperación de permeado mínimo,
- III) máxima concentración de sales del agua producto,
- IV) mínimo caudal del agua rechazo,
- V) mínimo ratio entre agua rechazo y agua producto y,
- VI) flujo medio máximo del sistema de membranas instalado

En su investigación, Feron, simula un sistema utilizando componentes no disponibles comercialmente y propone dos alternativas para gestionar la variabilidad

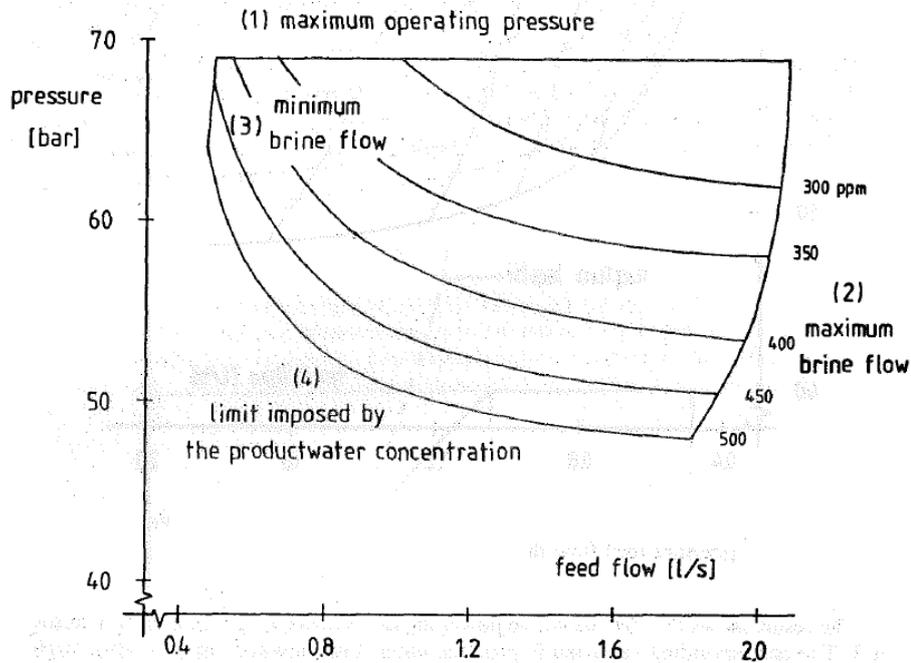


Fig. 2.2: Márgenes operativos calculados por Feron en 1985 [2].

eólica: (1) propone modificar el área de las membranas y (2) propone permitir la operación variable dentro de los márgenes operativos de las membranas. Debido a que la modificación del área de las membranas no es factible en tiempo real, la segunda opción propuesta por Feron resultó ser la más viable. Este autor analizó, por primera vez, la viabilidad económica de que un sistema de este tipo [124].

Una de sus conclusiones fue que la viabilidad económica de este tipo de sistemas puede quedar restringida a zonas con altas velocidades de viento y que dispongan de unos precios de los combustibles elevados. No obstante, a partir de los años 80, las innovaciones tecnológicas, la mejora de las eficiencias de los equipos energéticos involucrados en los sistemas, así como el agravamiento del problema de escasez de agua mundial, incentivaron la elaboración de nuevos estudios teóricos en este sentido.

Siguiendo esta misma línea de trabajo, Warfel et al. [3], modelaron y analizaron una planta de ósmosis inversa accionada por tres configuraciones de sistemas autónomos diferentes: dos de ellas empleaban energía eléctrica proveniente de la

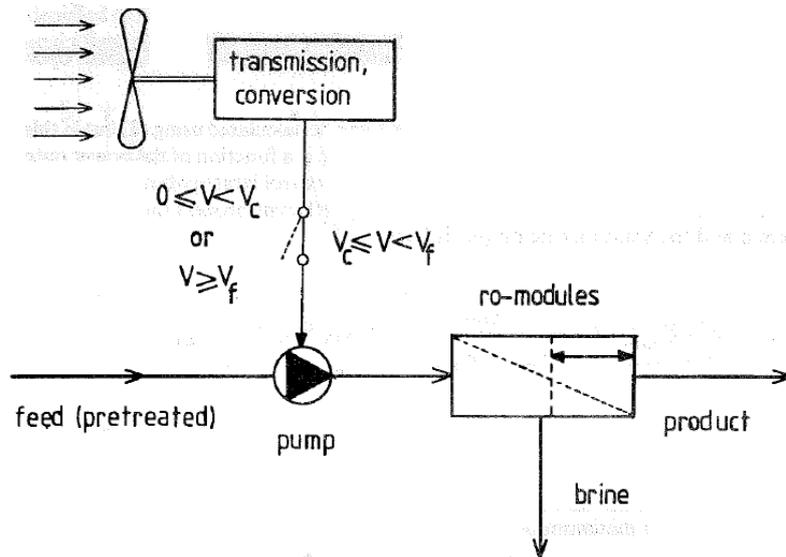


Fig. 2.3: Esquema del sistema autónomo propuesto por Feron en 1985 [2] para desalinizar agua de mar accionando una planta de ósmosis inversa mediante energía eólica y haciendo operar dicha planta en régimen variable con una velocidad del viento V (V_c y V_f , son las velocidades de corte inferior y superior de la turbina, respectivamente).

eólica y una usaba transmisión mecánica directa. Los resultados de estas tres configuraciones se compararon con los obtenidos por la misma planta accionada con un generador diesel. Para simplificar el análisis, Warfel et al. excluyeron el pretratamiento y el sistema de recuperación de energía. Además, tal y como hizo Feron previamente, calcularon el área operativa de la planta de OI (Fig. 2.4) y señalaron que la mejor estrategia de operación es aquella que mantiene la máxima presión posible. Según ellos, esta estrategia permite un mayor rango operativo y produce un mayor caudal producto para una misma potencia, lo que equivale a un menor consumo específico y unos menores costes operativos. Como contrapartida, esta estrategia operativa provoca un mayor deterioro de las membranas, lo que repercute en un aumento de la frecuencia de reemplazo de las mismas. No obstante, estas afirmaciones no están sustentadas por ningún análisis experimental sino que responden a la observación de los márgenes operativos calculados por los autores (Fig. 2.4).

Posteriormente, en la universidad de Loughborough (Reino Unido), los autores

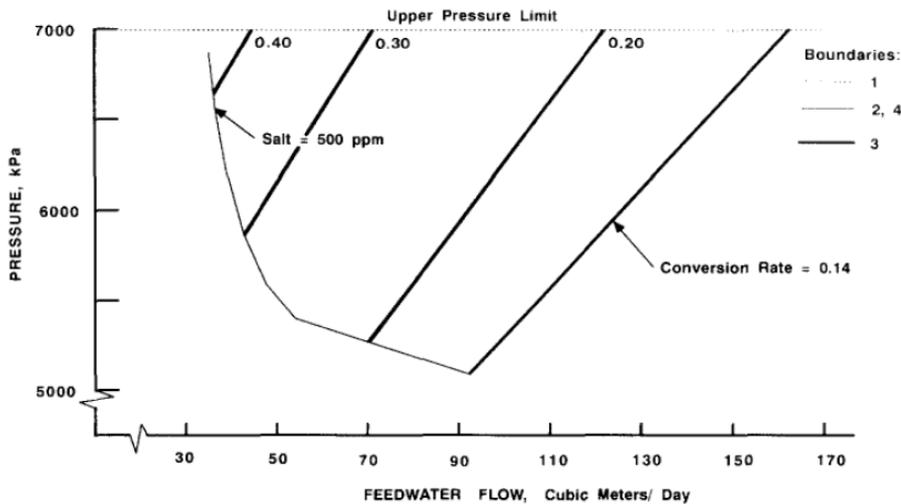


Fig. 2.4: Márgenes operativos calculados por Warfel et al. [3].

Thomson et al. [4] y Miranda & Infield [5] analizaron una propuesta innovadora de planta desalinizadora que opera accionada mediante energía eólica sin el uso de baterías. Ello también exigió un cálculo del área operativa de las membranas, como en los casos señalados anteriormente. El proyecto se preparó para un aerogenerador de una potencia nominal de 2.2 kW y la planta desalinizadora disponía de una capacidad de 0.5 m³/h. A pesar de que estos autores trabajan con modelos de Simulink-Matlab, se apoyaron en datos experimentales de la planta desalinizadora obtenidos parcialmente en un laboratorio y validaron experimentalmente algunos resultados contrastando la posibilidad de operar una planta desalinizadora en régimen variable.

Algunos estudios, como el desarrollado por De-la-Nuez et al. [108], no calcularon el área operativa de las membranas pero demostraron experimentalmente la viabilidad de hacer operar una planta en régimen variable en un sistema de mayor tamaño. Los autores realizaron una serie de tests para estudiar cómo afectan las fluctuaciones en un sistema de ósmosis inversa capaz de producir entorno a 6 m³/h en régimen nominal. Aunque declararon que requerirían de un estudio más amplio, avanzaron que las membranas permiten un funcionamiento en régimen variable sin sufrir deterioro.

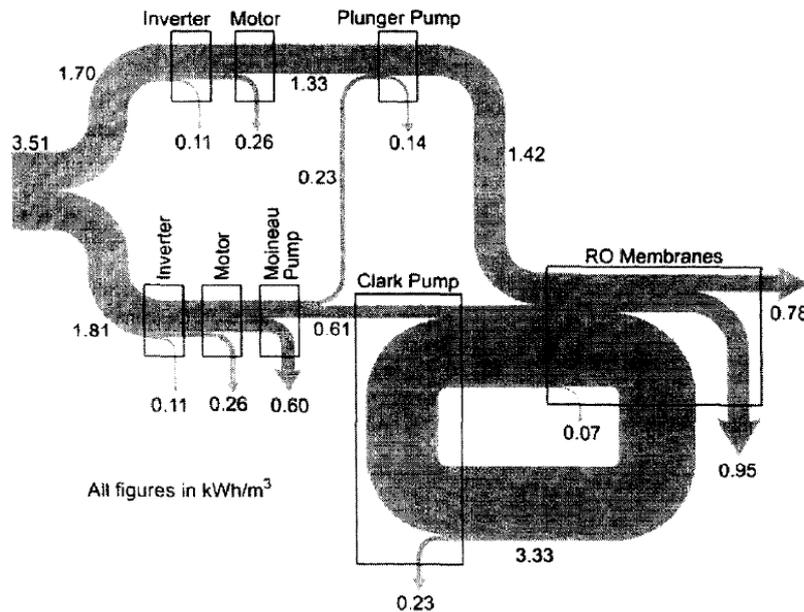


Fig. 2.5: Diagrama de flujos energéticos del sistema propuesto por Thomson et al. [4] y Miranda & Infield [5] para accionar una planta de OI y adaptar su funcionamiento a una potencia eólica variable.

Pohl et al. [6], siguiendo la idea planteada por los estudios anteriores citados, sí obtuvieron el área operativa ((Fig. 2.6)) de un sistema de desalación de ósmosis inversa de agua de mar constituido por un tubo de presión con cuatro membranas en serie (SW30-HR400i, DOW FilmTec™). Estos autores dieron un nuevo paso en este área de conocimiento y, en base a dicho diagrama (Fig. 2.6), propusieron cuatro estrategias de operación diferentes para adecuar el consumo de una planta desalinizadora a las variaciones en la producción energética de una turbina eólica. Las estrategias propuestas por los autores fueron las siguientes:

- presión de alimentación constante y caudal de agua de mar de alimentación variable,
- caudal de agua de mar de alimentación constante y presión de alimentación variable,
- presión y caudal de alimentación variables de tal forma que la proporción de

recuperación de permeado (algunas veces referenciada como *conversion rate*), definida ésta como el porcentaje del caudal de agua de alimentación que es convertida en caudal de permeado, permanece constante,

- d) presión y caudal de alimentación variables de tal manera que permanece constante el caudal de agua de rechazo.

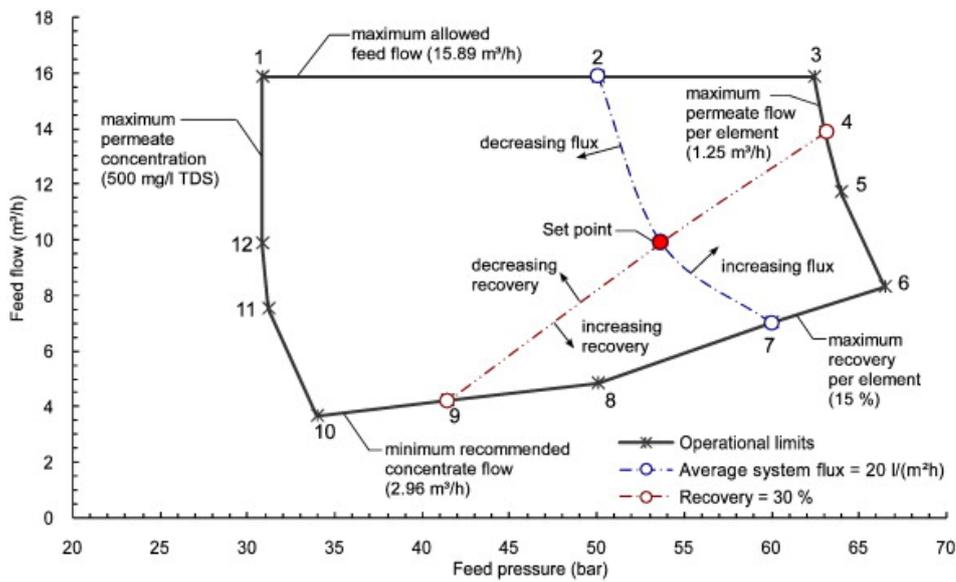


Fig. 2.6: Área operativa calculada por Pohl et. al [6].

Pohl et al. [6], en base a los estudios teóricos realizados en su investigación concluyen que, cuando la planta de OI ha de adaptarse a una amplia variación de la potencia, la estrategia de operación con recuperación de permeado constante es la que proporciona mejores resultados, en cuanto a consumo específico de energía, calidad del agua producida y márgenes de variación de la presión de alimentación se refiere. Los autores señalan que los resultados obtenidos deben ser verificados por la experiencia práctica o por experimentos especiales.

Después del estudio llevado a cabo por Pohl et al., los autores Park et al. [7–10] y Richards et al. [11, 12] desarrollaron diversos estudios sobre una muy pequeña planta desalinizadora instalada en un laboratorio de la Universidad Heriot-Watt

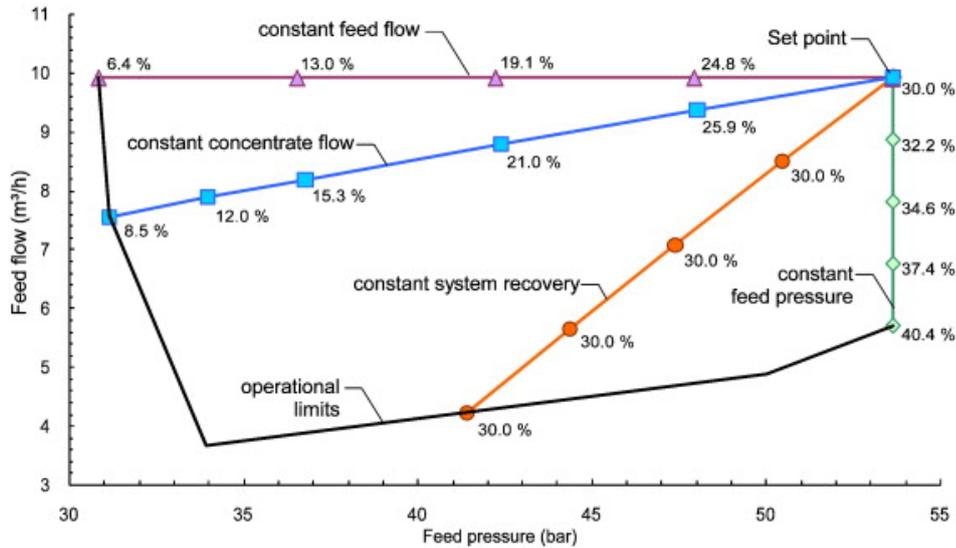


Fig. 2.7: Análisis llevado a cabo por Pohl et. al [6] al simular las cuatro estrategias propuestas para operar un sistema de desalación de agua en régimen variable dentro de un área operativa segura (SOW).

(Reino Unido). Dicho sistema emplea una sola membrana de agua salobre BW30-4040 DOW Filmtec™, a la cual se le introduce una solución salina de laboratorio que se prepara en un tanque. Para ello se utiliza una pequeña bomba que eleva la presión del fluido hasta unos 12 bar y que es accionada mediante un variador de velocidad. El variador de velocidad es alimentado alternativamente mediante un pequeño aerogenerador de 1 kW a 12.5 m/s FuturEnergy™, o una fuente de potencia programable. El sistema, además, contiene los filtros, válvulas y sensores propios de un sistema de desalación por ósmosis inversa. Su consumo nominal es de 240 W y su producción de agua de unos 300 l/h ($0.3 \text{ m}^3/\text{h}$). Las conclusiones de dichos estudios son diversas pero, entre ellas, destacan las siguientes:

- Si la planta desalinizadora trabaja dentro de los márgenes operativos facilitados por el fabricante, los resultados obtenidos al trabajar en régimen fluctuante y en régimen constante son similares.
- El funcionamiento de la planta sólo se ve afectado cuando la planta opera a muy bajo régimen y existen fluctuaciones a ese nivel operativo.

- Un sistema dinámico de energía, que funcione como *buffer* energético para amortiguar la intermitencia del viento, resulta útil en un sistema que conecta directamente una turbina eólica con una planta desalinizadora. Los supercondensadores resultan ser muy efectivos absorbiendo las oscilaciones de potencia en un rango temporal entre 15 seg. y 20 min. Su uso permite valores más elevados de calidad de agua media y cantidad de agua media producida.

Los autores de dichos estudios señalaron que la estrategia óptima de operación de un sistema de este tipo es la sugerida por Pohl et al. [6]. Es decir, trabajar con una recuperación de agua constante. No obstante ellos aplicaron la estrategia de mantener una de las variables de la planta constante (presión de operación) por su simplicidad de uso, lo cual restó cierta potencialidad a los estudios llevados a cabo.

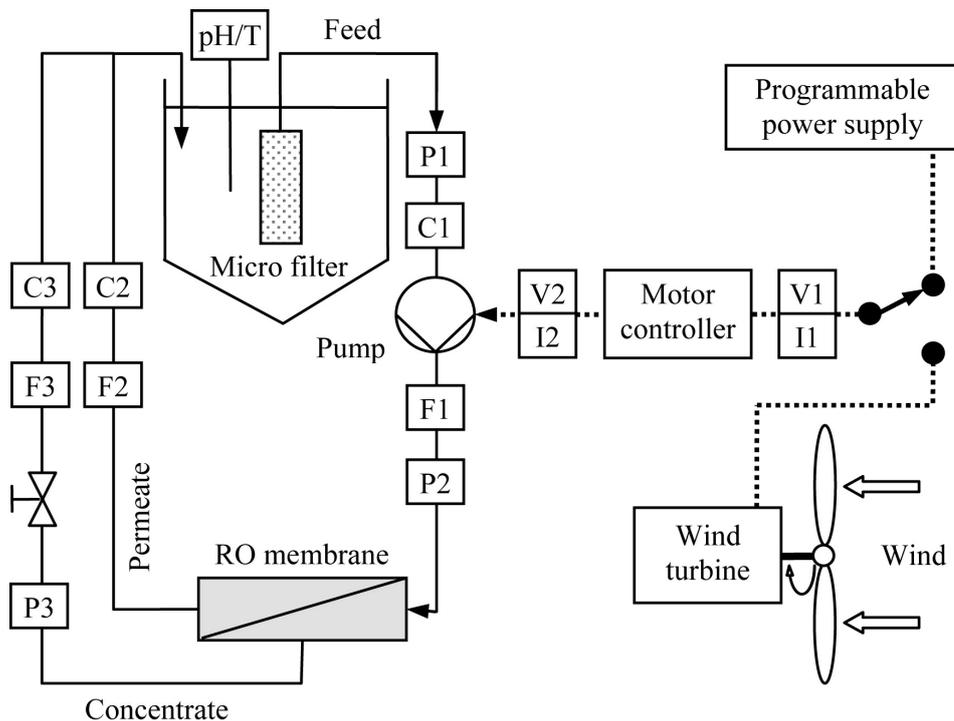


Fig. 2.8: Diagrama esquemático del sistema de membranas accionado por energía eólica desarrollado por Park et. al [7] y empleado en los estudios [7–12].

2.3 Utilización de técnicas de *Machine Learning* en sistemas de desalación

A partir de 1993, cuando El-Hawary [125] divulgó en la revista *Desalination* una lista de posibles aplicaciones de las técnicas de *Machine Learning* en sistemas de desalinización, han sido varios los autores que han usado estas técnicas en este área. El-Hawary se centró en analizar el potencial de aplicabilidad que tienen las redes neuronales artificiales (ANNs, de sus siglas en inglés) en las plantas desaladoras en general y desarrolla con especial atención los posibles usos de éstas en el procesado de alarmas, en la detección de fallos, en los sistemas de control, en la optimización operacional de las plantas, en la previsión de cargas para anticipar las desviaciones entre la demanda y la generación, para así programar la generación necesaria y, por último, en la evaluación de seguridad, para actuar y ejecutar el plan de contingencia adecuado a cada estado de la planta. Posteriormente, Rao et al. [126] profundizan en la conveniencia de aplicar técnicas de inteligencia artificial (IA) en los sistemas de control de las plantas desalinizadoras de tecnología *multistage flash* (MSF) y desarrollan una jerarquía de control inteligente basado en redes neuronales para dichas plantas. En primer lugar definen los diferentes niveles que debe tener un sistema de automatización inteligente evolucionado, luego detallan los problemas en cada uno de los niveles del sistema de control y la potencialidad que tienen las redes neuronales para resolverlos. De acuerdo con la jerarquía expuesta y teniendo en cuenta el trabajo previo llevado a cabo por Stephanopoulos [127], Rao et al. indican que las aplicaciones de la IA en los sistemas de control de la ingeniería de procesos en general y de las plantas de desalinización en particular deben dividirse en cuatro grupos: 1) Supervisión y optimización, 2) modelado e identificación, 3) control adaptativo and 4) sistemas de control convencionales.

No obstante, a pesar de las sugerencias de estos autores la mayoría de estudios desarrollados a partir de estas fechas en este área se han centrado en el modelado y simulación del funcionamiento de distintas plantas desalinizadoras alrededor del mundo. A continuación se describen varios estudios en este sentido:

Al-Shayji and Liu [13, 128, 129] emplean ANNs para modelar el rendimiento operativo de dos plantas desalinizadoras comerciales de gran escala, una planta

desalinizadora MSF de 181.760 m³/día situada en Kuwait y una planta de OI de 56.800 m³/día localizada en Arabia Saudí. Como aspectos destacables de la experiencia que Shayji & Liu llevan a cabo con la planta de OI de Arabia Saudí, se utilizan datos horarios tomados durante un mes de las siguientes variables operativas: temperatura, presión, caudal y pH de alimentación y caudal y conductividades del producto. Luego, se preparan dos arquitecturas para estimar por un lado el caudal producto y, por otro, la conductividad producto. Los autores estudian la conveniencia de aplicar una selección de variables (*feature selection*) como la que proporciona el análisis de componentes principales (PCA, de las siglas en inglés de *Principal Components Analysis*) para reducir la complejidad del subconjunto de datos de entrada, pero concluyen que es mejor emplear un mayor número de variables seleccionadas mediante el *knowhow* acumulado. Recomiendan encarecidamente la normalización de los datos de entrada y salida que intervienen en el proceso para que tengan todos el mismo orden de magnitud y no se produzca un incremento de la significancia en aquellas variables con mayores ordenes de magnitud. Emplean tres técnicas de normalización y concluyen que la técnica más apropiada es aquella que normaliza los datos entre los límites -1 y +1 con el valor medio fijado a cero. También analizan el tipo de configuración de red a aplicar, buscando la idoneidad de usar dos *multiple-input-single-output* (MISO) *networks* o una *multiple-input-multiple-output* (MIMO) *network*. Todas las arquitecturas de redes neuronales empleadas tienen una capa de entrada con cuatro neuronas (cuatro entradas) y dos capas ocultas (*hidden layers*) consecutivas con 30 neuronas y 15 neuronas cada una. La capa de salida dispone de una neurona en las configuraciones MISO y de dos neuronas (una por salida) en la configuración MIMO. Las entradas empleadas en las tres redes neuronales analizadas son la temperatura, la presión, el caudal y el pH de alimentación. El conjunto inicial de datos registrados se subdividió en dos partes iguales, 50 % se empleó como conjunto de entrenamiento y el otro 50 % como conjunto de test. Los resultados obtenidos por una y otra configuración (*MISO and MIMO networks*) no presentaron diferencias significativas.

Jafar & Zilouchian [14, 15] también emplean ANNs para modelar el comportamiento de dos plantas desalinizadoras de OI con dos tomas de agua de alimentación diferentes (de agua salobre y de agua de mar respectivamente). Los autores usan una *radial basis function network* (RBFN) y comparan su rendimiento con el que

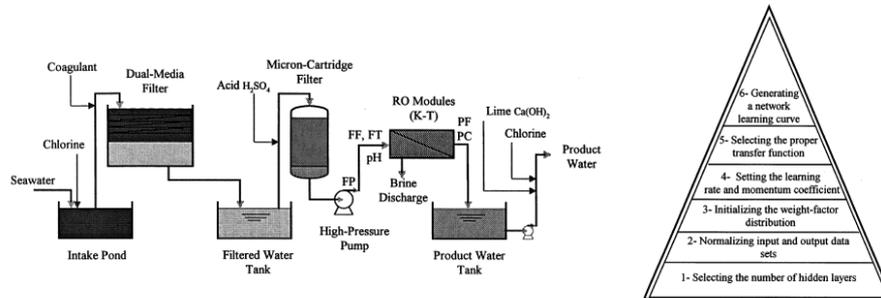


Fig. 2.9: Planta desalinizadora de ósmosis inversa empleada por Al-Shayji & Liu [13] y procedimiento propuesto por los autores para configurar las redes neuronales que predicen el comportamiento de dicha planta.

ofrece una *feedforward* ANN. Con ambos tipos de ANN predicen una variable distinta en cada planta desalinizadora con el objetivo de cuantificar la calidad del agua de permeado. En la primera planta se predice el caudal de permeado y en la segunda el número de sólidos totales disueltos (TDS de las siglas en inglés de Total Dissolved Solids). El conjunto de datos total utilizado contiene 800 registros y dicho conjunto se dividió en dos grupos de igual tamaño (400 registros para el subconjunto de entrenamiento y 400 para el subconjunto *test*). A su vez, el subconjunto de entrenamiento se dividió en dos partes iguales (*training* y *validation subsets*). Todas las entradas y salidas se normalizaron al rango [-1,1]. Los autores no dejan claro algunos detalles del estudio, como el tipo y el número de variables de entrada que utilizan, pero concluyen que la RBFN ofrecen un mejor rendimiento que la *feedforward* ANN entrenadas con el algoritmo de retropropagación (*back-propagation algorithm*). Las RBFN obtienen errores menores con un número de neuronas considerablemente menor pero con un coste computacional más elevado.

Otro ejemplo del uso de ANNs aplicadas al modelado y simulación del comportamiento de una planta desalinizadora es el trabajo desarrollado por Murthy & Vora [16]. En él se entrena una *back-propagation* ANN con dos capas ocultas de 10 neuronas cada una; tres neuronas en la primera capa, cuyas entradas son los datos de concentración, presión y caudal respectivamente, y dos neuronas en la capa de salida para predecir los valores de caudal de rechazo y permeado. En dicho estudio se ensaya una planta de laboratorio con un sistema de agua NaCl desarrollado por

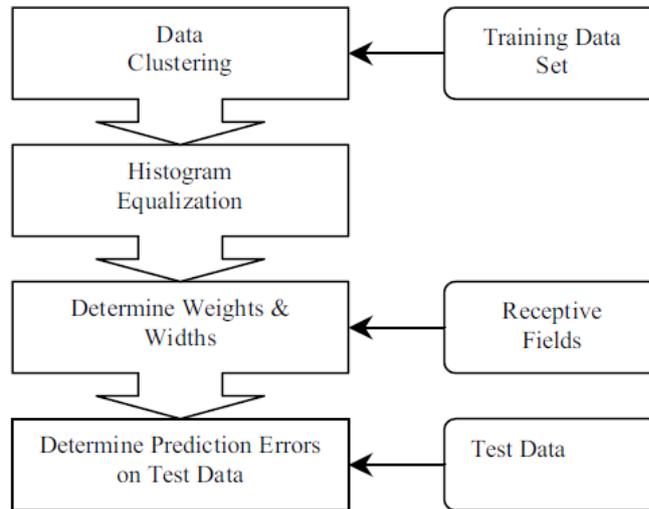


Fig. 2.10: Procedimiento que siguen Jafar & Zilouchian [14, 15] para configurar las redes neuronales que utilizan.

los autores que cambia la concentración del agua entre 1000-3000 ppm, la presión entre 20 y 100 atm y el caudal entre 300 y 1500 ml/min. Los autores concluyen que las ANN ofrecen unos resultados lo suficientemente satisfactorios como para poder usarse en el modelado, el control *on-line*, la predicción y la simulación del sistema [16].

Abbas & Al-Basaki [17] predicen el índice de producción de agua de una unidad de OI a partir de los valores de temperatura, presión y concentraciones de sales del agua de alimentación. Para el estudio emplean una membrana FilmTec SW30, y diseñan una metodología de recogida de datos en la que todos los experimentos mantienen el caudal de alimentación constante a 0.5 m³/h y se varían los parámetros de presión, concentración y temperatura. Cada ensayo de recogida de muestras dura un total de 30 min de entre los cuales 10 min se emplean para estabilizar el proceso y 20 min para la captura de datos. Con dichas muestras los autores prueban distintas configuraciones de *feedforward* ANN que incluyen una y dos capas ocultas, y 3, 5, 10 y 15 neuronas por cada capa oculta. Finalmente, la red neuronal más simple que les proporcionó menores errores RMSE fue la arquitectura de ANN formada por una única capa oculta compuesta por 5 neuronas. Con esta arquitec-

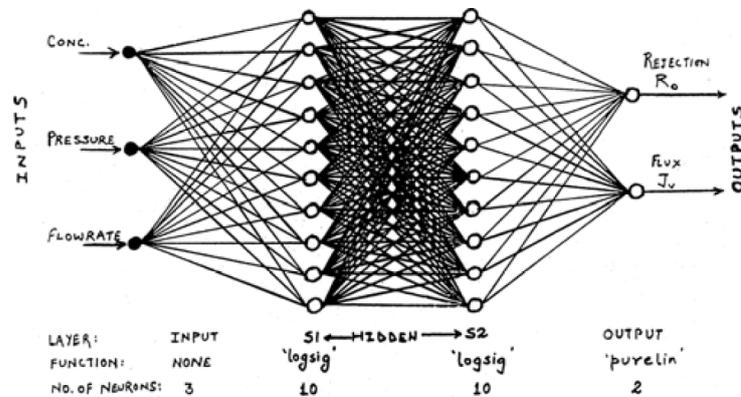


Fig. 2.11: Estructura de la ANN empleada por Murthy & Vora [16] para modelar y simular el comportamiento de una planta desalinizadora por ósmosis inversa.

tura entrenaron y sometieron a la ANN a tres escenarios de prueba diferentes para analizar la habilidad de la ANN al interpolar y extrapolar los datos recogidos. Con ello los autores obtuvieron un buen comportamiento de la ANN en la interpolación pero un pobre comportamiento de la misma en la extrapolación.

La experiencia que llevan a cabo los autores Lee et al. [18] en una planta de OI de agua de mar localizada en Emiratos Árabes Unidos y construida para producir 464,000 m³/día, se diferencia de las anteriores en que emplean dos variables adicionales como entradas a la ANN (Fig. 2.13). Utilizan las tres variables de entrada más comunes (temperatura, conductividad y caudal de agua de mar), pero además le introducen a la ANN los datos de tiempo de operación transcurrido (días) y los datos de la diferencia entre las presiones medidas a la entrada y a la salida de la membrana (*trans-membrane pressure - TMP* (bar)). Los autores utilizan 200 muestras de datos tomadas en la planta durante un año de operación. La *feed-forward* ANN empleada se construyó con una neurona por cada variable de entrada en la primera capa y dos neuronas en la capa de salida con los registros de TDS en el permeado y de caudal en el permeado. Se empleó una única capa oculta con 15 neuronas. El entrenamiento se hizo usando el *back-propagation algorithm*, dividiendo aleatoriamente los datos en tres grupos (*training* (60%), *validation* (20%) y *test* (20%)) y empleando la técnica de *early stopping* para evitar el sobreajuste [18]. Los autores obtienen ajustes de $R^2=0.96$ y $R^2=0.75$ entre las variables observa-

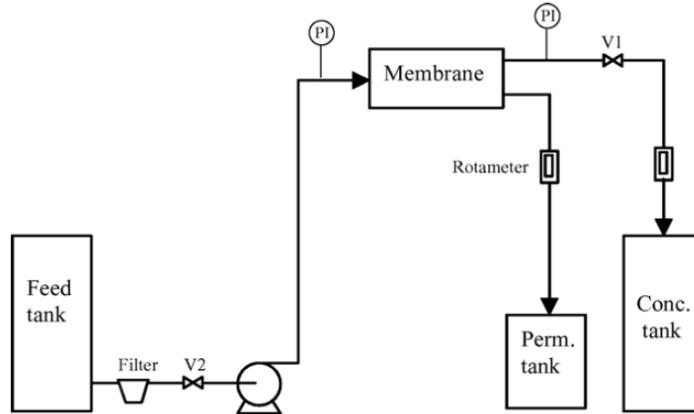


Fig. 2.12: Diagrama del diseño empleado por Abbas & Al-Basaki [17] para capturar los datos de entrenamiento que sirven para la configuración de las ANNs empleadas por los autores.

das y simuladas de TDS y caudal de permeado respectivamente. El análisis de los resultados de las variables simuladas es interesante ya que observan la dependencia existente entre los TDS en el permeado y la temperatura en el agua de alimentación. Sin embargo, la TMP le afecta menos. Además, observan que a medida que la TMP aumenta, también lo hace el caudal de permeado y proponen la maximización de la producción de agua actuando sobre la temperatura de alimentación para que aumente linealmente desde 27.5 hasta 29.5°C en el transcurso de un año.

Por último, Aish et al. [130] predicen el funcionamiento de cinco desalinizadoras de OI de agua salobre localizadas en la Franja de Gaza empleando dos clases de ANNs. Entrenan y validan dos *multilayer perceptron - artificial neural networks* (MLP-ANN) independientes para estimar un parámetro de calidad del agua con cada una de ellas. Ambas MLP-ANN se entrenan con un total de 120 registros de datos, recogidos cada semana durante un periodo de seis meses en las cinco plantas analizadas. También normalizan los datos de entrada y salida, aunque emplean la normalización al rango [0,1]. La primera de las MLP-ANNs utilizadas predice a una semana vista el valor de TDS en mg/l a partir de los datos actuales de temperatura del agua (°C), presión (bar), pH y conductividad eléctrica ($\mu\text{S}/\text{cm}$). Esta MLP-ANN contiene tres capas con cuatro neuronas en la primera capa, seis

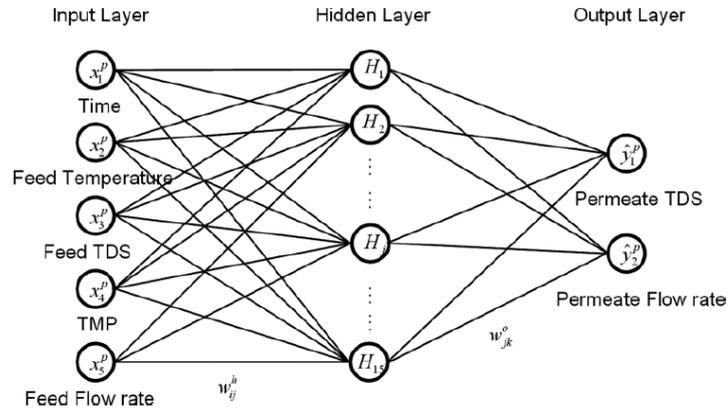


Fig. 2.13: Diagrama esquemático de la ANN utilizada por Lee et al. [18]

neuronas en la capa oculta y una neurona en la capa de salida. La segunda MLP-ANN predice a una semana vista el caudal de agua producto (m^3/h) empleando como datos de entrada la presión de alimentación (bar), el pH de alimentación y la conductividad de alimentación actuales. Esta segunda MLP-ANN también se construye con tres capas pero emplea tres neuronas en la primera capa, seis neuronas en la capa oculta y una única neurona en la capa de salida. Los autores comparan estos resultados con los obtenidos al entrenar dos *radial basis function* (RBF) *neural networks* independientes con las mismas salidas y entradas que en el caso anterior pero diferente número de neuronas en la capa oculta. A pesar de que para las *RBF neural networks* emplean un mayor número de neuronas en la capa oculta, el resultado de las MLP-ANN es más preciso.

Descripción de los equipos utilizados para el desarrollo y la gestión variable de un prototipo de planta desalinizadora

3.1 Introducción

Esta tesis tiene un fuerte carácter experimental y, por tanto, el diseño y la puesta en marcha de un prototipo resulta fundamental para la investigación que se pretende realizar, así como para futuras líneas derivadas de este trabajo. La calidad de los resultados obtenidos dependerá en buena medida de la calidad del prototipo desarrollado y, por ello, se dedica todo un capítulo a la descripción pormenorizada del sistema implementado y de los materiales utilizados.

Como ocurre en la gran mayoría de los trabajos de investigación, esta tesis deriva de una línea de trabajo iniciada desde hace años por personas que, de forma consciente y desinteresada, han contribuido a que se den las condiciones apropiadas para el desarrollo de trabajos como este. En este caso, el estudio de sistemas

de desalación accionados por energías renovables viene siendo un tema recurrente en el Instituto Tecnológico de Canarias (ITC) así como en el Departamento de Ingeniería Mecánica y en el Group for thre Research on Renewable Energy Systems (GRRES) de la Universidad de Las Palmas de Gran Canaria (ULPGC) . Desde la década de los 80 estas instituciones han liderado proyectos y propuestas relacionados con este ámbito de estudio. Ello ha permitido que este trabajo pueda desarrollarse dentro de las instalaciones del ITC, que se lleve a cabo desde el Departamento de Ingeniería Mecánica de la ULPGC y que haya sido posible aprovechar buena parte de los materiales utilizados en trabajos anteriores desarrollados por estas instituciones.

3.2 Descripción del prototipo

3.2.1 Descripción del prototipo inicial. Materiales de partida



- ① Estación de bombeo. ② Aljibe de agua producto. ③ Anemómetro y veleta. ④ Planta desalinizadora.

Fig. 3.1: Localización de los elementos principales del proyecto en la parcela de Pozo Izquierdo.

El desarrollo del proyecto descrito en esta tesis parte de un prototipo de planta de desalación de osmosis inversa para agua de mar, denominado AEROGEDESA [104], instalado en las dependencias del Instituto Tecnológico de Canarias (Isla de Gran Canaria, España), Fig. 3.1. El objetivo de este era producir agua potable a partir del agua de mar, empleando energía eólica y un sistema de almacenamiento

energético basado en baterías. La diferencia fundamental entre el prototipo ideado para el proyecto AEROGEDESA y el desarrollado para este trabajo radica en que el primero estaba diseñado para trabajar en régimen constante de presión y caudal de alimentación y, sin embargo, este nuevo se diseña para operar de forma variable.

El aerogenerador

El prototipo original (AEROGEDESA) es accionado por una turbina eólica de la marca Vergnet (modelo GEV10/15) que cuenta con un generador asíncrono de 15kW de potencia nominal, excitado por una batería de condensadores que le proporciona la energía reactiva necesaria para la magnetización del estátor. Se trata, de un aerogenerador bipala con palas fabricadas en fibra de vidrio que produce energía eléctrica trifásica a 400V y 50Hz. Tiene veleta para orientarse al viento y su regulación es inercial (*pitch*), o guiada por la velocidad de rotación. La velocidad de conexión de la máquina es de 4,5 m/s con un pitch arranque/nominal de 10°. El diámetro del rotor es de 10 m y la velocidad de giro nominal es de 139 r.p.m. para una velocidad de viento de 13 m/s. La máquina está instalada sobre una torre atirantada y abatible que la eleva a 18 m de altura.

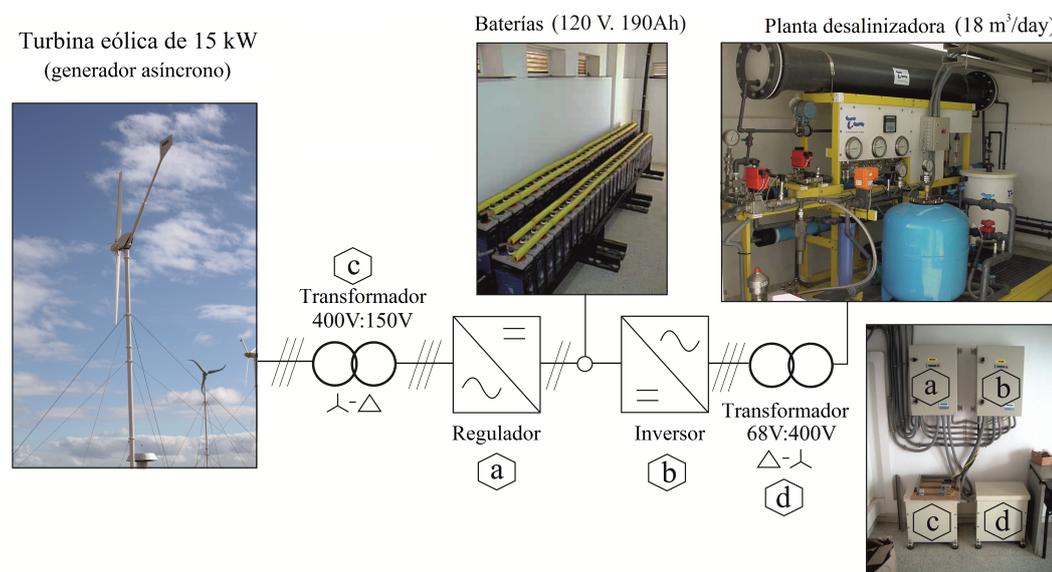


Fig. 3.2: Esquema del sistema eólico para desalación de agua de mar denominado AEROGEDESA.

El sistema de almacenamiento energético intermedio

El sistema de almacenamiento energético está formado por un banco de baterías que contiene 60 vasos de 2V cada uno [131]. El aerogenerador vuelca la energía generada a dicho banco de acumuladores a través de un transformador/rectificador. La carga del sistema de almacenamiento está gestionada por un regulador que evita la sobrecarga de las baterías y la descarga excesiva de las mismas. Cuando el nivel de carga de los acumuladores llega a un nivel predeterminado, se activa el inversor, que es el encargado de convertir la corriente continua de las baterías a la corriente alterna necesaria para el funcionamiento de la planta. Se usa un transformador para adecuar el nivel de tensión a la salida del inversor al nivel de tensión a la entrada de la planta desalinizadora.

La planta desalinizadora de ósmosis inversa

La planta desalinizadora, con una capacidad de 18 m³/día, está constituida por dos tubos de presión conectados en serie, cada uno de los cuales contiene tres membranas dispuestas en serie (Fig.3.3). Los datos más representativos de la misma se muestran en la tabla 3.1.

Tabla 3.1: Resumen de las principales características de la planta desalinizadora empleada en el proyecto AEROGEDESA.

Capacidad de producción nominal	18 m ³ /día
Presión nominal de operación	64 bar
Caudal de alimentación nominal	75 m ³ /día
Índice de conversión	24 %
Consumo de energía específico	8.4 kWh/m ³
Número de tubos de presión	2
Número de membranas instaladas en serie dentro de cada tubo	3
Tipo de membranas	FILMTEC SW 30-4040 HR
Configuración de los tubos de presión	En serie

Dado que la planta posee un sistema de almacenamiento masivo de energía en baterías, Fig.3.2, la planta desaladora opera en régimen constante de presión

(64 bar) y caudal de alimentación (75 m³/día), con una conversión del 24 % y un consumo específico de energía de 8.4 kWh/m³. Subiela et al. [104] han mostrado las gráficas de producción de agua durante un mes y durante días con velocidad del viento media y velocidad del viento alta, pudiendo observarse la constancia del caudal producto, independientemente de la potencia generada por la turbina eólica, en los periodos que se disponía de energía suficiente y los periodos de parada de la planta, como consecuencia de no disponerse de energía suficiente en las baterías para la operación de la planta en el punto de diseño de la misma.

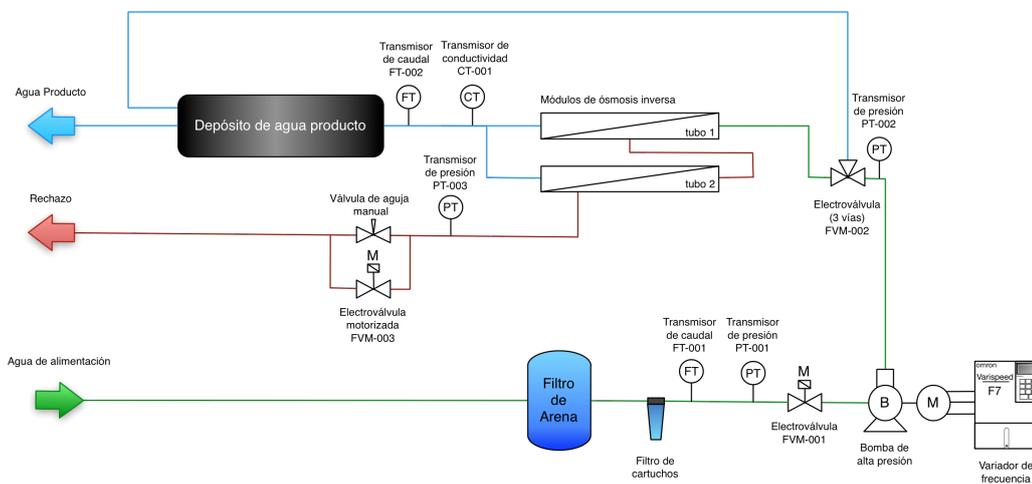


Fig. 3.3: Esquema hidráulico de de la planta desalinizadora empleada en el proyecto AEROGEDESA.

3.2.2 Esquema general del sistema completo

En la Fig. 3.4 se muestra un esquema general de la configuración del sistema de desalación con energía eólica que se pretende desarrollar a corto plazo. Asimismo, en dicha figura se delimita con una línea de trazos el subsistema ya diseñado y ensayado, cuyos resultados obtenidos son objeto de análisis en esta tesis doctoral.

De la observación de las figuras 3.2 y 3.4 se desprende que se propone la sustitución del aerogenerador de inducción en jaula de ardilla autoexcitado por un aerogenerador síncrono de imanes permanentes, cuya potencia nominal coincida

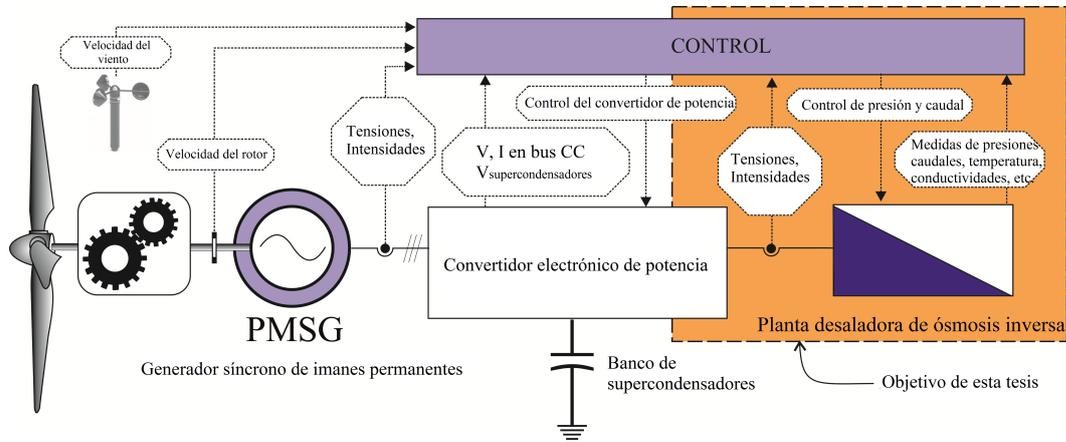


Fig. 3.4: Diagrama general del sistema eólico global para la desalación de agua de mar en régimen variable. De este sistema global, que se encuentra en desarrollo, se muestra el subsistema objeto de análisis en esta tesis encerrado en líneas discontinuas.

con la potencia máxima demandada por el sistema de desalación. Dicho cambio se debe a que el primero presenta puntos de inestabilidades en su funcionamiento aislado en cuanto a la tensión y frecuencia eléctrica se refiere. Además, dicho generador es muy propenso a desmagnetizarse con facilidad frente a cambios en la carga y la turbina eólica presenta limitadas capacidades de regulación de la potencia eólica captada. Asimismo, se propone sustituir las baterías como sistema de almacenamiento masivo de energía por un banco de supercondensadores que actúe como elemento amortiguador frente a cambios transitorios que se produzcan cuando el sistema de control trate de ajustar la demanda de potencia de la carga a la oferta de potencia eólica. La selección de dicho sistema de regulación dinámica se ha basado en las ventajas que estos presentan en aplicaciones donde se requiere un intercambio de potencia en intervalos muy cortos de tiempo [132–134], con rápidas cargas y descargas, alta eficiencia energética, elevados ciclos de operación por año, profundas descargas y alta densidad de potencia [135].

No obstante, dado que este sistema tiene un propósito experimental y el desarrollo de esta tesis se centra en la planta desalinizadora, el sistema final contempla la posibilidad de conectar la planta desalinizadora a la red eléctrica convencional, tal y como se observa más detalladamente en la Fig. 3.5.

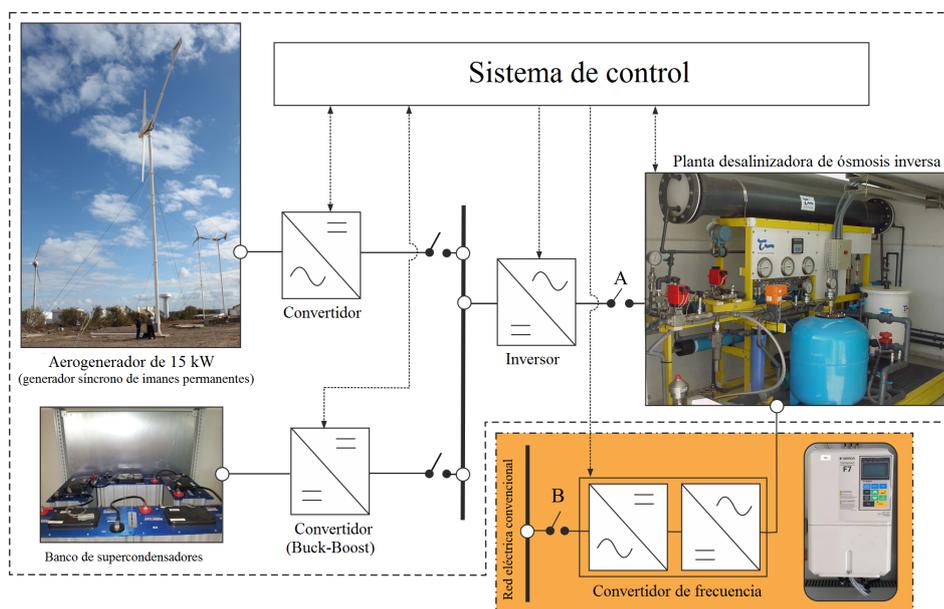


Fig. 3.5: Sistema global con interruptores A y B que posibilitan la conexión y desconexión a la red eléctrica convencional del subsistema objeto de análisis en esta tesis.

3.2.3 Nuevo sistema de desalinización propuesto. Diseño del prototipo empleado

En la Fig. 3.6 se muestra el esquema de la planta de OI, que se diseñó empleando como punto de partida el prototipo AEROGEDESA [104] descrito en apartados anteriores. Con las modificaciones realizadas, el nuevo prototipo puede operar en régimen variable de presión y caudal y admite que el sistema de control seleccione el número de tubos de presión que deben actuar en cada momento para adaptar su consumo a la variación de la oferta de potencia eléctrica de procedencia eólica.

Los cambios más relevantes realizados en el circuito hidráulico del sistema de desalación han sido la disposición en paralelo de los dos tubos de presión (PV1 y PV2), que en el prototipo AEROGEDESA estaban configurados en serie, y la instalación de una servoválvula de control proporcional (PSV) en el circuito del caudal de rechazo de la planta de OI.

Respecto a este último cambio hay que señalar que, inicialmente, dicha válvula fue de tipo de bola (PSV-1), pero posteriormente se instaló en paralelo con la

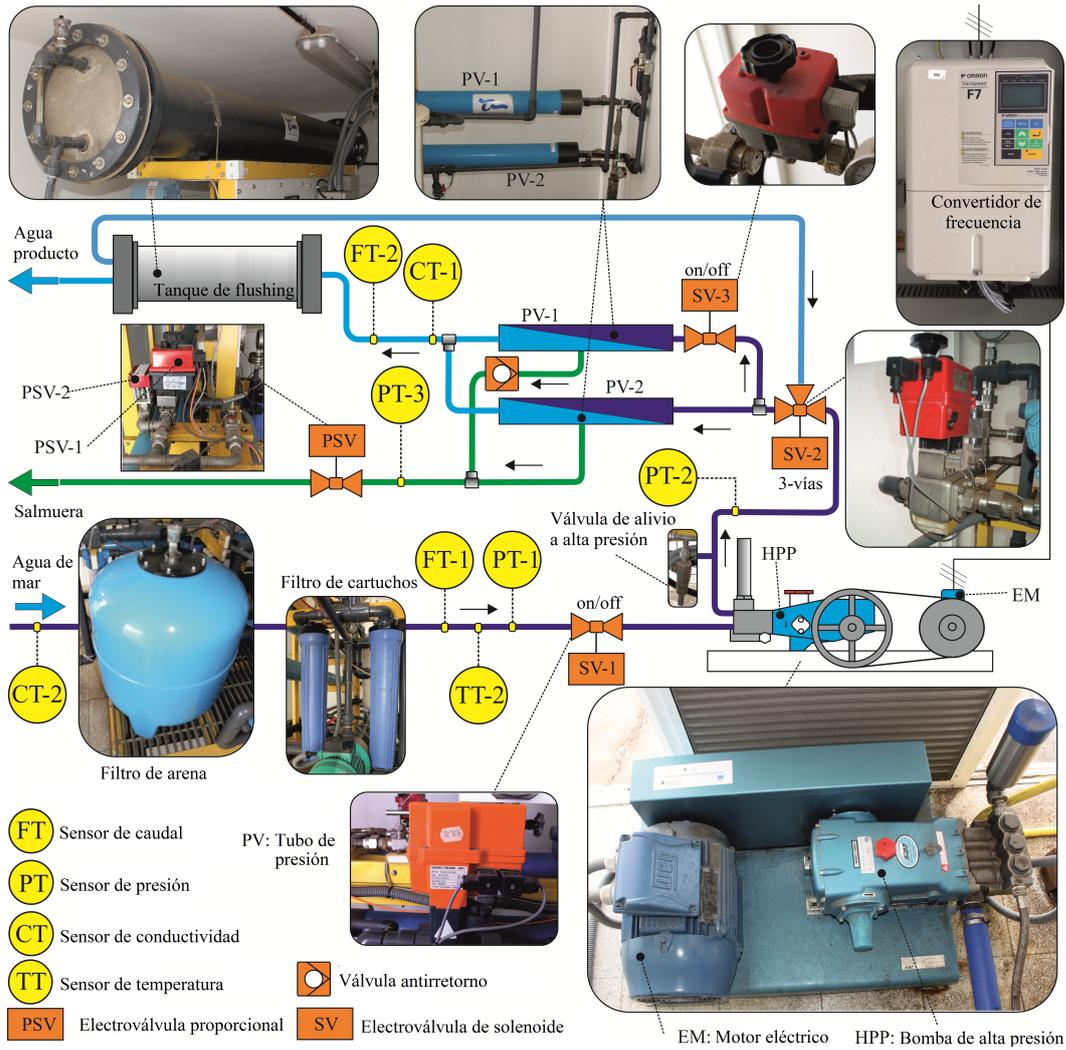


Fig. 3.6: Esquema hidráulico general del nuevo prototipo de planta desalinizadora empleado en esta tesis.

misma otra válvula de aguja (PSV-2), dados los inconvenientes que presentaba la primera desde el punto de vista del control de presión. Otros cambios realizados en el circuito hidráulico han sido:

- a) La sustitución de la bomba de alta presión de desplazamiento positivo (HPP - High Pressure Pump) y su motor de accionamiento (EM - Electrical Motor) por un sistema de mayor capacidad (MOTOR WEG-modelo W22 y bomba CAT 3541), dados los nuevos requerimientos de caudal de alimentación del sistema diseñado. El caudal nominal de la bomba CAT 3541, construida enteramente en acero inoxidable, es de 10.20 m³/h (765 rpm) y la presión de descarga se encuentra en el intervalo 7-70 bar. El motor eléctrico WEG-W22 (con un tipo de aislamiento F) es de tipo asíncrono con una potencia nominal de 11 kW, una intensidad nominal de 21.9 A y un factor de potencia, en condiciones nominales, de $\cos\phi = 0,85$. Como consecuencia de lo anterior, fue necesario cierto redimensionado del circuito hidráulico para su adaptación a los nuevos caudales y la instalación de nuevos sensores de caudal. Además, dado que los motores de inducción pueden presentar una mayor elevación de la temperatura cuando son alimentados por convertidores de frecuencia, se ha instalado en el interior del mismo un sensor de temperatura (TT-1) para analizar los potenciales sobrecalentamientos y, si fuese necesario, tomar las medidas oportunas para evitarlos.
- b) La instalación de una electroválvula (todo/nada) (SV-3) que permite o impide la entrada de agua de mar a alta presión en uno de los tubos de presión.
- c) La instalación de una válvula antirretorno a la salida del caudal de rechazo de uno de los tubos de presión. Dicha válvula impide que el caudal de rechazo del tubo en operación entre en el otro tubo cuando éste último está inoperativo.
- d) El cambio de las seis membranas iniciales por otras seis membranas nuevas de la marca TORAY, modelo TM810 (Tabla 3.2) y el cambio de los filtros de cartucho.
- e) La instalación de un conductivímetro (CT-2) con compensador automático de temperatura (ATC - Automatic Temperature Compensation) y un sensor de temperatura (TT-2) con el objeto de registrar las variaciones de la concentración de

Sólidos Totales Disueltos (TDS - Total Dissolved Solids) y temperatura del agua de mar de alimentación.

Tabla 3.2: Características de las membranas Toray utilizadas en el prototipo.

Modelo	TM810	Rechazo de sales mínimo	99.75 %
Configuración	Enrollado en espiral	Agua producto nominal	4.5 m ³ /día
Material	Aramida (Poliamida aromática)	Presión máxima de operación	69 bar
Diámetro	4"	Temperatura máxima del agua	45°C
Área	7 m ²	Rango de pH del agua de mar	2–11

Desde el punto de vista del circuito de potencia, el cambio fundamental ha sido la configuración del convertidor de frecuencia (OMRON Varispeed F7) (Tabla 3.3) para que el sistema de control pueda variar la velocidad de giro del motor eléctrico que acciona la bomba de alta presión y, consecuentemente, se modifique el caudal impulsado hacia las membranas por esta última.

Tabla 3.3: Características del convertidor de frecuencia utilizado (Omron Varispeed F7).

Modelo	CIMR-F7Z4011
Capacidad de salida	18 kVA
Tensión de entrada	380–480V
Intensidad de entrada	29A
Tensión de salida	0–480V
Intensidad máxima de salida	24A
Frecuencia de salida	0–400Hz

En la operación de la planta, el agua de mar procedente de un pozo de playa (señalado con el número 2 en la Fig. 3.1), pasa a través de un filtro de arena (CALPLAS FB-35, con 0.70 m² de superficie de filtración) y de filtros de cartucho de 3 micras hasta una electroválvula todo/nada (SV-1), accionada por el sistema de control, que en el caso de estar abierta permite que el caudal de agua de mar alimente a baja presión a la bomba de alta presión (HPP), Fig. 3.6. En el trayecto que el agua de mar recorre hasta su entrada en la bomba de alta presión el circuito

hidráulico dispone de tres sensores: un sensor de caudal (FT-1), un sensor de presión (PT-1), un sensor de temperatura (TT-2) y un sensor de conductividad (CT-2), que transmiten la información captada al sistema de control, Fig. 3.7.

En el tramo de circuito hidráulico instalado entre la bomba de alta presión y los tubos de presión se cuenta con una válvula de alivio, que limita a 67 bar la presión máxima del agua que puede entrar en las membranas, y de una electroválvula de tres vías (SV-2). Dicha electroválvula, accionada por el sistema de control, permite seleccionar el fluido de entrada a los tubos de presión (PV-1 y PV-2). Es decir, o bien permite la entrada del agua de mar impulsada por la bomba de alta presión a los tubos de presión que contienen las membranas de OI, o bien, permite la entrada de agua producto desde un tanque de agua producto situado en la parte superior de la planta y que, gracias a la fuerza de la gravedad, facilita el flushing de las membranas en los periodos de parada de la planta de OI. La presión que se produce a la entrada de los tubos de membranas es medida por un sensor de presión (PT-1) y transmitida al sistema de control.

El caudal de agua producto y su conductividad son medidos por los correspondientes sensores (FT2 y CT-1 con ATC) instalados entre el sistema de membranas y el tanque de flushing. Dichos sensores transmiten la información registrada al sistema de control, Fig. 3.7. Otro de los parámetros medidos y transmitidos al sistema de control es la presión del agua de rechazo. El sensor encargado de ello (PT-3) se encuentra instalado entre la válvula PSV y la tubería que unifica los caudales de rechazo de ambos tubos de presión.

3.3 El esquema de control utilizado

En la figura 3.7 puede observarse un diagrama simplificado del esquema de control empleado en esta tesis doctoral.

Tal y como se observa en la esquina superior derecha de dicha figura, el convertidor de frecuencia que acciona el motor de la bomba de alta presión de la planta se conecta a la red eléctrica convencional mediante un cable trifásico. Las intensidades y tensiones de línea son medidas por un equipo de instrumentación diseñado para este propósito. Dichas señales permiten calcular el consumo de potencia de la

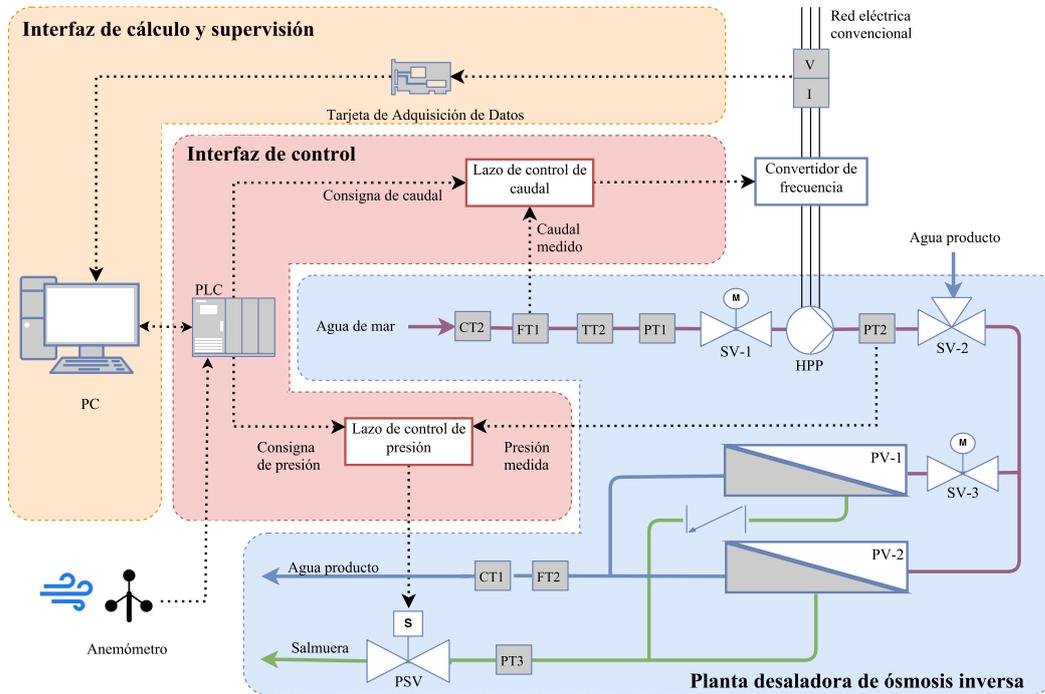


Fig. 3.7: Diagrama del esquema de control empleado en la planta desalinizadora.

planta y se transmiten, mediante una tarjeta de adquisición de datos, al ordenador principal del sistema. Este ordenador es el encargado de realizar los cálculos más complejos del sistema, de establecer la estrategia de control y de supervisar todo el proceso.

El ordenador principal se encuentra conectado bidireccionalmente con la interfaz de control, cuya unidad principal es un autómata programable Allen Bradley SLC 500. Dicho autómata recibe todas las variables provenientes de los equipos de medida instalados en la planta y la variable de velocidad de viento medida por el anemómetro de cazoletas instalado sobre la caseta de la planta desalinizadora (ver número 3 de la figura 3.1). Con estas variables, el autómata calcula el valor de potencia eólica disponible a partir de la velocidad del viento medida por el anemómetro y de la curva de potencia facilitada por el fabricante del aerogenerador Vergnet 10/15 (Fig. 3.8). Posteriormente, en función de la potencia eólica calculada, envía una orden a todos los actuadores de la planta para configurarla y situarla en uno de los posibles estados de operación definidos (ver Fig. 3.9).

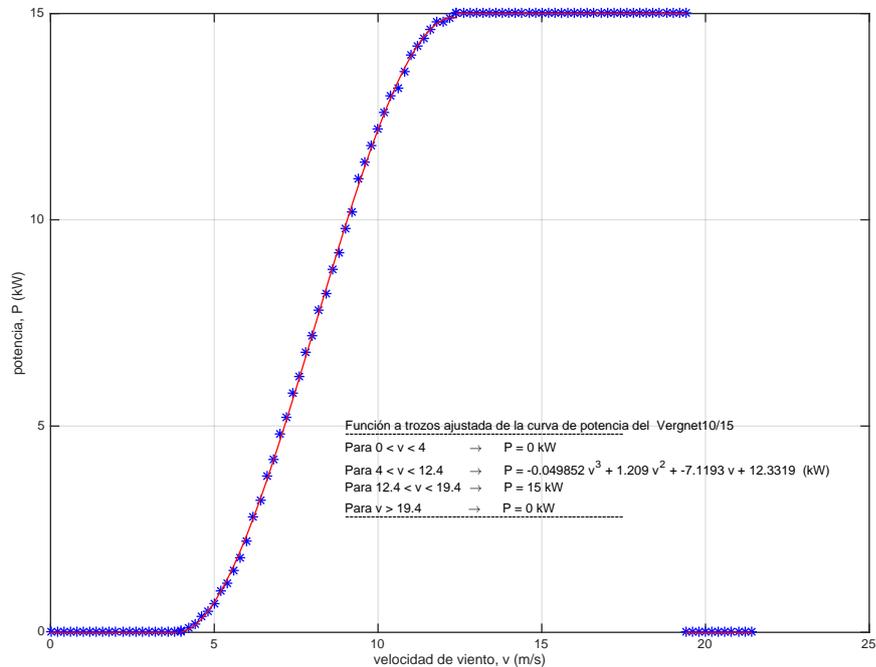


Fig. 3.8: Curva de potencia del aerogenerador Vergnet 10/15.

Los posibles estados de operación en los que trabajará la planta son los siguientes:

1. **Estado de parada.** La planta se encuentra completamente detenida de manera que únicamente permanece activo el sistema de control adquiriendo las señales de los distintos sensores.
2. **Estado de arranque.** El sistema de control detecta que se dan las condiciones necesarias para el arranque y, por tanto, proporciona las órdenes oportunas para que todos los actuadores configuren la planta de manera que pueda comenzar a operar.
3. **Estado de operación.** Una vez producido el arranque, el sistema entra en el modo operación y comienza a buscar el objetivo marcado por el ordenador central. La unidad de control dispone de dos lazos de regulación y control

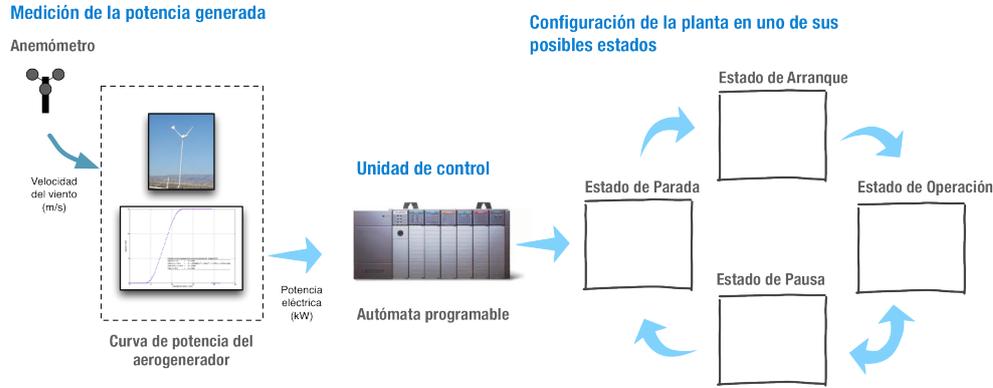


Fig. 3.9: Estados operativos de la planta desalinizadora.

que se encargan de: (a) regular el caudal de alimentación para ajustarlo a la consigna de caudal y (b) regular la presión de alimentación para ajustarla a la consigna de presión. El cálculo de ambas consignas se estudiará con mas detalle en capítulos posteriores.

4. **Estado de pausa.** El sistema de control detecta momentáneamente que las condiciones de operación se han perdido y permanece en espera para decidir si continúa en el estado de operación o, de lo contrario, vuelve al estado de parada.

Si la planta se encuentra en modo de parada, ésta presenta la siguiente configuración: SV-1 cerrada, SV-2 permitiendo el paso de agua producto para permitir el fenómeno de limpieza natural por *flushing*, SV-3 abierta y PSV completamente abierta. Si la potencia eléctrica teóricamente disponible, P_{wt} , es mayor que la potencia necesaria para el funcionamiento de al menos un tubo de presión, $P_{cut-in(PV1)}$, el sistema de control ordena el cambio del modo de parada al modo de arranque. Por tanto, el sistema de control procede a la apertura de la válvula SV-1, cambia de posición la válvula SV-2 (permitir el paso de agua de mar), cierra la válvula SV-3 (en el caso de que $P_{wt} < P_{cut-in(PV1yPV2)}$) y conecta el interruptor que alimenta con corriente eléctrica trifásica al variador de frecuencia (Fig. 3.10). Seguidamente, el sistema procede a generar las consignas de presión, p_{ref} , y caudal, Q_{ref} , necesarias para adaptar la potencia consumida a la potencia generada.

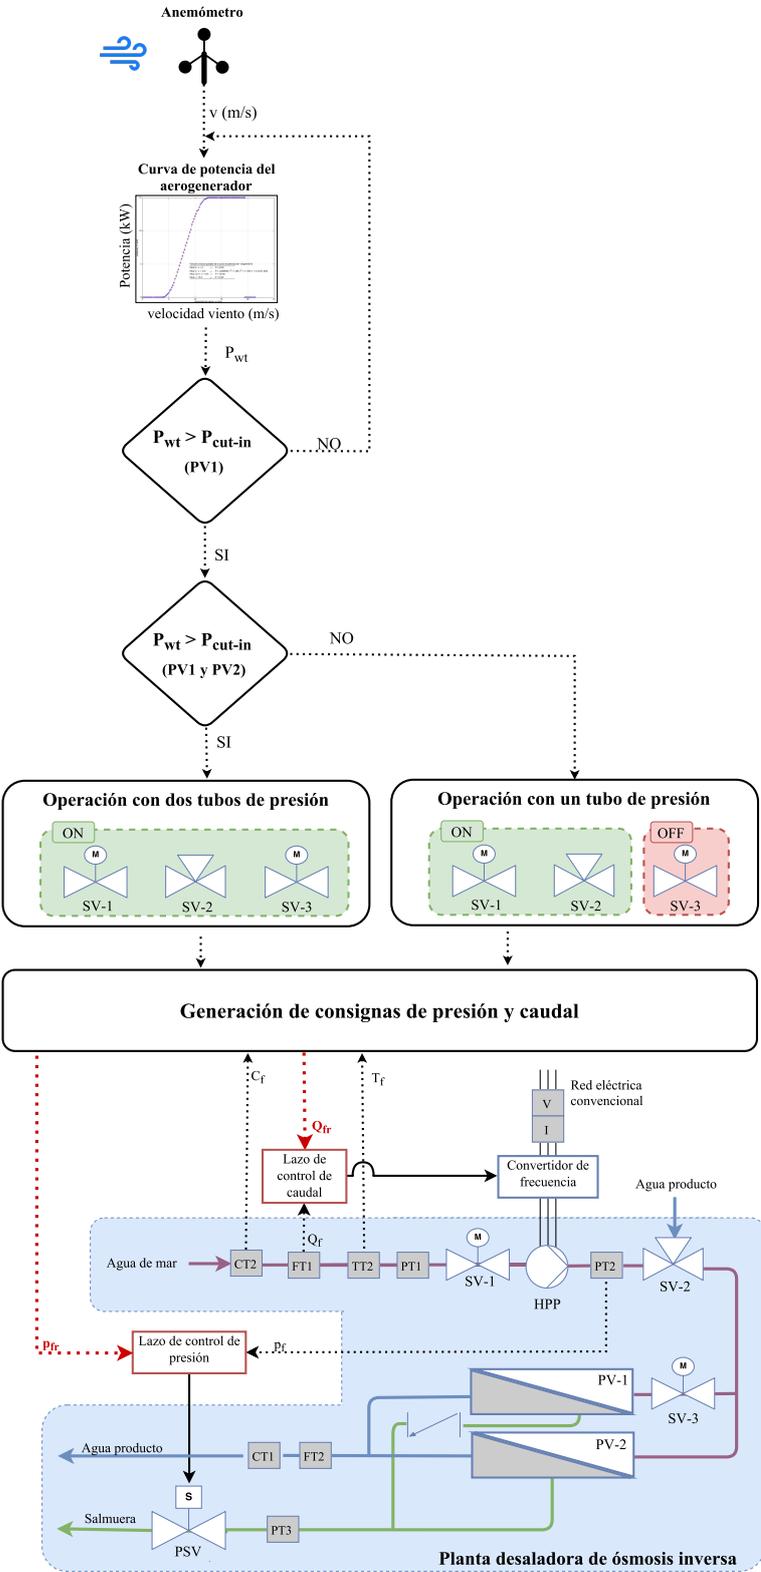


Fig. 3.10: Diagrama de flujo de la toma de decisiones del sistema de control empleado.

Posteriormente, cada uno de los dos lazos de control implementados en el autómata programable, mediante dos subrutinas independientes destinadas a ello, regulan su actuador correspondiente. Por un lado una subrutina actúa sobre el variador de velocidad para regular la velocidad de la bomba de alta presión de desplazamiento positivo y ajustar así el caudal de alimentación de la planta. Y, por otro lado, la otra subrutina actúa sobre la servoválvula PSV para controlar la presión de alimentación de la planta de ósmosis inversa. Ambas contienen un lazo de control realimentado. El lazo de control que regula el caudal acciona el variador de velocidad en función del caudal de consigna, Q_{ref} , y del caudal medido, Q_f , por el sensor FT-1. Y el lazo de control realimentado que regula la presión de alimentación de la planta, mediante un controlador proporcional-integral-derivativo (PID). Además, la subrutina correspondiente al lazo de presión adapta los parámetros del PID a los distintos niveles operativos para lograr una regulación de presión suave y robusta. Todo este proceso queda reflejado esquemáticamente en el diagrama de flujo mostrado en la Fig. 3.10. En él se representan, de forma simplificada, las decisiones que toma el sistema de control a la hora de variar la energía consumida por la planta desalinizadora de OI.

El sistema de control, además de los sensores utilizados para el control principal del sistema, también recibe información desde otros sensores, que puede utilizarse para generar señales de alarma. Entre estos sensores se encuentra el sensor TT-1, que mide la temperatura de operación del motor eléctrico que acciona la bomba de alta presión; el sensor PT-1, que mide la presión de entrada de agua de mar a la bomba de alta presión; los sensores que miden el caudal producto, FT-2, y su conductividad, CT-1; el sensor PT-3 que mide la presión del agua de rechazo del sistema de membranas; los sensores que miden las corrientes y voltajes a la entrada del variador de frecuencias y permiten determinar la potencia consumida por el sistema en cada momento, además de evaluar el factor de potencia y el rendimiento de la carga.

Estudios preliminares que permiten la implementación de estrategias de gestión inteligente en el prototipo de planta desalinizadora desarrollado

4.1 Introducción

En este capítulo describen todos los estudios preliminares llevados a cabo para poder aplicar, posteriormente, las estrategias de regulación adecuadas que permitan la adaptación de la potencia consumida por la planta a una potencia de origen eólico cambiante.

En primer lugar se determinan los límites operativos del prototipo experimental para, a partir de ellos, elaborar una estrategia de operación que respete en todo momento las restricciones impuestas por el fabricante de las membranas de la planta desalinizadora. A continuación, se analizan las distintas estrategias de operación

candidatas a utilizarse en un sistema de este tipo, con vistas a que el sistema opere en régimen variable y aproveche al máximo el recurso eólico disponible. Finalmente, se hace un estudio pormenorizado del régimen de vientos existente en el lugar de la instalación, con el fin de prever las variaciones eólicas más frecuentes y obtener una función de distribución adaptada al sitio.

4.2 Determinación de los límites teóricos admisibles de operación del prototipo de planta de ósmosis inversa

Con el objetivo de estimar los límites de variación de la presión y caudal de alimentación de la planta desalinizadora de OI en función del número de tubos de presión que operan, se recurrió a la determinación teórica del área de valores admisibles de dichos parámetros haciendo uso del software (*Toray Design System v.2.0*) [136] facilitado por el fabricante de las membranas. En este contexto, hay que tener en cuenta que, dado que los paquetes de software que algunos fabricantes han desarrollado y puesto a disposición pública para ayudar a diseñar sistemas de OI utilizando sus membranas específicas están basados en el funcionamiento nominal y estabilizado de la membrana seleccionada bajo condiciones de diseño, el comportamiento real puede variar [36, 137]. Los datos del agua de alimentación utilizada en la simulación se obtuvieron de los análisis realizados a diversas muestras históricas de agua de mar tomadas en la sala de bombeo, Fig. 3.1. Dichos análisis revelaron una media de sólidos totales disueltos de 37332 mg/l (valores extremos: 35200 mg/l y 39800 mg/l), con conductividad media, a 25°C, de 51480 $\mu\text{S}/\text{cm}$ (valores extremos: 47800 $\mu\text{S}/\text{cm}$ y 53900 $\mu\text{S}/\text{cm}$), pH medio de 7.29 (valores extremos: 7.2 y 7.5), turbidez menor de 1 NTU (Unidad Nefelométrica de turbidez), sólidos suspendidos (inferiores a 2 mg/l y carbón orgánico total (TOC) inferior a 1 mg/l.

En la Fig. 4.1 se muestra el área de operación de un tubo y dos tubos de presión en un sistema de ejes cartesianos cuando la temperatura del agua de mar a la entrada de las membranas es de 25°C¹. Para elaborar la Fig. 4.1 se han establecido los

¹Esta es la temperatura a la que los fabricantes de membranas calculan la productividad normalizada de las mismas.

siguientes datos de entrada relativos a los elementos de OI: edad de los elementos (3 años), factor de ensuciamiento (0.85), aumento del paso de sales por año (7 %). En dicha figura el eje X representa la presión de alimentación y el eje Y el caudal de alimentación. Las fronteras de operación estuvieron condicionadas por el máximo caudal de alimentación (3 y 6 m³/h), mínimo valor de la tasa de recuperación de permeado (5 %), máxima concentración de sales en el agua producto (500 mg/l), mínimo caudal de rechazo (0.7 m³/h), mínima relación de rechazo a permeado (7.0) y máximo flujo medio (20 l/m²/h). Suponiendo constante la temperatura y la concentración del agua de mar de alimentación, dependiendo del punto concreto dentro de las zonas delimitadas de la Fig. 4.1 en que opere la planta, existirá una determinada tasa de recuperación de permeado y el permeado tendrá una cierta concentración.

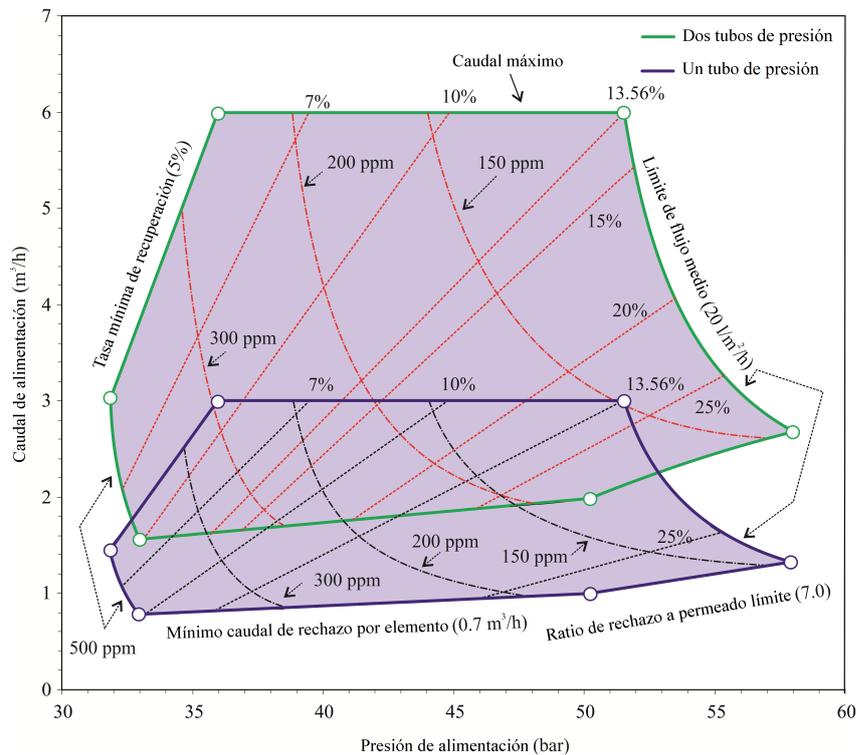


Fig. 4.1: Área teórica de operación de un tubo y dos tubos de presión de la planta desalinizadora cuando los TDS y la temperatura del agua de mar a la entrada de las membranas son 37332 mg/l y 25°C, respectivamente.

Como puede observarse en la Fig. 4.1 es posible trabajar siguiendo líneas de iso-recuperación o iso-concentración del agua producto, si se mantiene una cierta relación entre el caudal y la presión de alimentación. Concretamente, en el caso de iso-recuperación la relación entre presión y caudal de alimentación puede ser representada por una línea recta, Ec.(4.1). Donde k_1 y k_2 representan la pendiente y la ordenada en el origen que, para las condiciones fijadas en el sistema de membranas utilizado, dependen fundamentalmente de la tasa de recuperación de permeado, de la concentración del agua de alimentación y de la temperatura del agua de alimentación.

$$Q_f = k_1 p_f + k_2 \quad (4.1)$$

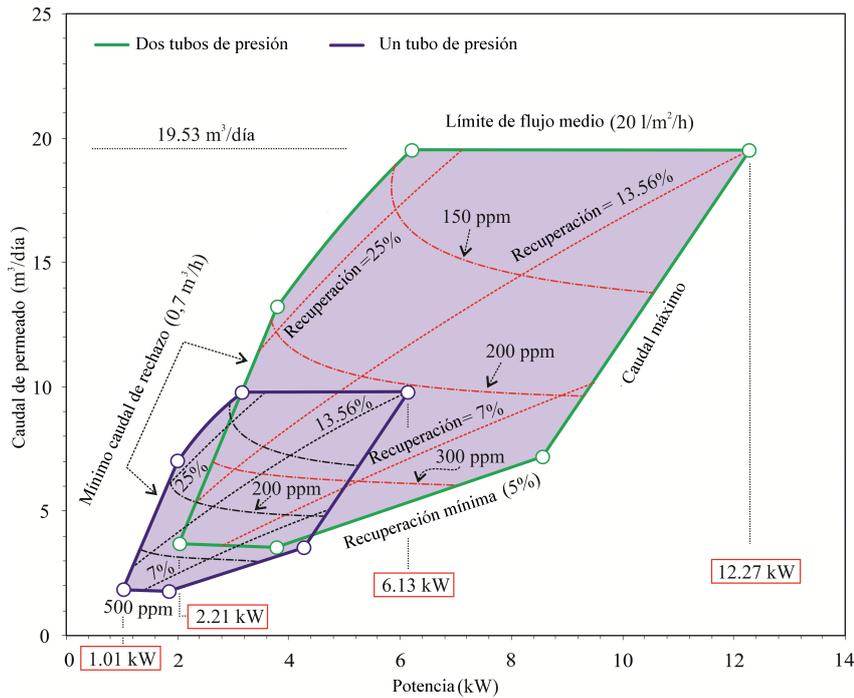


Fig. 4.2: Área teórica de operación de la planta de OI representada en un sistema de ejes cartesianos, donde se observan la potencia demandada por la planta de OI y el caudal de agua producida (Concentración de agua de mar=37332 mg/l; Temperatura=25°C; Rendimiento del sistema=70 %)

En la Fig. 4.2 se muestra la zona teórica de operación de la planta de OI en un sistema de ejes cartesianos, donde el eje X representa la potencia demandada

por la planta de OI y el eje Y el caudal producto. Aunque el rendimiento del sistema dependerá del punto particular de operación, para construir dicha figura se ha supuesto un rendimiento medio del sistema basado en las pérdidas originadas por el variador de frecuencia, el motor eléctrico y la bomba de alta presión de 70 % y una temperatura y concentración del agua de mar de alimentación de 25°C y 37332 mg/l TDS, respectivamente. Como ocurría en la Fig. 4.1, dependiendo del punto concreto dentro de las zonas delimitadas de la Fig. 4.2 en que opere la planta existirá una determinada tasa de recuperación y el permeado tendrá una determinada conductividad. Puede observarse en la Fig. 4.2 que es posible trabajar siguiendo líneas de iso-recuperación. Ello puede conseguirse si se mantiene una cierta relación entre la presión y el caudal de alimentación de la planta de OI, de los cuales depende la potencia demandada por la misma.

4.3 Estrategias de operación para lograr la producción de agua en régimen variable

La potencia eléctrica variable ofertada por el sistema de generación eólico, P_{wt} , (Fig. 3.10) ha de ser equilibrada, en la medida de lo posible, por la potencia consumida por la planta desalinizadora, P_{RO} . Dado que la potencia consumida por esta última es función de la presión, p_f , y del caudal de alimentación, Q_f , se ha de cumplir la Ec.(4.2). Donde η , en este trabajo, es el rendimiento del sistema convertidor de frecuencia-motor eléctrico-bomba de alta presión.

$$P_{wt} = P_{RO} = \frac{p_f Q_f}{\eta} \quad (4.2)$$

El conjunto de valores de p_f y Q_f que pueden satisfacer la Ec.(4.2) sin violar las restricciones impuestas por las áreas de operación definidas en la Fig. 4.1 es múltiple. Sin embargo, los caudales producto (y sus concentraciones), los caudales de rechazo, los consumos energéticos específicos, los márgenes de variación de la potencia demandada, etc., difieren en función de los valores de dichos parámetros de operación. Las estrategias que pueden utilizarse a la hora de seleccionar los valores que han de tomar p_f y Q_f que satisfagan la Ec.(4.2) pueden ser diversas.

Cómo se ha señalado en apartados anteriores, Pohl et al. [6] han propuesto y analizado teóricamente cuatro tipos de estrategias a las que se podría añadir alguna más, como por ejemplo, la de variar el caudal y presión de alimentación con el objetivo de mantener constante una concentración dada del agua producto. Las estrategias propuestas por Pohl et al. [6] son:

- a) Presión de alimentación (p_f) constante y caudal de alimentación (Q_f) variable. Por tanto, en esta estrategia varía la conversión (Y), el caudal y la calidad del agua producto (Q_p y C_p , respectivamente).
- b) Caudal de alimentación (Q_f) constante y presión (p_f) variable. Con esta estrategia también se origina la variabilidad de la conversión (Y), el caudal y la calidad del agua producto (Q_p y C_p , respectivamente).
- c) Variación de la presión (p_f) y caudal (Q_f) de tal manera que la conversión (Y) permanezca constante. El parámetro variable de salida es la calidad del agua producto (C_p) y su caudal (Q_p).
- d) Variación de la presión y del caudal de alimentación de tal manera que se mantiene constante el caudal de rechazo (Q_r). Los parámetros variables de salida son la conversión, el caudal de agua producto y su calidad (Y , Q_p y C_p , respectivamente).

Los ensayos realizados en el prototipo de planta de OI diseñado que se analizan en esta tesis doctoral se centran en la estrategia de variar la presión y caudal de alimentación con el propósito de mantener la tasa de recuperación de permeado aproximadamente constante.

La elección realizada se ha sustentado en dos consideraciones. Por un lado, desde el punto de vista teórico, dicha estrategia se ha revelado como la mejor para operar un sistema de ósmosis inversa cubriendo un amplio rango de variación de la potencia eléctrica que debe accionarla [6]. Según los análisis teóricos realizados, con la tasa de recuperación obtenida en la intercepción de la línea de flujo límite medio con la línea de máximo caudal de agua de mar de alimentación se consigue el mayor rango de variación de potencia, Fig. 4.2. Concretamente, en

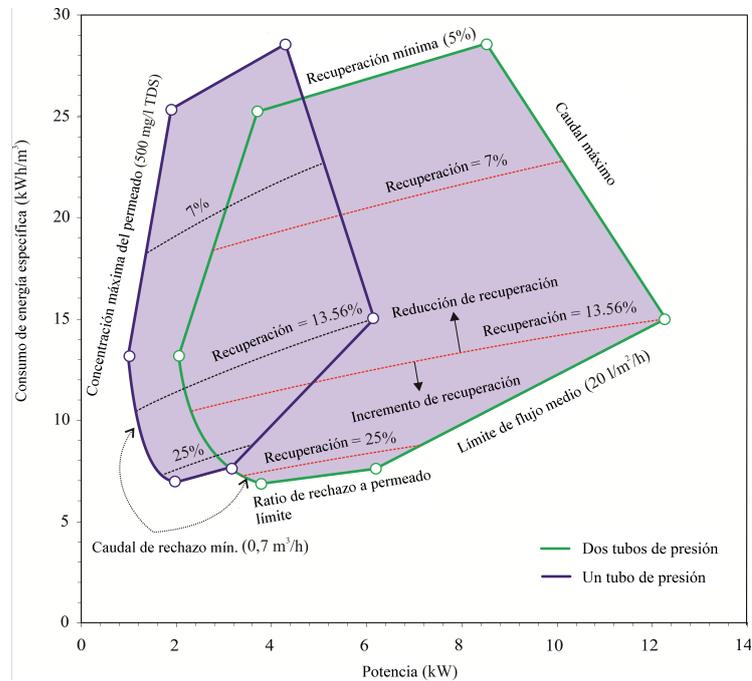


Fig. 4.3: Área teórica de operación de la planta de OI representada en un sistema de ejes cartesianos, donde se observan la potencia demandada por la planta de OI y el consumo específico de energía (Concentración de agua de mar=37332 mg/l; Temperatura=25°C; Rendimiento del sistema=70 %)

el sistema analizado en esta tesis, dicha tasa de recuperación de permeado es de aproximadamente 13.56 %. Asimismo, puede observarse en la Fig. 4.3 que tasas de recuperación de permeado mayores de 13.56 % permiten disminuir el consumo específico de energía de la planta de desalación. Sin embargo, dichas tasas reducen los márgenes de potencia generada por la turbina eólica que puede consumir la planta de desalación.

Por otro lado, desde el punto de vista práctico, se ensayaron también las estrategias a) y b) citadas anteriormente para verificar que los resultados experimentales se corresponden con los teóricos. En dichos experimentos se comprueba que el aprovechamiento del recurso eólico es mayor empleando la estrategia elegida. La estrategia d), basada en variar caudal y presión de alimentación manteniendo el caudal de rechazo constante, no se llevó a la práctica dado que el prototipo empleado no dispone de recuperador de energía y, por ello, no resulta necesaria dicha

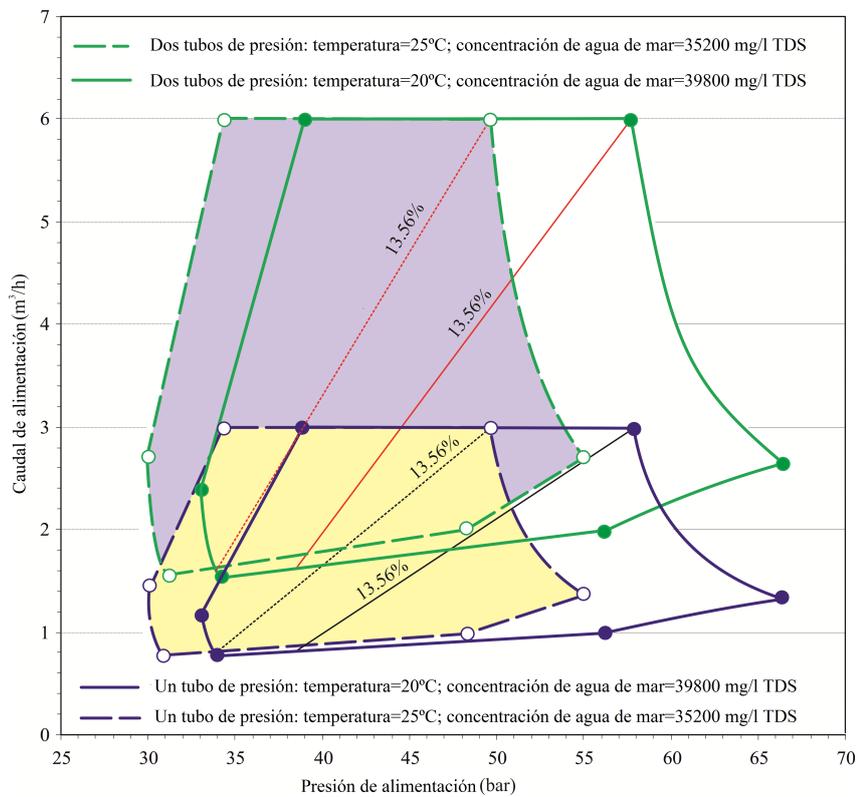


Fig. 4.4: Límites teóricos de presión y caudal de alimentación admisibles de la planta desalinizadora en función de las combinaciones más extremas de los intervalos de temperaturas y concentraciones (20°C-39800 mg/l y 25°C-35200 mg/l).

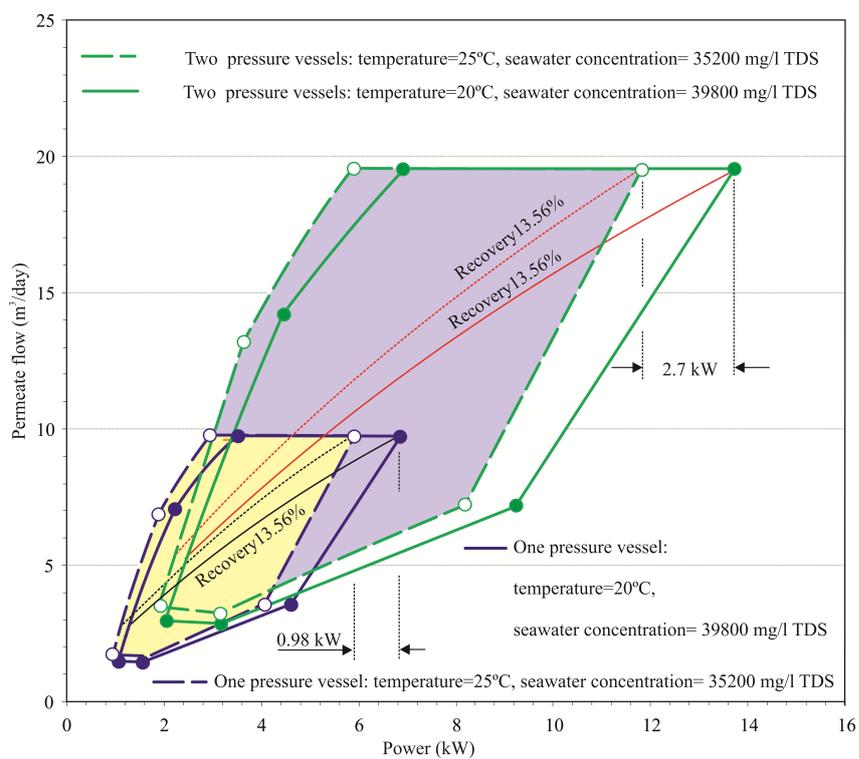


Fig. 4.5: Límites teóricos de la potencia de accionamiento admisible por planta desalinizadora en función de las combinaciones más desfavorables de los intervalos de temperaturas y concentraciones (20°C-39800 mg/l y 25°C-35200 mg/l), estimado un rendimiento del 70 %.

regulación.

Llegado a este punto, hay que señalar que aunque no ha sido considerado en trabajos previos [2, 3, 5, 6], los márgenes de operación representados en las figuras 4.1 a 4.3 y las características del agua producto son también dependientes de la concentración del agua de alimentación y de su temperatura. Los análisis realizados en este trabajo indican que los márgenes históricos de variación estacional de la composición iónica del agua de mar, como se ha indicado anteriormente, dan lugar a concentraciones de agua de mar que se encuentran entre 35200 mg/l y 39800 mg/l. Las medidas de temperatura históricas realizadas a la entrada del agua de mar en la planta indican que los márgenes extremos de esta se encuentran entre 19°C y 24°C, con una moda de 23°C. Probablemente, este estrecho rango de variación de la temperatura del agua de mar se justifique por la situación geográfica y por la toma subterránea (más específicamente pozo vertical de playa) de la misma.

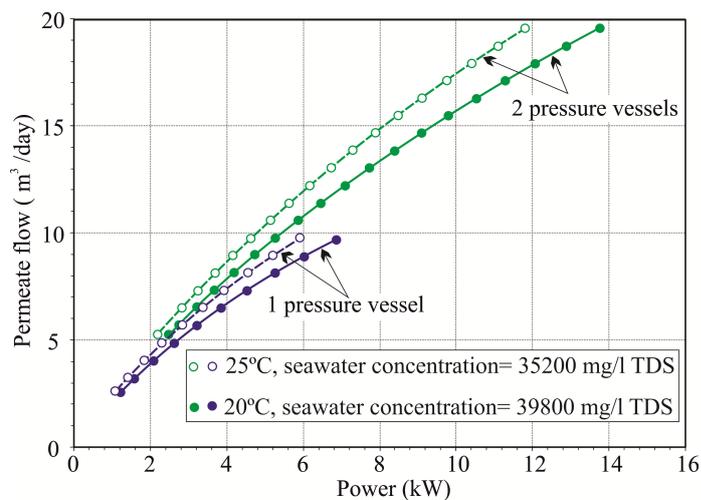


Fig. 4.6: Caudal producto teórico producido por la planta desalinizadora en función de las combinaciones más desfavorables de los intervalos de temperaturas y concentraciones (20°C-39800 mg/l y 25°C-35200 mg/l), considerando un rendimiento del 70 %.

Asimismo, las medidas realizadas en la planta objeto de este trabajo han permitido determinar que el paso del agua de mar a través de la bomba de alta presión eleva la temperatura de la misma aproximadamente 1°C. Por tanto, se estima que el intervalo de temperaturas de operación de las membranas de la planta se encuentra

entre 20°C y 25°C, siendo la temperatura más frecuente de 24°C. El efecto que tienen, en teoría, las combinaciones más extremas de los intervalos de temperaturas y concentraciones (20°C-39800 mg/l y 25°C-35200 mg/l) en los márgenes de operación admisibles de la planta, se muestra en la Fig. 4.4 y en la Fig. 4.5. En las mismas se puede observar que se requieren presiones menores cuando las temperaturas del agua de mar son altas y sus concentraciones bajas para conseguir una misma conversión que cuando las temperaturas son bajas y las concentraciones altas². El sistema de control deberá ajustar la presión para mantener la conversión constante al variar la temperatura y la concentración del agua de mar. Ello debe ser considerado especialmente cuando las presiones y caudales de trabajo puedan causar que se supere el máximo flujo medio (20 l/m²/h).

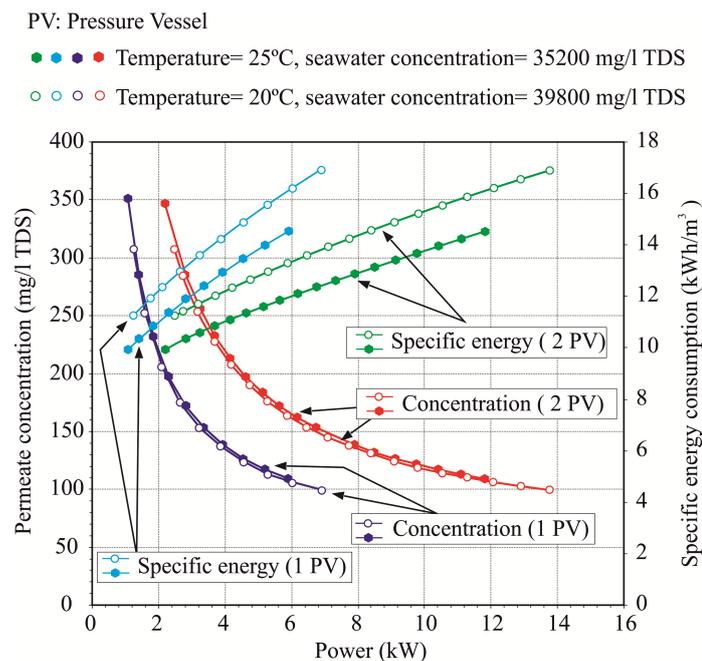


Fig. 4.7: Concentración del agua producto y consumo específico de energía teóricos de la planta desalinizadora en función de las combinaciones más desfavorables de los intervalos de temperaturas y concentraciones (20°C-39800 mg/l y 25°C-35200 mg/l), considerando un rendimiento del 70 %.

²Para más información sobre como la temperatura y la concentración del agua de mar de alimentación afecta al rendimiento de una planta desalinizadora de ósmosis inversa pueden consultarse varias referencias [36, 37, 137]

De acuerdo con dichos análisis teóricos, cuando el sistema opera con una tasa de recuperación constante de 13.56 % y temperaturas y concentraciones comprendidas entre 20°C y 25°C y 39800 mg/l y 35200 mg/l, respectivamente, el caudal de agua producto varía en función de la potencia consumida según se refleja en la Fig. 4.6. Asimismo, las concentraciones del agua producida y los consumos energéticos específicos varían en función de la potencia consumida según se muestra en la Fig. 4.7. Con respecto a las concentraciones teóricas estimadas en la Fig. 4.7, hay que señalar que estas no representan las situaciones extremas. Para una presión, caudal y temperatura dados del agua de mar de alimentación, cuanto mayor sea la concentración de ésta, mayor será la concentración del agua producto (menor calidad del agua producto). Esto es consecuencia de la disminución del caudal producto, ya que es mayor la presión osmótica (que es directamente proporcional a la suma de las concentraciones molares individuales de las sales disueltas [138]).

Asimismo, para una presión, caudal y concentración dados del agua de mar de alimentación, cuanto mayor es la temperatura de ésta, menor es el rechazo de sales (deterioro de la calidad del agua producto). Esto último es debido al aumento de la solubilidad de las sales en la membrana y/o por otra parte, al efecto dilatador que se origina en la estructura de las membranas [36, 137]. Respecto a los consumos específicos para una recuperación del 13.56 % , puede observarse que estos son menores cuanto menores son las concentraciones del agua de alimentación (35200 mg/l TDS) y mayores sean las temperaturas (25°C). Un aumento de la temperatura se traduce en un incremento del caudal producto, debido a la reducción de la viscosidad del agua de alimentación [139], que origina un incremento de la permeabilidad de las membranas de OI. Aunque la presión osmótica se incrementa en proporción directa con la temperatura [138], el impacto global de la temperatura es generalmente beneficioso [137]. Por tanto, un incremento de temperatura requiere que se reduzca la presión de alimentación, si se desea mantener la recuperación constante, lo que implica un menor consumo energético para obtener el mismo caudal de agua producto [140]. También puede observarse en Fig. 4.7 que, si el rendimiento del sistema fuese constante, para una potencia de consumo dada, se obtiene mejor calidad del agua producto con un tubo de presión que con dos. Sin

embargo, los consumos específicos de energía son mayores con un tubo de presión que con dos.

4.4 Análisis de las potencias eléctricas de origen eólico

De acuerdo con el esquema de control diseñado para llevar a cabo los ensayos en la planta desalinizadora diseñada, Fig. 3.10, para simular las potencias eléctricas de origen eólico, P_{wt} , que pueden ser absorbidas por el prototipo actual en cada instante (entre aproximadamente 2 y 11 kW) se precisa hacer uso de la curva de potencia-velocidad del viento de la turbina eólica que se seleccione.

En este trabajo, dado que aún no ha sido posible obtener la curva de potencia de la turbina eólica que ha de sustituir a la actual disponible (Vergnet-GEV10/15), se utilizó la curva de potencia-velocidad del viento de esta última, Fig. 4.8a.

Asimismo, se llevó a cabo un análisis de las velocidades medias de cada minuto de viento registrado en el lugar, a 20 metros sobre el nivel del suelo, durante el año 2010. Del análisis eólico realizado se desprende que el régimen de vientos puede ser representado por una mezcla de distribución normal truncada simple y de distribución de Weibull (*singly truncated normal Weibull mixture distribution*) [141], Ec.(4.3). Dicha función de densidad de probabilidad de la velocidad del viento presenta dos modas (3.26 m/s y 10.53 m/s), Fig. 4.8b.

$$g(v) = \frac{\omega\alpha_1}{\beta_1(v/\beta_1)^{\alpha_1-1}} \exp\left[\left(-\frac{v}{\beta_1}\right)^{\alpha_1}\right] + (1-\omega)\frac{1}{I_0\beta\sqrt{2\pi}} \exp\left[-\frac{(v-\alpha)^2}{2\beta^2}\right] \quad (4.3)$$

Donde I_0 se expresa por la Ec.(4.4)

$$I_0 = \frac{1}{\beta\sqrt{2\pi}} \int_0^\infty \exp\left[-\frac{(v-\alpha)^2}{2\beta^2}\right] dv \quad (4.4)$$

La función de distribución acumulativa viene dada por Ec.(4.5)

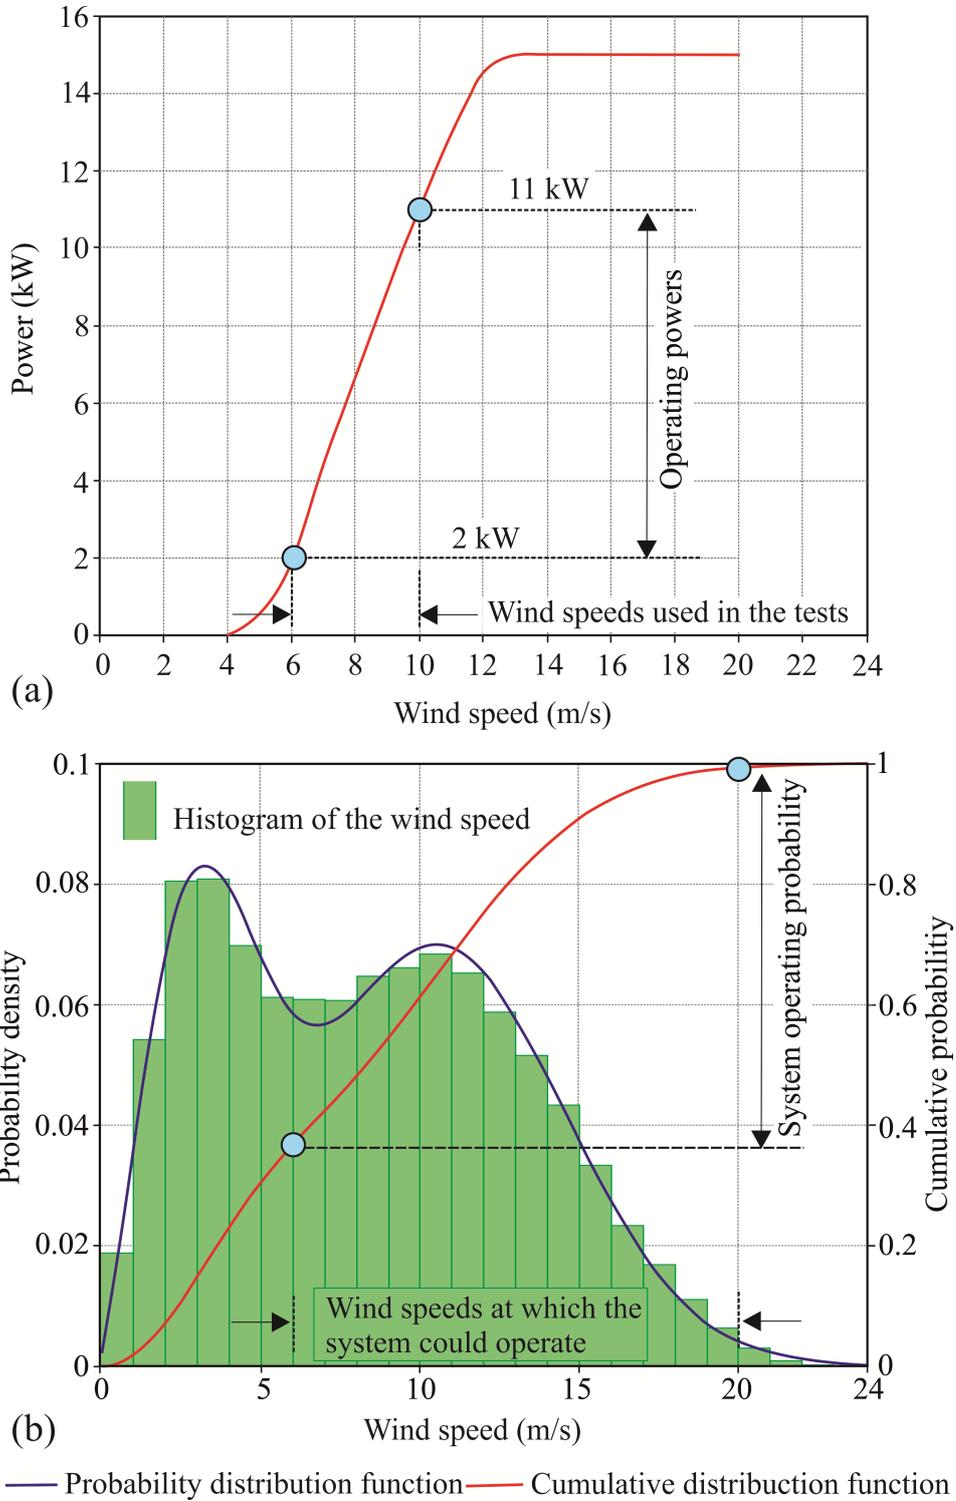


Fig. 4.8: a) Curva de potencia de la turbina eólica Vergnet- GEV10/15 utilizada para la simulación de la generación de potencia eólica. b) Histograma experimental de las velocidades de viento registradas en el lugar y funciones de densidad de probabilidad ajustadas al mismo.

$$G(v, \alpha_1, \beta_1, \alpha, \beta, \omega) = \omega \left[1 - \exp \left[-\frac{v}{\beta_1} \right]^2 \right] + \quad (4.5)$$

$$+ (1 - \omega) \int_0^v \frac{1}{I_0 \beta \sqrt{2\pi}} \exp \left[-\frac{(v - \alpha)^2}{2\beta^2} \right] dv$$

Para la serie de datos analizados, los valores de los distintos parámetros $(\alpha_1, \beta_1, \alpha, \beta, \omega)$ recogidos en Ec.(4.6), Ec.(4.7) y Ec.(4.10), se muestran en la Tabla 4.1. Dichos parámetros fueron estimados haciendo uso del método de máxima verosimilitud. El coeficiente de determinación obtenido ha sido de $R^2=99.98\%$.

Tabla 4.1: Parámetros de la mezcla de distribuciones de Weibull y normal truncada simple.

α	β	α_1	β_1	ω
(m/s)	(m/s)	-	(m/s)	-
10.573	3.955	2.168	3.933	0.691

Con respecto a la variación temporal de la velocidad media del viento calculada para cada minuto se comprueba que, si en el minuto i esta es de v_i , en el minuto $i + 1$ su valor será de $v_i \pm \Delta_i$, con los valores más frecuentes de Δ_i en los intervalos 0.0-0.5 y 0.5-1.0 m/s, Fig. 4.9.

Dadas las frecuencias de ocurrencia, se decidió utilizar las potencias eléctricas de origen eólico, P_{wt} , obtenibles, según la curva de potencia-velocidad del viento mostrada en la Fig. 4.8a, cuando las velocidades del viento varían entre 6 m/s (~ 2.0 kW) y 10 m/s (~ 11.0 kW) con valores de Δ comprendidos en el intervalo 0-0.5 m/s.

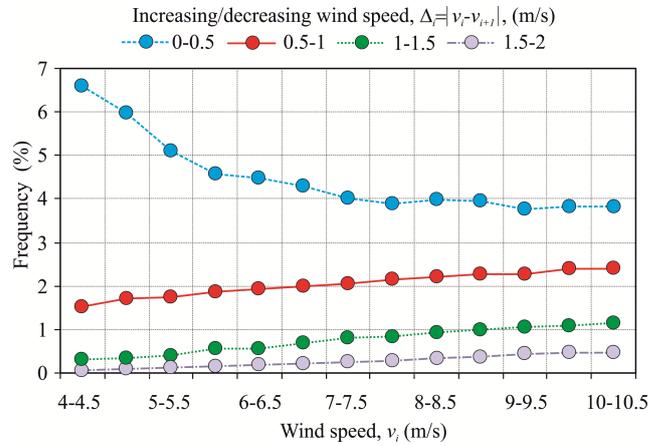


Fig. 4.9: Frecuencias de varios intervalos (0-0.5 m/s a 1.5-2.0 m/s) de las diferencias absolutas $\Delta_i = |v_i - v_{i+1}|$ obtenidas entre los datos consecutivos de la serie de velocidades medias (cada minuto) del viento registradas en el año 2010 en la zona de estudio, en función de varios intervalos (4-4.5 m/s a 10-10.5 m/s) de la velocidad del viento v_i .

4.5 Aplicación de funciones de regresión polinómicas para generar las consignas que permiten gestionar la potencia eléctrica consumida por el prototipo y adaptarla al recurso eólico variable

Las presiones (p_{fr}) y caudales (Q_{fr}) de alimentación que deben ser usados como variables de referencia en el sistema de control con el objeto de que la carga, trabajando con una determinada conversión (en este caso de 13.56%), consuma una potencia P_{RO} dada, dependen de las características particulares de la planta desalinizadora, de su punto de operación y de las características del agua de alimentación.

Se precisa, por tanto, de una función de transferencia que teniendo como entrada la potencia a consumir, P_{RO} , la concentración del agua de mar y su temperatura, tenga como respuesta la presión (p_{fr}) y caudal (Q_{fr}) de alimentación que deben ser usados como variables de referencia. Para ello, en este capítulo se describe el uso inicial de funciones de transferencia empíricas obtenidas mediante el ajuste de funciones no lineales a los datos experimentales registrados.

Más adelante, teniendo en cuenta los antecedentes en el uso de redes neuronales artificiales (ANNs - *Artificial Neural Networks*) para desarrollar modelos basados en datos para describir el rendimiento de los procesos de membrana [14, 17, 18, 142], se ha considerado apropiado utilizar funciones de transferencia basadas en técnicas de aprendizaje automático. Entre las técnicas disponibles, se propone el uso de las ANNs (basadas en algoritmos inspirados en la Biología) [143], las Máquinas de Vectores Soporte (SVMs - *Support Vector Machines*) y los Bosques Aleatorios (RFs - *Random Forests*), que tienen su raíz en la teoría de aprendizaje estadístico (SLT - *Statistical Learning Theory*) y métodos de optimización [144].

4.5.1 Generación de las presiones y caudales de referencia

Utilizando un agua de mar con una concentración de 37170 mg/l y una temperatura media de entrada a la membrana de 23°C, se llevó a cabo la medida, a la entrada del variador de frecuencia, de la potencia activa P_{RO} consumida por la planta desalinizadora al variar los caudales del agua de alimentación y las presiones ejercidas por la bomba de alta presión, siguiendo la consigna de mantener la conversión en el rango comprendido entre 13.5 % y 13.6 %.

A los datos experimentales obtenidos se le ajustaron funciones no lineales con el objeto de obtener tendencias en el comportamiento del sistema que fuesen implementadas como funciones de transferencia en el sistema de control (Fig. 4.10). En la Ec.(4.6) y la Ec.(4.7) se recogen las curvas de presión de referencia p_{fr} y caudal de referencia Q_{fr} , para el caso de un solo tubo de presión. En Ec.(4.8) y Ec.(4.9) se muestran las curvas correspondientes para dos tubos de presión. En la Tabla 4.2 se muestran los parámetros de las mencionadas curvas y el correspondiente coeficiente de determinación, R^2 .

$$p_{fr} = \sqrt{a + b [\ln (P_{RO})^2]} \quad (4.6)$$

$$Q_{fr} = \frac{\sqrt{P_{RO}^3}}{b + a\sqrt{P_{RO}^3}} \quad (4.7)$$

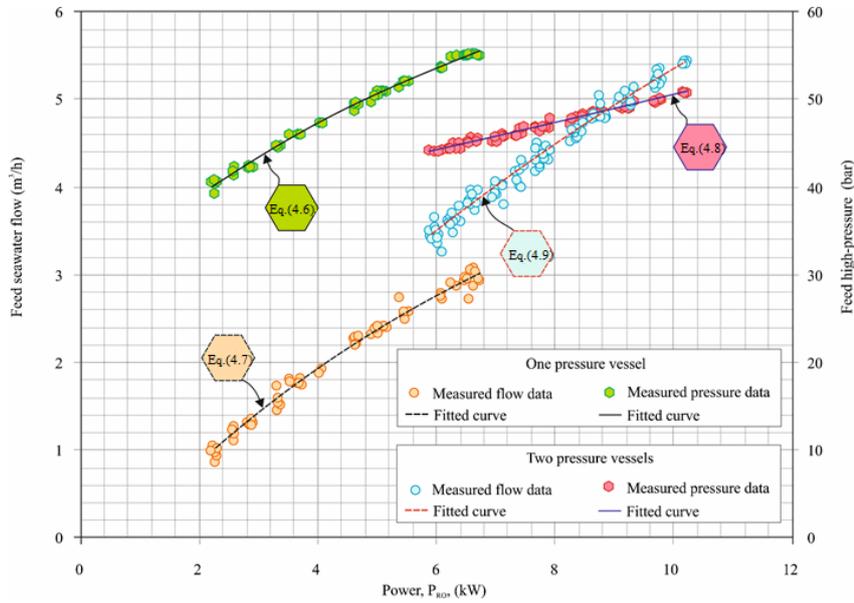


Fig. 4.10: Representación de las funciones de transferencia experimentales de la planta desalinizadora, que relacionan la potencia consumida con las presiones y caudales de alimentación para una tasa de recuperación comprendida en el intervalo 13.5 % y 13.6 % y una concentración y temperatura del agua de alimentación a la entrada a las membranas de 37170 mg/l TDS y 23°C, respectivamente.

Tabla 4.2: Parámetros de las curvas de tendencia.

Ec.	a	b	R^2	Número de datos
4.6	1304.953007	486.6473711	0.9968617	97
4.7	0.175395872	2.737677435	0.9937340	97
4.8	5.111632419	0.460492195	0.9923884	174
4.9	-2.803570000	2.576787368	0.9879077	174
4.10	5675.001	-20090.10600	0.9129780	97
4.11	67.17483989	1.507001117	0.39305017	174
4.12	0.571117084	-1.53986196	0.77899471	97
4.13	0.893915675	-2.38296586	0.78977987	174

$$p_{fr} = \left[a + b \frac{P_{RO}}{\ln(P_{RO})} \right]^2 \quad (4.8)$$

$$Q_{fr} = a + b\sqrt{P_{RO}} \quad (4.9)$$

En los estudios teóricos realizados se ha supuesto un rendimiento constante del sistema del 70 %, independientemente de los parámetros de operación. Por tanto, en los ensayos realizados se ha tratado de ajustar el funcionamiento de la planta a una recuperación aproximadamente constante (13.5 %-13.6 %), pero teniendo en cuenta el rendimiento del sistema en función de la potencia consumida por el mismo, P_{RO} , Fig. 4.11. Puede observarse en Fig. 4.11 que el rendimiento disminuye notablemente cuando el sistema opera con un solo tubo de presión a bajos caudales, por lo que la potencia consumida se eleva significativamente respecto a la estimada teóricamente. Asimismo, cuando el sistema opera con dos tubos a altos caudales el rendimiento es superior al estimado teóricamente. Por tanto, las potencias reales máximas consumidas resultan inferiores a las estimadas. En la Ec.(4.10) y Ec.(4.11) se muestran las curvas de tendencia de los rendimientos asociados a la operación de uno y dos tubos de presión, respectivamente. En la Tabla 4.2 se muestran los parámetros correspondientes a dichas curvas de ajuste.

$$\eta = \sqrt{a + b \frac{\ln(P_{RO})}{P_{RO}^2}} \quad (4.10)$$

$$\eta = a + b [\ln(P_{RO})]^2 \quad (4.11)$$

Para inyectar el caudal mínimo de operación (1 m³/h) en un tubo de presión, la bomba de alta presión ha de girar a 75 rpm. Dada la relación de velocidades establecida (aproximadamente 1.92) entre la bomba de alta presión y el motor eléctrico que la acciona, este último ha de girar a muy baja velocidad (aproximadamente 144 rpm) para lograr dicho caudal de alimentación. Sin embargo, para suministrar el caudal máximo de operación (6 m³/h), la bomba de alta presión debe girar a 450 rpm y el motor que la conduce a aproximadamente 864 rpm (inferior al régimen

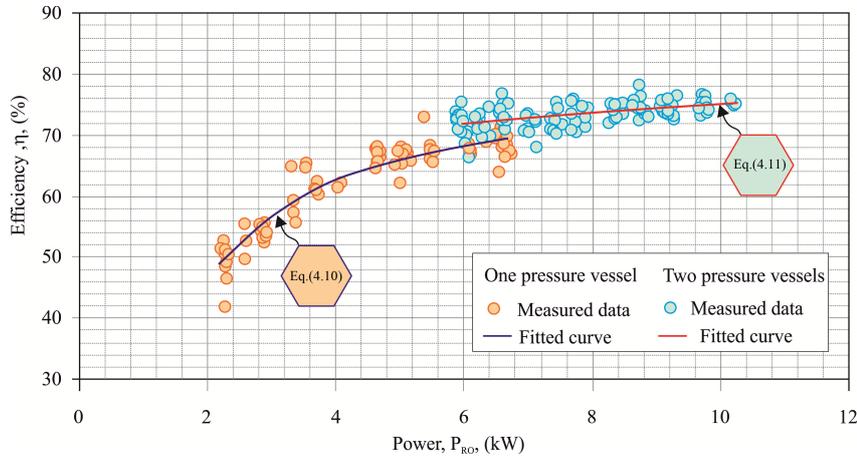


Fig. 4.11: Representación del rendimiento experimental del sistema en función de la potencia consumida, para una tasa de recuperación comprendida en el intervalo 13.5 % y 13.6 % y una concentración y temperatura del agua de alimentación a la entrada a las membranas de 37170 mg/l TDS y 23°C, respectivamente.

nominal del mismo que es de 1465 rpm). Debido a ello, en los estudios experimentales realizados se ha observado, Fig. 4.12, una acusada variación del factor de potencia en función de la potencia activa consumida por la carga a distintas frecuencias de operación. Puede observarse en Fig. 4.12 que el factor de potencia disminuye a valores próximos a 0.5 cuando el sistema opera con un solo tubo de presión y a bajos caudales. El factor de potencia, cuando la planta trabaja con los dos tubos con caudales de 6 m³/h, es del orden de 0.77.

En la Ec.(4.12) y Ec.(4.13) se muestran las curvas de tendencia de los factores de potencia relacionados con la operación de uno y dos tubos de presión, respectivamente. En la Tabla 4.2 se recogen los parámetros a y b correspondientes a dichas curvas de ajuste.

$$PF = \sqrt{a + b \frac{\ln(P_{RO})}{P_{RO}^2}} \quad (4.12)$$

$$PF = \left[a + \frac{b}{P_{RO}^2} \right]^2 \quad (4.13)$$

4.5 Aplicación de funciones de regresión polinómicas para generar las consignas que permiten gestionar la potencia eléctrica consumida por el prototipo y adaptarla al recurso eólico variable

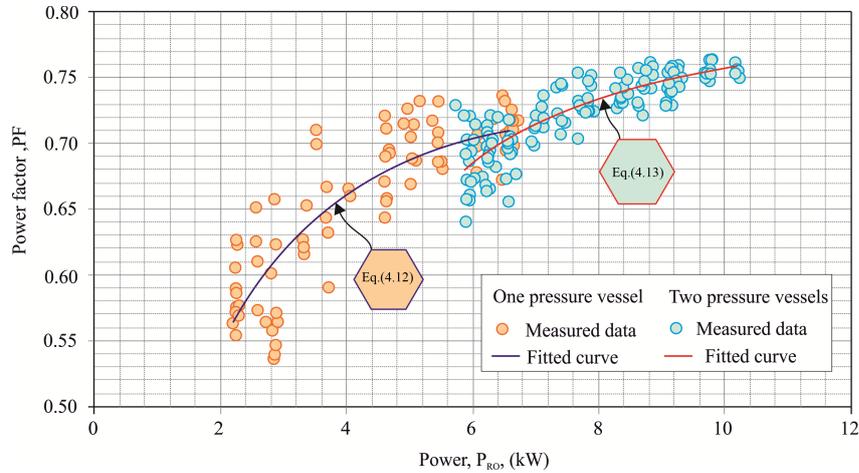


Fig. 4.12: Representación del factor de potencia experimental del sistema en función de la potencia consumida, para una tasa de recuperación comprendida en el intervalo 13.5 % y 13.6 % y una concentración y temperatura del agua de alimentación a la entrada a las membranas de 37170 mg/l TDS y 23°C, respectivamente.

4.5.2 Ensayos experimentales de operación variable de la planta desalinizadora incorporando modelos de regresión no lineales en el sistema de control

Para llevar cabo este primer análisis del comportamiento de la planta desalinizadora en el proceso de adaptación de la potencia consumida P_{RO} a la potencia generada por la turbina eólica P_{wt} se ha supuesto que la velocidad del viento permanece constante durante intervalos de tiempo Δt de 120 s. Dicho margen de tiempo es el mínimo que, de acuerdo con los ensayos realizados, precisa el sistema de control para conseguir una cierta amortiguación de las oscilaciones de los parámetros de operación (p_f , Q_f) y aproximarse a los valores fijados como referencia u objetivo. En la Fig. 4.15 se muestra la variación de la velocidad del viento de forma escalonada, con un tramo ascendente con incrementos de 0.5 m/s y un tramo descendente análogo. Dicho margen de velocidades cubre todo el rango de potencias generadas por la turbina eólica que pueden ser consumidas por la planta desalinizadora (2-11 kW, Fig. 4.8-a) en el ensayo realizado, permitiendo observar el funcionamiento de uno y dos tubos de presión. En el caso analizado, de acuerdo con la Fig. 4.8, la planta operará con mayor frecuencia empleando dos tubos de presión a máxima

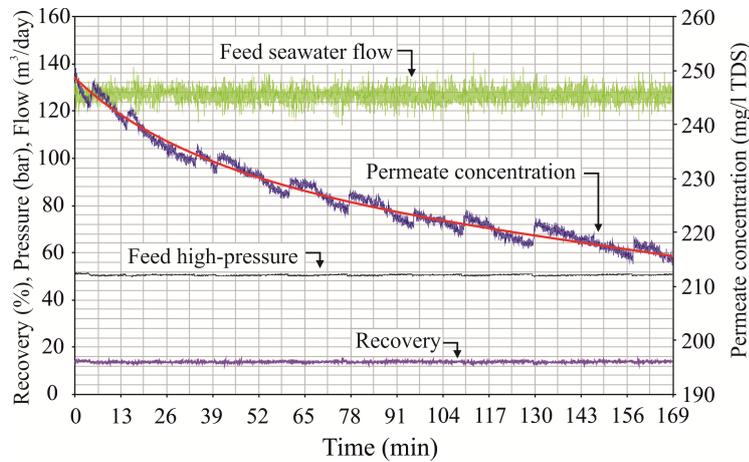


Fig. 4.13: Evolución de la concentración del flujo de permeado según se incrementa el intervalo de tiempo en que la planta de OI opera con dos tubos de presión en condiciones de potencia generada (con presión y caudal de referencia de 50.5 bar y 5.3 m^3/h , respectivamente) y condiciones del agua de alimentación ($23^\circ C$, 37160 mg/l) constantes.

demanda de potencia. Asimismo, se puede observar en Fig. 4.15-a las potencias objetivo y las oscilaciones de la potencia consumida por la planta desalinizadora. En la Fig. 4.15-b se muestran las oscilaciones de las presiones de operación de la planta respecto a las presiones de referencia y en la Fig. 4.15-c las oscilaciones de los caudales de alimentación respecto de los de referencia.

En la Fig. 4.16-a se muestran los caudales producidos y los caudales de rechazo generados por la planta desalinizadora en función de los parámetros de caudal de alimentación y presión aplicados en cada momento. En Fig. 4.16-b se muestra el índice de recuperación y en la Fig. 4.16-c la concentración del agua producto. En la Fig. 4.13 se muestra la variación de determinados parámetros de la planta de OI según se incrementa el intervalo de tiempo en que esta opera con dos tubos de presión en condiciones de potencia generada (con presión y caudal de referencia de 50.5 bar y 5.3 m^3/h , respectivamente) y condiciones del agua de alimentación ($23^\circ C$, 37160 mg/l) constantes.

Con objeto de estimar los potenciales requerimientos de ventilación forzada por parte del motor de accionamiento de la bomba de alta presión, dada su operación en

4.5 Aplicación de funciones de regresión polinómicas para generar las consignas que permiten gestionar la potencia eléctrica consumida por el prototipo y adaptarla al recurso eólico variable

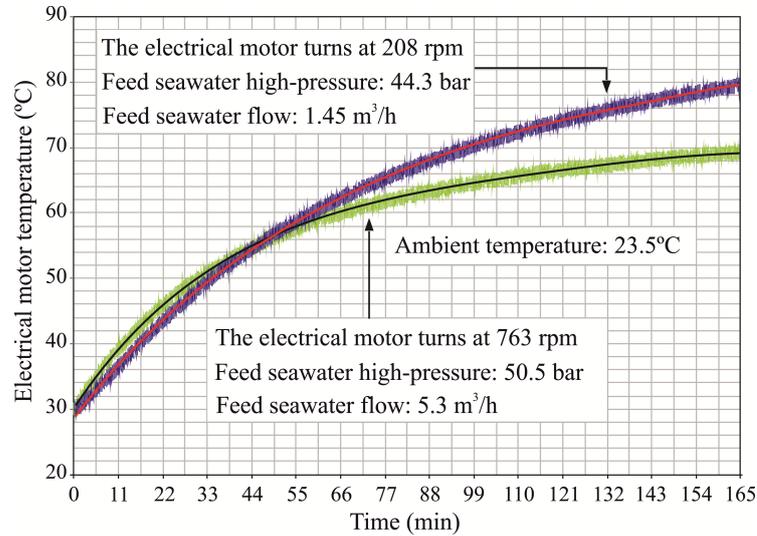


Fig. 4.14: Evolución en el tiempo de la temperatura del motor eléctrico, cuando éste trabaja a baja velocidad de rotación con un solo tubo de presión conectado, y cuando funciona a más alta velocidad de rotación, con la planta de OI operando con los dos tubos de presión conectados.

puntos alejados del nominal de diseño, se han analizado las variaciones de temperatura del mismo en dos situaciones extremas (Fig. 4.14). Una de ellas corresponde a su funcionamiento a una velocidad de giro de aproximadamente 208 rpm, correspondiente a la operación de un solo tubo de presión con caudal de alimentación de 1.45 m³/h y una presión de 44.3 bar. La otra situación analizada corresponde al funcionamiento de la planta de OI con los dos tubos de presión conectados y operando con un caudal de alimentación de 5.3 m³/h, una presión de 50.5 bar y el motor eléctrico girando a aproximadamente 763 rpm.

4.5.3 Análisis de resultados obtenidos de los ensayos experimentales realizados

De los ensayos realizados hasta el momento se desprende que es factible amoldar el consumo del prototipo de la planta de OI a una amplia variación de la potencia producida para la turbina eólica, que ha sido simulada, Fig. 4.15-a. Sin embargo, dada la sensibilidad del sistema de desalación a las oscilaciones de los parámetros

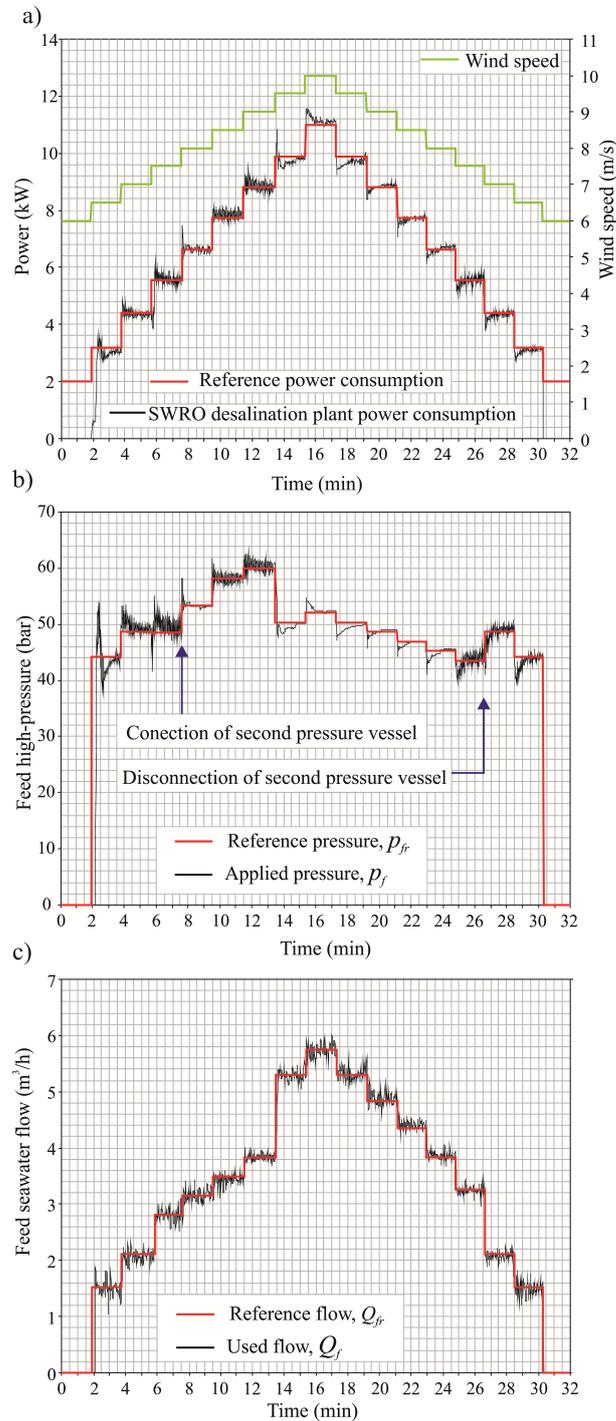


Fig. 4.15: a) Potencias objetivo y oscilaciones medidas de la potencia consumida por la planta desalinizadora en función del tiempo de operación. b) Presiones de referencia y oscilaciones respecto de las mismas de las presiones de operación medidas en la planta desaladaora en función del tiempo de operación. c) Caudales de agua de mar alimentación de referencia y oscilaciones respecto de los mismos de los caudales reales de operación medidos en la planta de OI en función del tiempo de operación.

4.5 Aplicación de funciones de regresión polinómicas para generar las consignas que permiten gestionar la potencia eléctrica consumida por el prototipo y adaptarla al recurso eólico variable

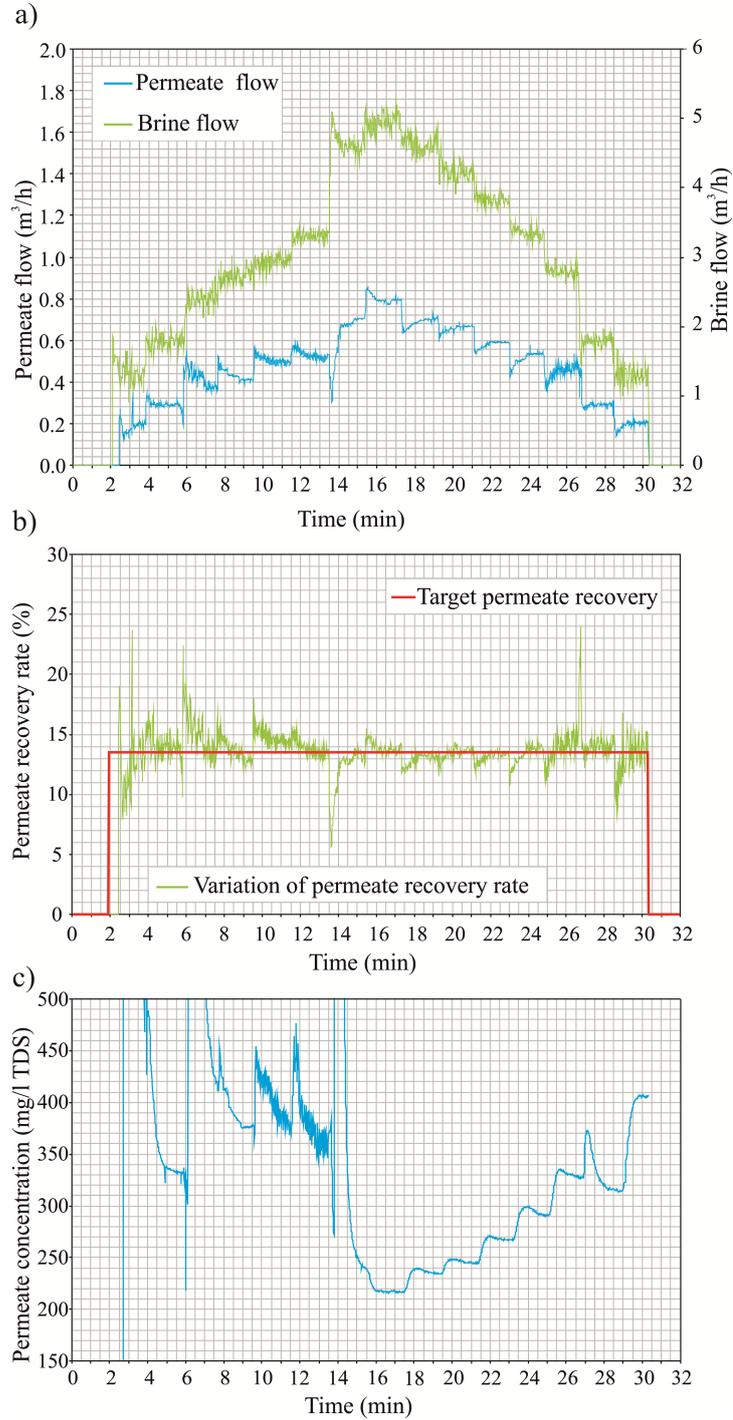


Fig. 4.16: a) Caudales de permeado y de rechazo medidos durante el tiempo que ha operado la planta de OI bajo las condiciones representadas en la Fig. 4.15. b) Tasa de recuperación de permeado registrados durante el tiempo que ha operado la planta de OI bajo las condiciones representadas en la Fig. 4.15. c) Concentración instantánea del flujo de permeado registrada durante el tiempo que ha operado la planta de PI bajo las condiciones representadas en la Fig. 4.15.

de control (presión y caudal de alimentación) respecto de sus valores de referencia (Fig. 4.15-b y Fig. 4.15-c), no se logra un perfecto ajuste entre la potencia teórica generada por la turbina eólica y la potencia consumida por la planta desalinizadora en los intervalos de tiempo Δt de 120 s, en el que se ha asumido que la primera permanece constante. Como puede observarse en Fig. 4.15-a, las rutinas de control implementadas permiten lograr una cierta amortiguación, en el intervalo de tiempo Δt de 120 s, de los picos de desajuste que se generan en los saltos de la potencia generada por la turbina eólica que han sido simulados. Sin embargo, como se muestra en Fig. 4.13, incluso, el uso de intervalos de tiempo superiores al considerado no ha permitido amortiguar completamente las oscilaciones del caudal y de la presión de alimentación. Como se desprende de la Fig. 4.15-b los mayores desajustes de la presión de operación respecto de la de referencia se generan en los saltos de potencia generada. En este contexto, se ha de indicar que dichos desajustes se atenuaron notablemente respecto de los obtenidos cuando en los ensayos iniciales se utilizó una válvula de bola (PSV-1), Fig. 3.6 en lugar de la actual válvula de aguja (PSV-2), Fig. 3.6. Como consecuencia de la alta sensibilidad que la presión presenta a pequeñas variaciones del orificio de cierre de la válvula de bola no se logró un adecuado control de la misma. Dicho inconveniente se acentuaba cuando los caudales de referencia eran más altos (mayores potencias de consumo).

Dados los tiempos de respuesta del sistema de desalación a la variación de los parámetros de operación (presión y caudal), no se logra que la tasa de recuperación de permeado se mantenga en todo instante en el valor constante de 13.56 % fijado como objetivo, aunque sí se logra que éste sea el valor de tendencia (Fig. 4.16-b).

Del análisis de los resultados obtenidos, hasta el momento, se deduce que dada la lentitud del sistema de control, para lograr adaptar instantáneamente el consumo de potencia de la planta desalinizadora a la potencia variable generada por la turbina eólica, así como por los tiempos de respuesta inherentes a los elementos de desalación, se precisa implementar un dispositivo de regulación dinámica. Dicho dispositivo ha de ser capaz de suministrar y almacenar la energía necesaria para cubrir las variaciones de la potencia generada por la turbina eólica respecto de las potencias de consumo reales. Se propone el uso de un supercondensador como sistema de regulación dinámica, encontrándose la investigación que llevan a cabo en

esta materia en fase de análisis y experimentación.

Asimismo, se deduce de los estudios realizados que dada la variación de los límites de operación del prototipo de planta desalinizadora con la temperatura y la concentración del agua de mar de alimentación, puede precisarse la incorporación de una carga de volcado al sistema de desalación accionado por energía eólica propuesto, que se indica en la Fig. 3.4. Dicha anexión, se justifica ante el típico pobre nivel de control de las turbinas eólicas de baja potencia y la necesidad de eliminar la potencia generada cuando esta es superior a la que es capaz de consumir la planta en aquellas situaciones en las que la concentración del agua de alimentación es baja y su temperatura es alta, Fig. 4.5.

Hay que señalar que, dado que el rechazo depende en gran medida de los parámetros de operación y estos se modifican dinámicamente, los valores de concentración de sales del agua producto no logran estabilizarse en los intervalos de tiempo Δt de 120 s utilizados. Como puede observarse en Fig. 4.13, según se incrementa el intervalo de tiempo en que la planta de OI opera con dos tubos de presión en condiciones aproximadamente constantes de presión (50.5 bar)), caudal ($5.3 \text{ m}^3/h$) y condiciones del agua de alimentación (23°C , 37160 mg/l), la concentración de sales del agua producto disminuye tendiendo a la estabilización después de varias horas.

Como puede observarse en Fig. 4.13, cuando la temperatura del aire ambiente ha sido de 23.5°C y el motor eléctrico ha girado a 763 rpm, su temperatura se ha estabilizado en aproximadamente 70°C , después de operar durante 170 min. Sin embargo, cuando el motor eléctrico ha girado a 208 rpm durante 170 min en operación continua, su temperatura ha alcanzado los 79.5°C sin estabilizarse. La estabilización se logra en estas circunstancias cuando se ha alcanzado aproximadamente los 81°C . Esta elevación de la temperatura es consecuencia de los efectos combinados del aumento de pérdidas como consecuencia de las componentes armónicas suministradas por el convertidor de frecuencia y por la reducción en la capacidad de refrigeración del motor auto-ventilado cuando éste opera a bajas revoluciones. El motor eléctrico utilizado, como ya se ha indicado, ha sido diseñado para una elevación de temperatura Clase B (80°C) [145]. Dicho aumento de la temperatura es siempre aditivo a la temperatura ambiente (máxima de 40°C), por tanto, en

el caso de que el motor opere a bajas revoluciones, se dispone de una capacidad térmica extra de 49°C para el caso analizado. Es decir, la diferencia entre la capacidad de temperatura de la clase de aislamiento B (130°C) y la temperatura de operación (81°C). Esta capacidad térmica extra puede utilizarse cuando las temperaturas ambientes sean más elevadas, cuando existan elevaciones de temperaturas por sobrecargas o para alargar la vida del motor y que este tolere mejor los sobrecalentamientos originados por tensiones altas o bajas, desequilibrios de voltaje, etc.

En los lugares donde las temperaturas ambientes sean más elevadas o se estimen mayores sobrecalentamientos, entre las posibles soluciones para evitarlos se encuentran el uso de un motor con una clase de aislamiento más alta, el sobredimensionamiento del motor auto-ventilado o la utilización de un sistema de refrigeración independiente (kit de ventilación forzada).

Por último, señalar que, de acuerdo con los resultados experimentales obtenidos hasta el momento en el trabajo realizado y la experiencia de proyectos previos desarrollados [84–86, 91, 95], se estima que la estrategia de operación planteada podría incorporarse a los sistemas de desalación accionados con energía eólica de mayor escala, tal como el desarrollado en el proyecto SDAWES [86, 91]. Ello, podría reducir las frecuencias de conexión y desconexión de los módulos que integran el sistema de desalación, incluso operando a más altas tasas de recuperación de permeado, Fig. 4.3.

Descripción de las técnicas de *Machine Learning* consideradas en este trabajo de investigación

5.1 Introducción

En este capítulo se describen los aspectos más relevantes de las tres técnicas de *Machine Learning* consideradas en este trabajo de investigación, que tienen su raíz en la teoría de aprendizaje estadístico y métodos de optimización [144]:

- Redes Neuronales Artificiales (ANNs),
- Máquinas de Vectores Soporte (SVMs),
- Bosques Aleatorios (RFs).

Siguiendo el hilo conductor expuesto en la metodología de este trabajo, en primer lugar, se selecciona una de estas técnicas (las ANNs) para crear cuatro modelos que fueron incorporados al sistema de control de la planta. El objetivo es que estos

modelos proporcionen las consignas de caudales y presiones necesarias para controlar en tiempo real la potencia eléctrica consumida por la planta desalinizadora y ajustarla a la generación eléctrica proporcionada por una turbina eólica.

Posteriormente, se emplearon las tres técnicas señaladas para modelar el funcionamiento del prototipo de planta desalinizadora desarrollado en esta tesis. En este segundo paso, se compararon todas las técnicas cuando se varían en un amplio rango los caudales y presiones de operación (como consecuencia de la variación de las potencias eléctricas suministradas por una turbina eólica) así como las características del agua de alimentación (temperatura y conductividad), con el propósito de esclarecer qué técnica es más apropiada para simular el comportamiento del mismo ante la variación de dichos parámetros de operación.

Con respecto al uso de las ANNs en el campo de la desalinización con la tecnología de OI, se debe señalar que desde 1993, cuando El-Hawary [125] propuso algunas posibles aplicaciones de ANNs en desalación, se publicaron varias propuestas para usar las ANNs en tareas que incluyen la optimización de la operación de las plantas desalinizadoras [18], el modelado de las unidades de desalación por OI, [17] y la predicción del funcionamiento de las plantas de OI [14, 16, 130, 142, 146]. La utilización de las SVMs está motivada por ser una de las técnicas que mejor representan el estado del arte en el campo de las técnicas de Machine Learning, con un algoritmo de entrenamiento muy eficaz y estable que proporciona siempre una solución única al problema de estimación y una mayor *sparsity* en dicha solución [147]. La técnica de RF, es una técnica emergente que ha crecido en popularidad en los últimos años, dado que su estrategia de operación ha resultado ser muy buena en comparación con muchas otras técnicas, incluyendo las SVMs y las ANNs, además de ser robusta contra el sobreajuste [148].

5.2 Redes Neuronales Artificiales (ANNs)

Las ANNs constituyendo un paradigma de aprendizaje y procesamiento automático, se basan esquemáticamente en la estructura neuronal del cerebro. Al contrario que los programas de ordenador convencionales, las redes neuronales *elaboran* la información de entrada para obtener una salida o respuesta y no aplican

ciegamente un algoritmo [19].

El principal elemento de una ANN es la neurona artificial. Ésta recibe una serie de entradas a través de interconexiones y emite una salida en base a unas funciones definidas en ella. En la Fig. 5.1, se observa una neurona a la que se le introduce un grupo de entradas x_1, x_2, \dots, x_n definidas por un vector \bar{X} . Estas entradas se multiplican por sus pesos asociados w_1, w_2, \dots, w_n , definidos por el vector \bar{W} . Finalmente, se suman todas las entradas ponderadas algebraicamente obteniendo una salida E que se replica tantas veces como interconexiones de salida disponga la neurona:

$$E = x_1 \cdot w_1 + x_2 \cdot w_2 + \dots + x_n \cdot w_n \quad (5.1)$$

O, en forma vectorial:

$$E = X^T W \quad (5.2)$$

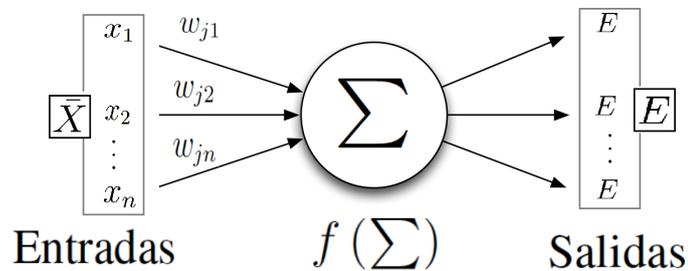


Fig. 5.1: Esquema de una unidad de proceso típica [19].

La estructura básica de interconexión entre células es la de la red multicapa, mostrada en la Fig. 5.2. En ella, las neuronas se suelen agrupar en unidades estructurales que se denominan capas. Las neuronas de cada capa pueden agruparse, a su vez, formando grupos neuronales (*clústers*). Dentro de un grupo, o de una capa si no existe este tipo de agrupación, las neuronas suelen ser del mismo tipo. Finalmente, el conjunto de una o más capas constituye la red neuronal [149].

Se distinguen tres tipos de capas: de entrada, de salida y ocultas. Una capa de entrada está compuesta por neuronas que reciben datos o señales procedentes del

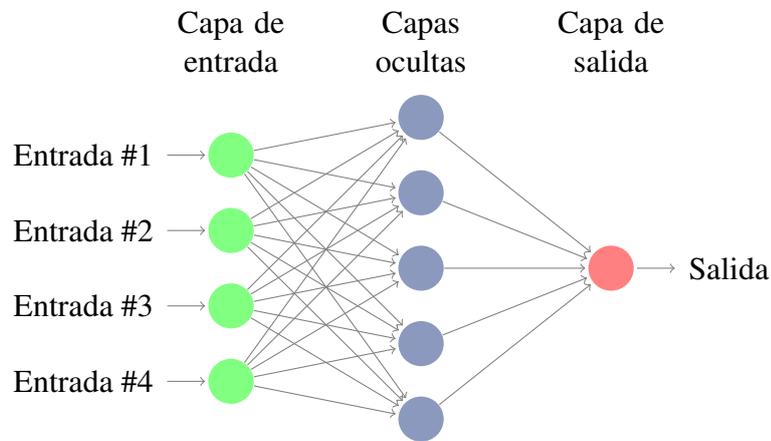


Fig. 5.2: Esquema de una red neuronal artificial (ANN) de tres capas y una salida.

entorno. Una capa de salida es aquella cuyas neuronas proporcionan la respuesta de la ANN. Una capa oculta es aquella que no tiene una conexión directa con el entorno [149]. A través de las interconexiones de las distintas unidades se transmiten valores numéricos de una célula a otra. Estos valores son evaluados por los pesos de las conexiones, que se ajustan durante la fase de aprendizaje para producir la ANN final [19].

Los sistemas neuronales trabajan fundamentalmente en dos modos de operación, el modo recuerdo o ejecución y el modo aprendizaje o entrenamiento [149]. Este último es de especial interés dado que el esquema de aprendizaje de una red es lo que determina el tipo de problemas que será capaz de resolver [19]. La fase de aprendizaje puede definirse como el proceso por el que se determinan los valores de los pesos para todas las conexiones de la red. Está basado en ejemplos, por lo que la capacidad de una ANN estará ligada al tipo de ejemplos disponibles en el proceso de aprendizaje. Para que éste sea eficiente debe haber un número suficiente de ejemplos que posean la diversidad adecuada para que la red no se especialice en resolver un problema muy concreto [19]. El aprendizaje se lleva a cabo introduciendo lentamente los ejemplos del conjunto de aprendizaje y modificando los pesos de las conexiones siguiendo un determinado esquema. Una vez introducidos todos los ejemplos se comprueba si la red trabaja como se espera; de no ser así se repite el proceso introduciendo nuevamente todos los ejemplos. Los pesos se pueden modificar después de cada ejemplo o cuando se introduzcan todos ellos. El proceso de

aprendizaje termina cuando se alcanza un número de ciclos establecido; cuando el error descienda por debajo de una cantidad fijada o cuando la modificación de los pesos comienza a ser irrelevante.

En las varias veces que se han empleado las ANNs en este trabajo, siempre se ha utilizado la arquitectura conocida como Perceptrón Multicapa (MLP, de sus siglas en inglés) [143]. Esta arquitectura ha sido validada y propuesta por numerosos autores para propósitos similares [13, 16, 18, 125, 130, 150] y, tal y como ya se ha dicho, se caracteriza porque tiene sus neuronas agrupadas en capas de diferentes niveles (Fig. 5.2). Las neuronas de la capa de entrada no actúan como neuronas propiamente dichas, sino que se encargan únicamente de recibir los patrones que proceden del exterior y propagar dichas señales a todas las neuronas de la siguiente capa. La última capa actúa como salida de la red, proporcionando al exterior la respuesta de la red para cada uno de los patrones de entrada. Las neuronas de las capas ocultas realizan un procesamiento no lineal de los patrones recibidos. Las conexiones del perceptrón multicapa siempre están dirigidas hacia adelante, esto quiere decir que las neuronas de una capa siempre se conectan con las de la capa siguiente. Por ello esta estructura recibe el nombre de redes alimentadas hacia adelante o redes «feedforward» [19, 151, 152]. Las conexiones entre las neuronas llevan asociado un número real, llamado peso de la conexión. Todas las neuronas de la red llevan también asociado un umbral, que en el caso del perceptrón multicapa suele tratarse como una conexión más a la neurona, cuya entrada es constante e igual a 1. También suele decirse que el perceptrón multicapa tiene conectividad total, esto es que las neuronas de una capa están conectadas con todas las neuronas de la capa siguiente, así hasta llegar a la última capa de la arquitectura.

El perceptrón multicapa define una relación entre las variables de entrada y las variables de salida de la red. Esta relación se obtiene propagando hacia adelante los valores de las variables de entrada. Cada neurona procesa la información recibida y produce una respuesta mediante su función de activación que se propaga a través de la conexión correspondiente.

Si se tiene un perceptrón multicapa con L capas, de las cuales $L - 2$ son capas ocultas, que dispone de n_L neuronas en la capa L , para $L = 1, 2, \dots, C$:

- $W^L = (w_{ij}^L)$ es la matriz de pesos asociada a las conexiones de la capa L a la capa $L + 1$ para $L = 1, 2, \dots, L - 1$.
- $B^L = (\beta_i^L)$ es el vector de umbrales (o bias) de las neuronas de la capa L para $L = 2, \dots, L$.
- y, h_i^L es la activación de la neurona i de la capa L .

Las activaciones de las distintas neuronas se calculan de la siguiente forma:

- **Activación de las neuronas de la capa de entrada (h_i^1).** Como estas neuronas se encargan de transmitir las señales recibidas del exterior:

$$h_i^1 = x_i ; \text{ para } i = 1, 2, \dots, n_1 \quad (5.3)$$

- **Activación de las neuronas de la capa oculta L (h_i^L).** Estas neuronas procesan la información recibida aplicando la función de activación f a la suma de los productos de las activaciones que recibe por sus correspondientes pesos, es decir:

$$h_i^L = f \left(\sum_{j=1}^{n_{L-1}} w_{ji}^{c-1} h_j^{L-1} + \beta_i^c \right) ; \text{ para } i = 1, 2, \dots, n_L \text{ y } L = 2, 3, \dots, L - 1 \quad (5.4)$$

- **Activación de las neuronas de la capa de salida L (h_i^L).** Estas neuronas también se activan mediante una función de activación que, en este caso es:

$$y_i = h_i^L = f \left(\sum_{j=1}^{n_{L-1}} w_{ji}^{L-1} h_j^{L-1} + \beta_i^L \right) ; \text{ para } i = 1, 2, \dots, n_L \quad (5.5)$$

La funciones de activación f más utilizadas para el perceptrón multicapa son la *función sigmoïdal* y la *función tangente hiperbólica*. Dichas funciones poseen como imagen un rango continuo de valores dentro de los intervalos $[0, 1]$ y $[-1, 1]$, respectivamente, y vienen dadas por las siguientes expresiones:

$$f_1(x) = \frac{1}{1 + e^{-x}} \quad (5.6)$$

$$f_2(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (5.7)$$

Ambas son crecientes con dos niveles de saturación: el máximo, que proporciona salida 1, y el mínimo, que proporciona salida 0 en el caso de la función sigmoide y salida -1 para la tangente hiperbólica. Habitualmente la función de activación es común a todas las neuronas de la red y es elegida por el diseñador basándose únicamente en los valores de activación que se quiera que alcancen las neuronas.

A veces, las neuronas de la capa de salida se distinguen de las demás en que su función de activación es distinta. Las más usadas son la función identidad y la función escalón.

De cara a diseñar una arquitectura concreta para resolver un problema, se han de tener en cuenta los siguientes ítems.

1. *La función de activación a emplear.* Dependiendo del recorrido que se desea que tenga la salida, se elige una función u otra. Generalmente el hecho de elegir una de las dos expuestas no influye en la capacidad de la red para resolver un problema.
2. *El número de neuronas y número de capas.* Algunas veces tanto el número de neuronas como el número de capas vienen impuestos por el tipo y las variables del problema a resolver. Otras es preciso hacer una serie de pruebas iniciales que determinen el número de capas y neuronas óptimo. En el caso de las capas ocultas, no existe un método o regla que determine el número óptimo de neuronas, en la mayor parte de las aplicaciones es necesario determinarlo por prueba y error. Partiendo de una arquitectura ya entrenada, se aumenta o disminuye el número de capas y neuronas ocultas hasta encontrar la arquitectura que mejor satisfaga los requerimientos del problema. En esta tesis se expone un método propio que realiza esta tarea.

En este trabajo en concreto se han utilizado ANNs del tipo feedforward-MLP. En general, las ANNs han sido utilizadas en varios tipos de aplicaciones en sistemas de energía renovable [153]. En el año 2000, por ejemplo, Addison et al. [154],

propusieron una versión de algoritmo MCP basado en redes neuronales para estimar la energía eólica producida. Los autores investigaron la posibilidad de utilizar redes neuronales para hacer predicciones de rendimiento energético a largo plazo en un sitio eólico potencial. En su trabajo consideraron la eficacia de las redes neurales en la predicción de la velocidad del viento en un sitio objetivo a partir de mediciones de la velocidad y dirección del viento en un sitio de referencia. Los autores compararon esta técnica con los algoritmos MCP estándar utilizados en la industria de la energía eólica. Concluyeron que con esta técnica se pueden alcanzar mejoras en la precisión de la predicción entre 5 %-12 %. Propuestas similares han sido llevadas a cabo con posterioridad en otras referencias [155–157].

Todos los modelos utilizados en este trabajo en los que se emplean las ANNs, cuentan con cuatro capas de neuronas ($L=4$). Una capa de entrada (*input layer*), con un número de neuronas n_{L-3} igual al número de variables de entrada al modelo, dos capas ocultas (*hidden layers*) con n_{L-2} y n_{L-1} neuronas y una capa de salida (*output layer*) con una sola neurona, $n_L=1$, que proporciona la respuesta del modelo. La función de regresión genérica de la ANN se representa en la Ec. (5.8).

$$f(x) = g \left(\beta_0^L + \sum_{j=1}^{n_{L-1}} w_j^{L-1} h_j^{L-1} \left(\beta_j^{L-1} + \sum_{k=1}^{n_{L-2}} w_{kj}^{L-2} h_k^{L-2} \left(\beta_k^{L-2} + \sum_{i=1}^{n_{L-3}} w_{ik}^{L-3} x_i \right) \right) \right) \quad (5.8)$$

En la Ec. (5.8) $h_j^{L-1}(\cdot)$, $h_k^{L-2}(\cdot)$ y $g(\cdot)$ son las funciones de activación de los nodos de las capas ocultas $L-1$ y $L-2$ y del nodo de la capa de salida L , respectivamente. En este trabajo las funciones $h_j^{L-1}(\cdot)$ y $h_k^{L-2}(\cdot)$ tienen forma sigmoideal, sin embargo, la función $g(\cdot)$ se ha tomado la función lineal usualmente empleada en las arquitecturas MLP. Para llevar a cabo la estimación de los parámetros desconocidos (pesos w y bias β) de las ANNs, se utilizó el algoritmo de entrenamiento RPROP (cuyas siglas en inglés se expanden en *Resilient Backpropagation* [158]. Este algoritmo se llevó a la práctica usando la Matlab's Neural Network Toolbox [159].

5.3 Máquinas de Vectores Soporte (SVMs)

Las máquinas de vectores soporte, máquinas de soporte vectorial o SVMs (por sus siglas en inglés) son un tipo de red neuronal originalmente diseñada para la solución de problemas no lineales de clasificación [160, 161], pero que también se han aplicado a problemas de regresión [162, 163] y predicción de series temporales [164–169]. Tienen una gran capacidad de generalización [22, 170], la cual es función directa de su estructura y de la metodología utilizada para la estimación de sus parámetros [164].

El concepto fundamental en el que se basan las SVM para su aplicación en problemas de clasificación es el que se muestra en la Fig. 5.3. Los datos de entrada son transformados implícitamente a un espacio nuevo, generalmente de una dimensión superior, en donde es posible clasificarlos con hiperplanos de separación [20]. Es decir, después de convertir los datos adecuadamente, se busca el hiperplano óptimo de separación, el cual solo depende de unos pocos puntos llamados vectores de soporte.

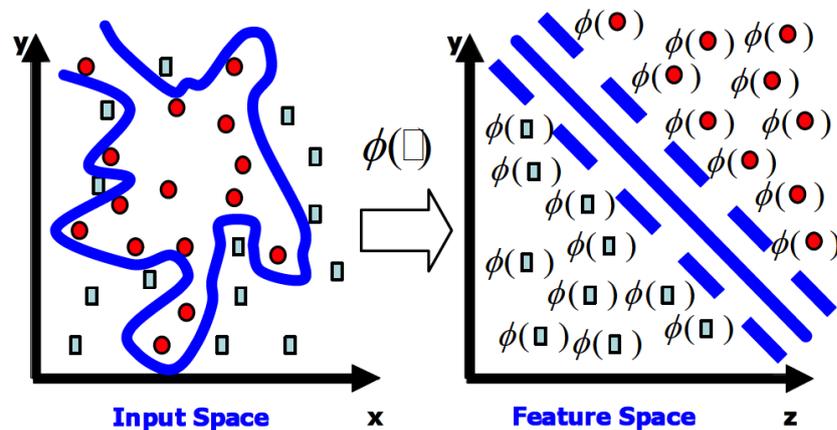


Fig. 5.3: Esquema de transformación de espacios de una SVM. Fuente: [20].

Las máquinas de vector soporte, también pueden aplicarse a problemas de estimación por regresión como el que atañe a este trabajo [21, 163, 171]. De hecho, en dicha aplicación, las SVM han proporcionado excelentes resultados [166, 172, 173].

Partiendo de un conjunto de datos de entrenamiento $\{(x_1, y_1), \dots, (x_e, y_e)\} \subset \mathcal{X} \times \mathcal{R}$, donde \mathcal{X} denota el espacio de los patrones de entrada. El objetivo de una SVM aplicada a regresión (ε -SV regression) consiste en encontrar una función $f(x)$ que, como máximo, tenga una desviación ε de los valores objetivo y_i de todos los datos del conjunto de entrenamiento (Fig. 5.4). En otras palabras, no importa el error que cometan los datos siempre y cuando éste sea inferior al ε definido, pero de ninguna forma se acepta ninguna desviación mayor que esta [21].

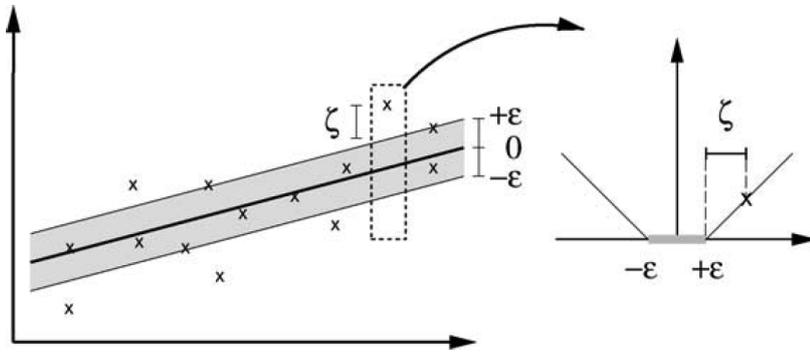


Fig. 5.4: Ajuste de un problema lineal empleando regresión mediante una SVM. Fuente: [21].

Cuando se aplican las Máquinas de Soporte Vectorial a problemas de regresión no lineales, donde el vector \mathbf{x} es el vector de entradas al modelo e \mathbf{y} es el conjunto de salidas, lo primero es convertir el problema a un espacio superior para hacerlo un problema de regresión lineal [22, 148, 152]. Para ello se transforma del espacio de entrada de dimensión m mediante una función no lineal $\Phi = \Phi(\mathbf{x}) \in \mathbb{R}^h$ a un nuevo espacio de dimensión h comúnmente mayor que d , en el cual se resuelve un problema lineal. Para llevar a cabo dicha transformación se ha de seleccionar una función denominada «kernel» $k(x_i, x_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle$ que es una función definida positiva:

De esta manera se obtiene un problema de regresión (lineal en Φ pero no lineal en \mathbf{x}) como el siguiente:

$$\begin{aligned}
 f(\mathbf{x}) &= \langle \mathbf{w}, \Phi(\mathbf{x}) \rangle + b \\
 &= \langle \sum_{x_i \in \mathcal{S}} \beta_i \Phi(\mathbf{x}_i), \Phi(\mathbf{x}) \rangle + b \\
 &= \sum_{x_i \in \mathcal{S}} \beta_i \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}) \rangle \\
 &= \sum_{x_i \in \mathcal{S}} \beta_i k(\mathbf{x}_i, \mathbf{x})
 \end{aligned} \tag{5.9}$$

donde $\langle \cdot, \cdot \rangle$ denota el producto escalar y \mathbf{w} y b son los coeficientes de obtenidos por minimización del error entre f y los valores observados de y , con $b \in \mathbb{R}$. Esta minimización del error se logra solucionando el problema de optimización que se formula en la Ec. 5.10 [22].

$$\min_{w,b} \left\{ \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi'_i) \right\}$$

$$\left\{ \begin{array}{l} \langle \mathbf{w}, \Phi(\mathbf{x}_i) \rangle + b - y_i \leq \varepsilon + \xi_i \\ y_i - \langle \mathbf{w}, \Phi(\mathbf{x}_i) \rangle + b \leq \varepsilon + \xi'_i \\ \xi_i, \xi'_i \geq 0, i = 1, \dots, n \end{array} \right. \tag{5.10}$$

Para medir este error, en vez de usar el error cuadrático medio, las Máquinas de Vector Soporte empleadas para Regresión (SVR) emplean el ε -insensitive error, definido por:

$$|f(\mathbf{x}; \mathbf{w}) - y|_\varepsilon = \begin{cases} 0, & \text{si } |f(\mathbf{x}; \mathbf{w}) - y| < \varepsilon \\ |f(\mathbf{x}; \mathbf{w}) - y| - \varepsilon, & \text{en otro caso,} \end{cases} \tag{5.11}$$

En caso de que la diferencia entre f e y sea menor que ε , el error es ignorado; pero si el error es mayor que dicho valor, se calcula el error absoluto medio. Los coeficientes \mathbf{w} y b son estimados por minimización de la siguiente función objetivo R usando los datos del conjunto de entrenamiento (\mathbf{x}_i, y_i) :

$$R = \frac{C}{N} \sum_{i=1}^N |f(\mathbf{x}_i; \mathbf{w}) - y_i|_\varepsilon + \frac{1}{2} \|\mathbf{w}\|^2, \tag{5.12}$$

En la Ec. 5.9, β_i son los multiplicadores de Lagrange y $\mathbf{w} = \sum_{x_i \in \mathbb{S}} \beta_i \Phi(x_i)$, siendo \mathbb{S} el conjunto de vectores soporte (conjunto de puntos de la muestra que saturan las restricciones de la Ec. 5.10 en el espacio de características).

$\|\mathbf{w}\|^2$ es la norma de \mathbf{w} ; mientras que $\xi_i, \xi'_i \geq 0, i = 1, \dots, n$, son variables *slack* que se penalizan en la función objetivo y que recogen los posibles errores; C es un parámetro regularizador que debe seleccionarse. Cuanto más elevado es el valor de C mayor es la penalización de los errores del ajuste y la solución es una función $f(x)$ más compleja. Cuanto menor es el valor de C menos se penalizan los errores del ajuste y la solución es una función $f(x)$ menos compleja; ε es un margen máximo que se permite al error y que define una banda de radio ε alrededor de los datos (x_i, y_i) , dentro de la cual el error no se penaliza con objeto de no producir sobreajuste.

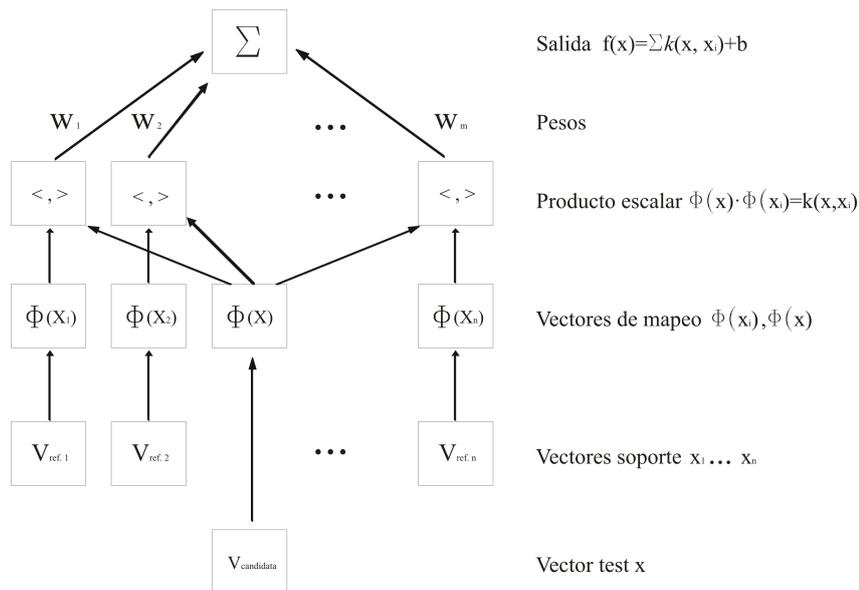


Fig. 5.5: Arquitectura de la Máquina de Vector Soporte. Fuente: [22].

La principal ventaja de las SVR sobre los modelos basados en ANNs radica en la conversión del problema de regresión no-lineal a un problema lineal. La Eq. (5.9) elimina la necesidad de optimizar el problema no lineal con mínimos locales en la función objetivo. No obstante, $\Phi(x)$ puede llegar a ser un vector de una dimensión muy elevada, lo que eleva el coste computacional de la resolución del problema de regresión lineal. En SVR, se suele emplear un kernel trucado, que se basa en

reemplazar el producto escalar $\langle \Phi(\mathbf{x}), \Phi(\mathbf{x}') \rangle$ en la solución del algoritmo por una función kernel $K(x, x')$ que no presenta las dificultades de manejo de datos de la función $\Phi(\mathbf{x})$. Por supuesto, cada *kernel* diferente determina un modelo diferente de SVM. Sin embargo, la problemática de la selección óptima del *kernel* no ha sido considerada en este trabajo, seleccionándose aquí el *kernel gaussiano* [22, 152], Ec. 5.13, debido a sus buenas propiedades ampliamente contrastadas en multitud de ámbitos de aplicación:

$$k(x, x_i) = \exp \left\{ -\frac{1}{2\sigma^2} \|x - x_i\|^2 \right\} \quad (5.13)$$

En Ec. 5.13 el parámetro σ regula el grado de complejidad de la solución.

C , ε y σ son, por tanto, los parámetros a definir (conocidos como hiperparámetros).

Tras la minimización de la ecuación (5.12), que usa el método de los multiplicadores de Lagrange, la regresión final estimada queda de la forma:

$$f(\mathbf{x}) = \sum_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (5.14)$$

donde la sumatoria solo se realiza sobre el subconjunto de los datos \mathbf{x}_i (llamados vectores soporte). Tal y como se ha comentado, el rendimiento del modelo SVR depende de la función *kernel* elegida y de los hiperparámetros C y ε .

Para la programación de los modelos de simulación basados en SVM utilizados en este trabajo se ha utilizado la función *fitrsvm* de la *Statistics and Machine Learning Toolbox* de Matlab [174].

En este trabajo se ha utilizado un kernel gaussiano, Ec. 5.13. Los datos de entrada de los distintos modelos se introducen todos mediante el vector \mathbf{x} . Entre ellos se introducen las potencias eléctricas consumidas por la planta, la conductividad del agua, la temperatura, etc.

partiendo de un conjunto de variables predictoras X , una variable continua Y . Tres son los tipos de nodos que contiene un árbol de regresión. El nodo raíz, que por convenio se ubica en la parte alta del diagrama del árbol de regresión, los nodos interiores que al igual que en el nodos raíz se declaran condiciones exhaustivas y excluyentes a las variables predictoras y M nodos hojas (o nodos terminales), en cada uno de los cuales, R_i , se especifica un nivel predictivo de la variable objetivo Y , cumpliéndose que $\bigcap_{i=1}^M R_i = \emptyset$.

La función de regresión en el caso de un árbol de regresión puede expresarse en la forma mostrada en la Ec. 5.15, [152].

$$f(x) = \sum_{i=1}^M \gamma_i I(x \in R_i) \quad (5.15)$$

En Ec. 5.15 γ_i son constantes en cada nodo hoja R_i , ya que para cada observación que cae en el interior de un nodo hoja se establece la misma predicción, la cual es la media $\overline{y_{R_i}}$, Ec. 5.16, de los valores objetivo y_j pertenecientes a dicho nodo hoja. En Ec. 5.15, $I(\cdot)$ es una función que proporciona el valor 1 si el argumento es verdadero y 0 en caso contrario.

$$\gamma_i = \overline{y_{R_i}} = \frac{1}{n_i} \sum_{x_j \in R_i} y_j \quad (5.16)$$

En la Ec. 5.16 n_i es el número total de observaciones de la variable objetivo Y pertenecientes al nodo hoja R_i .

Al construir un árbol de regresión se persigue encontrar M nodos hojas que minimicen el *Residual Sum of Squares (RSS)*, dado por la Ec. 5.17.

$$RSS = \sum_{i=1}^M \sum_{x_j \in R_i} (y_j - \gamma_i)^2 \quad (5.17)$$

El árbol final contiene, en cada hoja (o nodo terminal), un conjunto reducido de datos que representa a cada una de las clases [175]. Las clases se consideran *disjuntas* puesto que una instancia pertenece siempre a una clase pero no puede

pertenecer a dos clases al mismo tiempo. Dicho de otra manera, las reglas de división son excluyentes y exhaustivas ya que cada instancia cumple o no cumple una condición y, además, siempre ha de cumplir una de las condiciones [177]. Por tanto, para que un árbol de decisiones funcione bien es importante tener en cuenta: i) el número de particiones a considerar, y ii) el criterio de selección de particiones [177]. Con el fin de evitar el sobreajuste del modelo, se utiliza un algoritmo de poda (*pruning*) que elimina aquellas condiciones de las ramas del árbol consideradas demasiado específicas. En los problemas de regresión, el algoritmo *CART* va asignando una media y una desviación típica a cada uno de los nodos divididos. De esta manera, a medida que va creciendo el árbol, el algoritmo intenta seleccionar aquellas particiones que reduzcan las desviaciones típicas de los nodos hijos. Finalmente, se obtiene la variable estimada promediando el valor del resultado en cada nodo.

Dada la dificultad desde el punto de vista computacional de considerar todos los posibles casos de partición del espacio de características en M nodos hoja, suele emplearse un *greedy algorithm* que, mediante un proceso iterativo conocido como división binaria recursiva, proporciona para cada nodo el punto de corte. Dicho proceso finaliza cuando cada nodo hoja contiene menos de un número de observaciones establecido por el usuario u otra norma de parada.

Una de las desventajas de los arboles de regresión es que no tienen el mismo nivel de precisión predictiva que otras técnicas de regresión tal como las ANNs y las SVMs [152]. Sin embargo, utilizando un RF, que es una técnica basada en árboles que implica generar múltiples árboles, los cuales se combinan para realizar una predicción, la capacidad predictiva de los arboles de regresión puede ser notablemente mejorada [152].

El ***Bagging*** es un método de agregación de modelos homogéneos ya que combina varios modelos de la misma naturaleza (varios árboles de decisión en el caso de los RF). Consiste en obtener varios subconjuntos a partir del conjunto inicial de datos y promediar las predicciones realizadas por los distintos modelos [175]. El método emplea el procedimiento *Bootstrap* para generar los distintos subconjuntos [152, 175, 179].

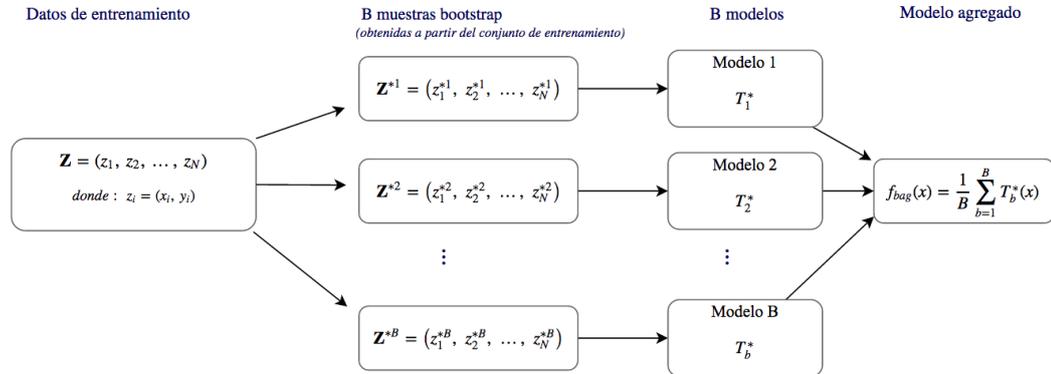


Fig. 5.7: Diagrama explicativo de la técnica de *Bagging*.

Combinando las técnicas *CART* y *Bagging*, se obtiene el algoritmo RF, (Algoritmo 1).

Es decir, la técnica de RF recurre al bootstrapping para generar B pseudo conjuntos de entrenamiento a partir de la muestra \mathbf{Z} de n datos escogida para el entrenamiento con los que ajustar separadamente B árboles de regresión $T_b(x)$ y después promediarlos, Ec. 5.18.

Con el *bagging* se puede lograr reducir la alta varianza y relativamente baja bias (ya que en los RFs los árboles de regresión no se someten a podado del promedio de los árboles de regresión. Sin embargo, se necesita reducir la correlación que pueda existir entre cualquier par de árboles B del RF para que la reducción de la varianza sea notable. Para ello, en el proceso de construcción de los B árboles que componen el RF esta técnica realiza una selección aleatoria de $mtry < d$ predictores totales antes de evaluar cada división del árbol.

Para la programación de los modelos MCP basados en RF utilizados en este trabajo se ha utilizado la función *TreeBagger* de la *Statistics and Machine Learning Toolbox de Matlab* [174].

Algoritmo 1 Algoritmo *Random Forest* para regresión

Partiendo de un conjunto de datos de entrenamiento $\mathbf{Z} = (z_1, z_2, \dots, z_N)$, donde $z_i = (x_i, y_i)$:

1. Se utiliza una selección con reemplazamiento (*bootstrapping*) para crear B nuevos subconjuntos de igual tamaño que el conjunto original de datos de entrenamiento \mathbf{Z} .
2. Con cada nuevo subconjunto *bootstrap* $(Z^{*1}, Z^{*2}, \dots, Z^{*B})$ se construye un árbol T_b del *random-forest*. Para su construcción, se repiten recursivamente los siguientes pasos en cada nodo terminal del árbol, hasta alcanzar el tamaño de nodos mínimo n_{min} especificado:
 - I. Del número total de variables p , se seleccionan m aleatoriamente.
 - II. De las m variables, se selecciona la mejor variable que divide los datos del nodo actual.
 - III. Se divide el nodo actual en dos nodos hijos.
3. Se obtiene el ensamblado de árboles $\{T_b\}_1^B$.

Para realizar la estimación de una nueva entrada x , se aplica la siguiente expresión agregada:

$$f_{RF}^B = \frac{1}{B} \sum_{b=1}^B T_b(x) \quad (5.18)$$

Redes Neuronales Artificiales para la gestión variable del prototipo de planta desalinizadora considerado

6.1 Introducción

En este capítulo se propone y se analiza el uso de Redes Neuronales Artificiales (ANNs) para gestionar la operación variable del prototipo desarrollado.

En capítulos anteriores se explicó la problemática planteada al intentar controlar la potencia consumida en una planta de este tipo. Por un lado, el sistema de control debe adecuar los valores de presión y caudal de operación en la planta para que esta consuma la potencia requerida en cada momento. Por otro lado, dichos valores se ven afectados por las características del agua de alimentación y por la potencia a consumir en cada instante.

A continuación se detalla la propuesta de incorporar modelos de ANN en el sistema de control de la planta para permitir la operación fluctuante de la misma en concordancia con la generación variable de origen eólico que la alimenta. Los

modelos de ANN se construyen para que generen las consignas de caudal y presión (con la restricción de mantener la tasa de recuperación de permeado dentro de un cierto rango) teniendo en cuenta, no sólo la potencia eléctrica disponible, sino también la temperatura y conductividad del agua de alimentación de la planta.

La novedad de esta propuesta radica en el hecho de que, por primera vez, se emplean ANNs como herramientas de control en una planta desalinizadora de pequeño tamaño. El objetivo es investigar si los modelos ANN son capaces de manejar las consignas de presión y caudal de operación permitiendo que la energía consumida por la planta se adapte a una amplia y aleatoria variación de potencia suministrada por una turbina eólica. Estas consignas de presión y caudal generadas por los modelos ANN constituyen las entradas a dos lazos de control que regulan los actuadores que manejan estas variables. La metodología utilizada para lograr el objetivo marcado contiene, a su vez, novedades con respecto a las metodologías utilizadas en estudios existentes en la literatura científica. En este sentido, se debe señalar lo siguiente:

- a) Una estrategia muy específica es utilizada para capturar los datos operativos de la planta desalinizadora de OI (que son usados para el entrenamiento de los modelos ANN).
- b) Se propone una nueva metodología que incluye el uso de algoritmos genéticos y del algoritmo de retropropagación resiliente [158] para llevar a cabo la selección del número de capas ocultas de neuronas y el número de neuronas de cada capa oculta en los modelos ANN empleados.
- c) También se propone un procedimiento para analizar las hipótesis estadísticas que justifican estadísticamente las conclusiones alcanzadas cuando se comparan los errores cometidos al tratar de ajustar la potencia real consumida a la potencia eléctrica disponible en varios ensayos operacionales usando distintas temperaturas de agua y conductividades.

6.2 Materiales

6.2.1 Equipamiento utilizado

El esquema de planta desalinizadora utilizado en esta tesis ya se ha descrito en el capítulo 3 (Fig. 3.4). Tal y como se ha explicado previamente, la planta formará parte, en un futuro cercano, de una microred eléctrica cuya configuración general puede observarse dentro de la línea de rayas discontinuas de la Fig. 6.1. Sin embargo, bajo circunstancias excepcionales, y con el propósito de realizar los ensayos necesarios para este estudio, la planta puede desconectarse de la micro-red eléctrica (abriendo el interruptor A) y conectarse (cerrando el interruptor B) a la red eléctrica convencional a través de un variador de frecuencia (tal y como se muestra en el recuadro naranja de la parte inferior derecha de la Fig. 6.1). En esta figura se muestran la dirección de los flujos de energía y agua en el sistema. También se observan las señales de entrada y salida que gestiona la ANN implementada e incorporada al sistema de control.

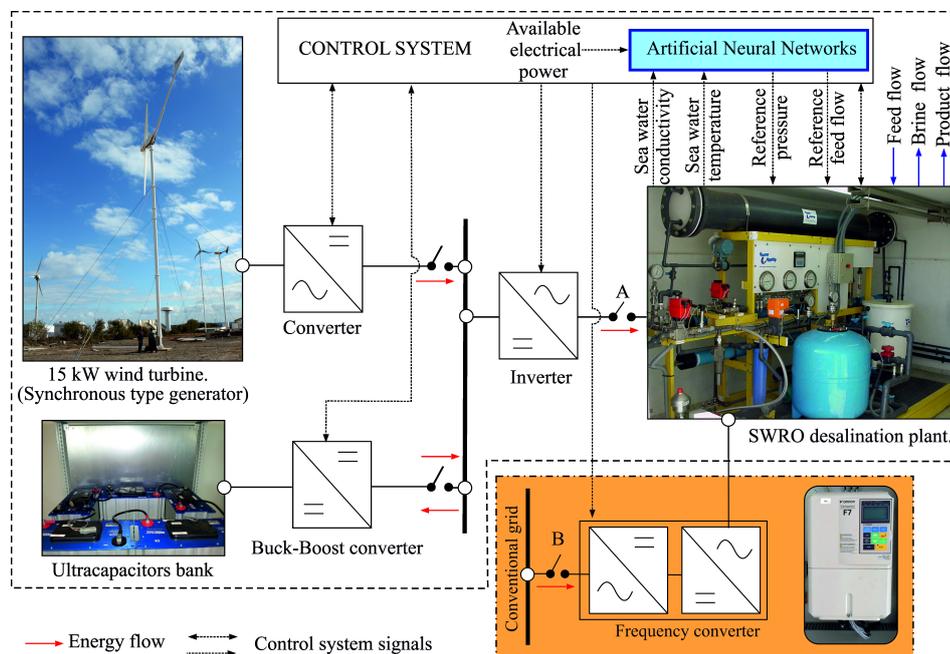


Fig. 6.1: Planta desalinizadora de ósmosis inversa usada para los estudios descritos en este apartado.

6.2.2 Equipos adicionales instalados en el sistema para modificar las características del agua de alimentación y estudiar nuevas estrategias de gestión inteligente

Con el propósito de variar las características del agua de alimentación que se introduce en la planta desalinizadora y estudiar así el efecto que estas variaciones tienen en el sistema diseñado, se añadieron los equipos adicionales que aparecen remarcados dentro del recuadro de trazos-puntos mostrado en la Fig. 6.2.

En la parte superior de dicha imagen (Fig. 6.2), se observa, dentro del recuadro de trazos discontinuos, el sistema hidráulico ya descrito anteriormente. A este sistema se le ha añadido un tanque para mezclar aguas de salinidades diferentes (agua producto con salinidad muy baja, agua de rechazo y agua de mar con salinidades muy elevadas). Este tanque contiene, a su vez, tres resistencias calentadoras de 6 kW cada una y una bomba agitadora. Con estos equipos es posible incrementar la temperatura del agua y lograr una mezcla homogénea rápidamente. El agua procedente de este tanque se impulsa al circuito hidráulico general del prototipo mediante una bomba de baja presión que accionada eléctricamente.

Cuando, en lugar de elevar la temperatura, se pretende enfriar la mezcla de agua de alimentación, se emplean bloques de agua de mar congelados mediante el congelador industrial mostrado en la parte inferior de la Fig. 6.2.

6.2.3 Intervenciones del sistema de control

El diagrama de bloques simplificado de la Fig. 6.3 muestra la forma de trabajar del sistema de control desarrollado que incluye a las ANNs. El objetivo fundamental de dicho sistema es variar la energía consumida por la planta desalinizadora cuando la potencia disponible cambia. La misión de las ANNs en el sistema de control ha sido resaltada en la Fig. 6.3.

Esencialmente, los modelos de ANN propuestos actúan como funciones de transferencia que, tomando como entrada los valores de:

- Potencia que la planta desalinizadora debe consumir, P_{wt} .

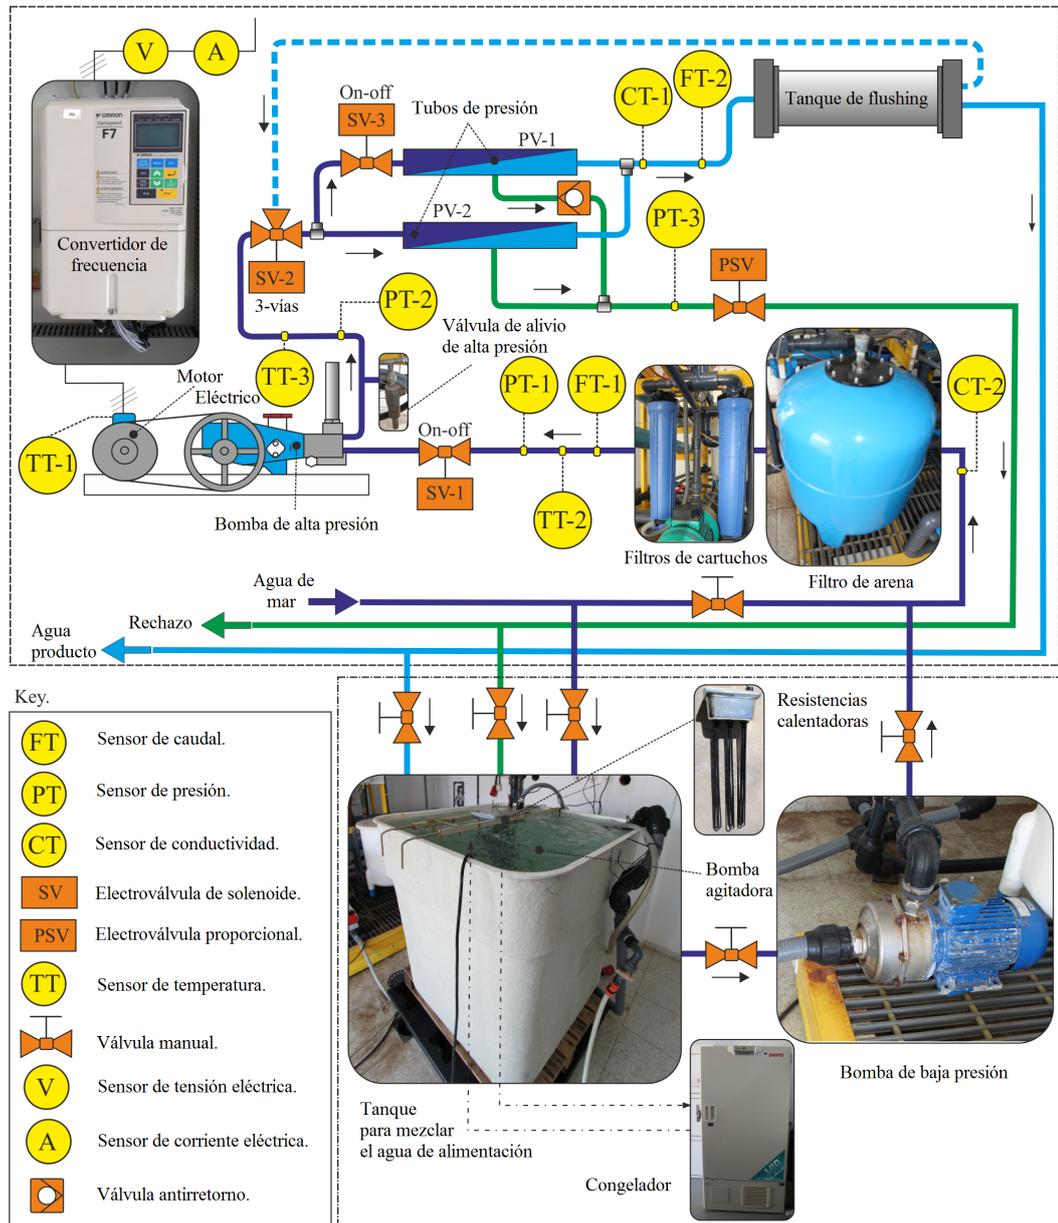


Fig. 6.2: Esquema hidráulico del nuevo prototipo de planta desalinizadora con los equipos adicionales instalados para el estudio de nuevas estrategias de gestión inteligente.

- Conductividad del agua de alimentación a la planta desalinizadora, C_f (registrada por el sensor de conductividad CT-2 mostrado en la Fig. 6.2).
- Temperatura del agua de alimentación de la planta desalinizadora, T_f (registrada por el sensor de temperatura TT-3 mostrado en la Fig. 6.2).

Con esas entradas, generan las consignas de presión, p_{fr} , y caudal Q_{fr} que son requeridas por el sistema de control para adaptar la potencia consumida a la potencia generada por la turbina eólica. La generación eléctrica de la turbina ha sido simulada a partir de los datos de viento medidos en tiempo real y la curva de potencia facilitada por el fabricante de la turbina eólica.

Asimismo, en la Fig. 6.3 se muestra una representación de las intervenciones del sistema de control relacionadas con el convertidor de frecuencia y la válvula proporcional de aguja PSV con el objetivo de regular el caudal de la bomba de alta presión así como la presión de operación de la planta de OI y así modificar su potencia consumida.

El sistema de control, en base a las consignas generadas por los modelos ANN (Q_{fr} y p_{fr}), regula las variables de presión y caudal a través de dos algoritmos que contienen dos bucles de control cerrado.

Uno de estos bucles actúa sobre el convertidor de frecuencia para regular la velocidad de la bomba de alta presión y, de esta manera, ajustar el caudal real en la planta a la consigna, Q_{fr} , generada por el modelo de ANN encargado para ello. El caudal real en la planta, Q_f , es medido por el sensor FT-1 representado en la Fig. 6.2. Este lazo de control se basa en un controlador de tipo PI (Proporcional-Integral) para realizar el control y ajuste de esta variable.

El otro lazo de control actúa sobre la válvula PSV para regular la presión real de operación, p_f , en la planta desalinizadora y ajustarla a la consigna de presión, p_{fr} , generada por otro modelo de ANN desarrollado para ello. La presión real en la planta es medida por el sensor PT-2 mostrado en la Fig. 6.2. En este caso, la presión se regula mediante un bucle cerrado que emplea un controlador de tipo PID (proporcional-integral-derivativo) implementado e integrado en el PLC (Programmable Logic Controller) del sistema.

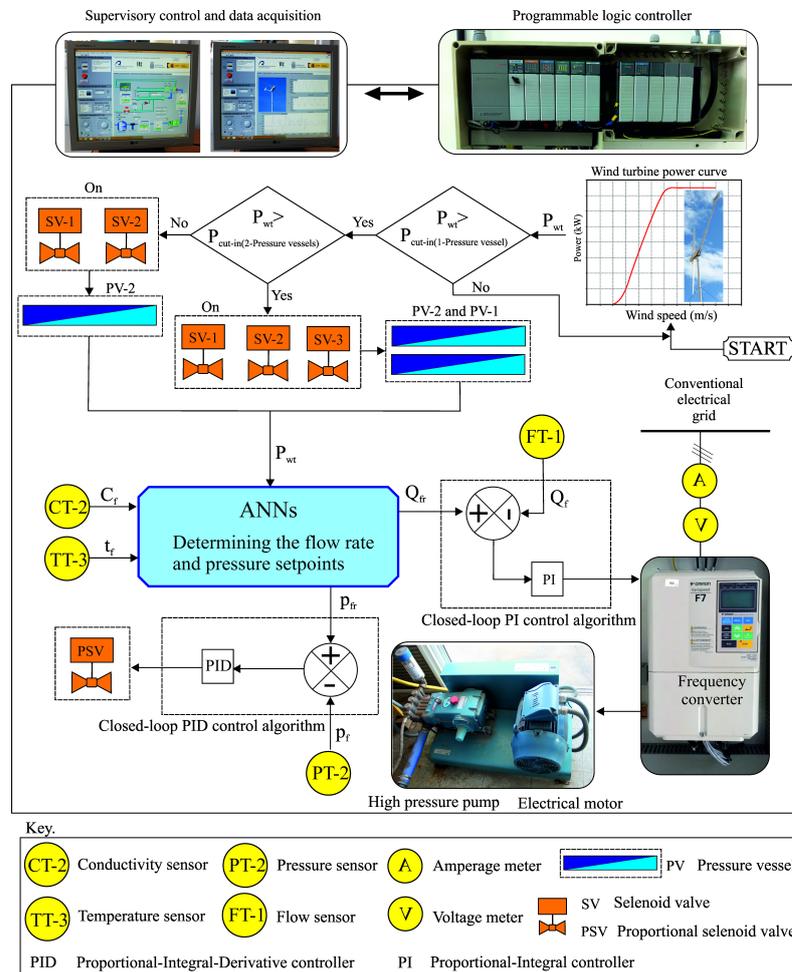


Fig. 6.3: Diagrama de actuación del sistema de control de la planta desalinizadora.

6.3 Metodología

6.3.1 Descripción del proceso de obtención de datos operativos de la planta desalinizadora

A continuación, se describe el procedimiento seguido para generar el conjunto real de datos operativos de la planta desalinizadora que permite entrenar y ensayar los modelos de ANN empleados. Posteriormente, una vez entrenados y ajustados los modelos, se incorporan en el sistema de control descrito anteriormente, Fig. 3.7. Más concretamente, se integran el bloque «*Generación de consignas de presión y*

caudal», señalado en la Fig. 3.10. El propósito es que, dicho bloque, genere las presiones, p_{fr} , y caudales, Q_{fr} , de referencia necesarios para adaptar la potencia consumida por la planta a la potencia generada por la turbina eólica.

Ata [180] llevó a cabo una amplia revisión de aplicaciones de ANNs en sistemas energéticos eólicos y concluyó que el funcionamiento de las ANNs es altamente dependiente de la selección de los datos de entrenamiento. Dado que el objetivo del trabajo descrito en este capítulo es el de conseguir que la planta de OI sea capaz de adaptarse a una amplia y aleatoria variación de potencias de operación, con diferentes combinaciones de características del agua de alimentación (conductividad y temperatura), se ha usado una muy particular estrategia para capturar los datos de operación de la planta desalinizadora.

Dado que la planta opera en régimen variable y su diseño permite la operación con uno o dos tubos de presión en paralelo, el proceso de recolección de datos ha de adaptarse a dicha forma de operación y cubrir el mayor rango operativo posible, Fig. 4.1. Por ello se procede de la siguiente manera:

1. Se configuró la planta para operar manualmente, alimentándose de la red eléctrica, con un solo tubo de presión.
 - a) Se estableció, de forma manual, un caudal de alimentación fijo, cuyo primer valor estaba entorno a $1 \text{ m}^3/\text{h}$ (el mínimo valor registrado fue $0.96 \text{ m}^3/\text{h}$), y se fue ajustando manualmente la presión a la entrada de las membranas hasta lograr una tasa de recuperación ente 13.5 % y 13.6 %.
 - b) Para ese punto operativo fijo, se variaron: la conductividad, entre valores comprendidos en el rango [$45032 \text{ }\mu\text{S}/\text{cm}$, $52875 \text{ }\mu\text{S}/\text{cm}$], y la temperatura del agua de entrada a las membranas, entre valores comprendidos en el rango [20.61°C , 26.70°C]¹.
 - c) Se fue incrementando el caudal en $0.5 \text{ m}^3/\text{h}$ y se repitieron los pasos a), b) y c) hasta llegar al máximo caudal admisible para la configuración de

¹Los rangos de conductividad y temperatura empleados abarcan los valores históricos obtenidos de las múltiples analíticas de agua de mar tomadas en la zona, tal y como se especificó en el apartado 4.2.

un sólo tubo ($3.00 \text{ m}^3/\text{h}$, aunque el máximo valor real registrado fue $3.07 \text{ m}^3/\text{h}$), Fig. 4.1.

2. Se configuró la planta para operar manualmente, alimentándose de la red eléctrica, con dos tubos de presión.
 - a) Se estableció, de forma manual, un caudal de alimentación fijo, cuyo primer valor estaba entorno a $3 \text{ m}^3/\text{h}$ (el mínimo valor registrado fue $3.04 \text{ m}^3/\text{h}$), y se fue ajustando manualmente la presión a la entrada de las membranas hasta lograr una tasa de recuperación ente 13.5% . y 13.6% .
 - b) Para ese punto operativo fijo, se variaron: la conductividad, entre valores comprendidos en el rango [$46395 \mu\text{S}/\text{cm}$, $55626 \mu\text{S}/\text{cm}$], y la temperatura del agua de entrada a las membranas, entre valores comprendidos en el rango [$19,88^\circ\text{C}$, $26,18^\circ\text{C}$]¹.
 - c) Se fue incrementando el caudal en $0.5 \text{ m}^3/\text{h}$ y se repitieron los pasos a), b) y c) hasta llegar al máximo caudal admisible para la configuración de dos tubos ($6 \text{ m}^3/\text{h}$, aunque el máximo valor real registrado fue $6.13 \text{ m}^3/\text{h}$), Fig. 4.1.

Para cada punto se registraron, con una frecuencia de 1 Hz, los valores instantáneos de caudal, presión, conductividad, temperatura y potencia consumida por la planta. Así, como resultado, se obtuvo un conjunto bruto de datos que, tras un filtrado y un tratamiento adecuado, quedó dividido en dos tablas Tabla 6.1 . La primera de ellas contiene los datos de operación con un único tubo de presión y está compuesta por 5 columnas (caudal, presión, conductividad, temperatura y potencia consumida) y 505 filas, correspondientes a las diferentes combinaciones de valores que tomaron las variables en esta configuración (Tabla 6.1). La segunda también la componen 5 columnas pero 692 filas, correspondientes a los distintos valores que tomaron las variables al operar con dos tubos de presión (Tabla 6.1).

6.3.2 Selección, entrenamiento y evaluación de los modelos ANN

Con cada técnica, se construyen cuatro modelos agrupados en parejas. Dos de ellos se ajustan para generar las consignas de presión y de caudal cuando la planta

Tabla 6.1: Muestra de datos registrados al operar la planta desalinizadora de OI con uno y dos tubos de presión. Estos datos fueron usados para llevar a cabo el entrenamiento, la validación y el ensayo de los modelos ANN empleados (*)

Un tubo de presión						Dos tubos de presión					
Fila	Cond.	Temp.	Pot.	Pres.	Caudal	Fila	Cond.	Temp.	Pot.	Pres.	Caudal
Nº	($\mu\text{S}/\text{cm}$)	($^{\circ}\text{C}$)	(kW)	(bar)	(m^3/h)	Nº	($\mu\text{S}/\text{cm}$)	($^{\circ}\text{C}$)	(kW)	(bar)	(m^3/h)
1	47645	23.45	1.84	33.43	1.05	1	47798	21.29	4.11	36.35	3.06
2	45032	20.91	1.84	33.34	0.97	2	47251	24.93	4.12	35.25	3.07
3	47763	23.44	1.85	33.38	1.04	3	46688	23.28	4.19	35.55	3.04
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
9	47645	23.54	1.87	33.27	0.98	171	55360	20.39	5.77	43.31	3.53
10	47645	23.43	1.87	33.33	1.04	172	55626	20.56	5.78	43.33	3.51
11	51611	23.98	1.87	34.08	1.00	173	47557	23.32	5.79	38.70	4.10
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
32	51241	26.45	2.09	38.11	0.96	318	51667	19.88	7.53	44.60	4.54
33	53732	24.36	2.09	38.57	1.07	319	47167	24.89	7.55	40.65	5.04
34	53813	24.11	2.09	37.76	1.01	320	54781	21.06	7.56	46.15	4.52
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
76	47298	20.61	2.63	37.13	1.50	383	53215	26.18	8.36	45.43	5.07
77	50507	21.45	2.68	39.47	1.49	384	53215	25.89	8.36	45.19	5.03
78	50668	21.28	2.69	39.76	1.52	385	52824	25.81	8.36	45.41	5.05
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
100	51206	26.70	2.83	40.38	1.50	550	46935	22.79	9.86	45.08	6.08
101	53132	26.18	2.83	40.33	1.50	551	46395	22.71	9.87	44.83	5.97
102	51206	26.38	2.84	40.38	1.51	552	47323	22.81	9.87	44.92	6.02
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
110	52875	26.23	2.88	40.16	1.46	682	53523	20.66	10.96	50.68	6.13
111	51133	26.23	2.90	40.20	1.47	683	52832	20.93	10.96	50.40	6.05
112	54180	20.75	2.98	42.33	1.49	684	53523	21.14	10.96	50.79	6.08
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
503	53655	21.21	6.21	52.83	3.03	690	52832	20.72	11.05	50.59	6.07
504	53239	21.09	6.22	53.09	3.07	691	52832	20.99	11.06	50.63	6.07
505	53239	21.11	6.22	52.77	2.97	692	52832	20.96	11.07	50.41	6.07

(*) Los números en negrita indican los valores mínimos y máximos registrados para las cinco variables.

opera con un sólo tubo de presión, empleando para ello los datos correspondientes a un tubo mostrados en la Tabla 6.1. Los otros dos, hacen lo mismo pero para aquellas situaciones en las que la planta trabaja con los dos tubos de presión conectados. Para ello, emplean los datos correspondientes a dos tubos de presión mostrados en la Tabla 6.1.

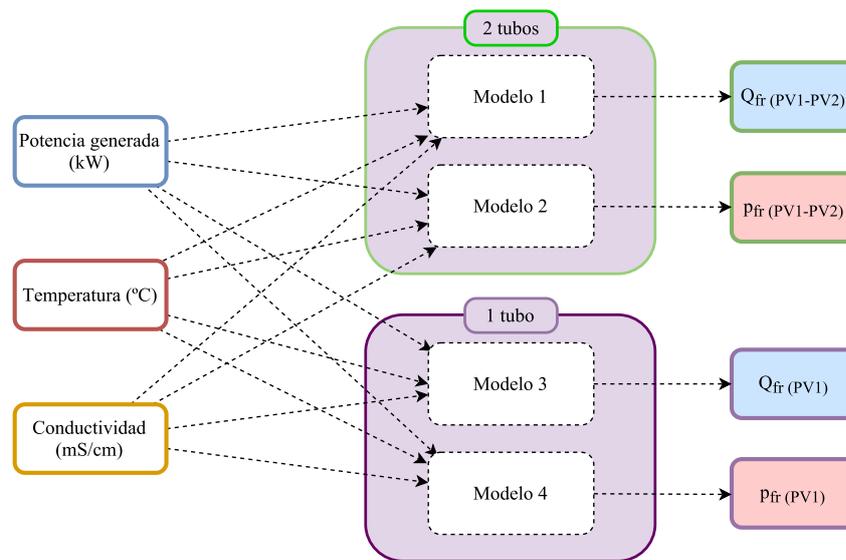


Fig. 6.4: Entradas, salidas y datos de entrenamiento de los cuatro modelos de cada técnica de *Machine Learning* implementado.

En la Fig. 6.4, se muestra un esquema de las entradas, salidas y datos de entrenamiento que alimentan a cada modelo implementado. Se observa que todos los modelos utilizan las mismas variables (potencia, temperatura y conductividad del agua de mar) pero se diferencian por las salidas, por los datos de entrenamiento que emplea cada uno y por el modo de operación en el cual se utiliza cada modelo.

6.3.2.1 Arquitectura de la red neuronal seleccionada

En primer lugar, dada la gran tradición y la capacidad de uso que tienen las ANNs con múltiples capas para resolver problemas multivariable lineales y no-lineales, se ha empleado esta técnica de Machine Learning para resolver el problema planteado. Del amplio abanico de posibles tipos de Redes Neuronales existen-

tes, se emplea la topología del MLP prealimentado, para crear los cuatro modelos que se pretenden implementar.

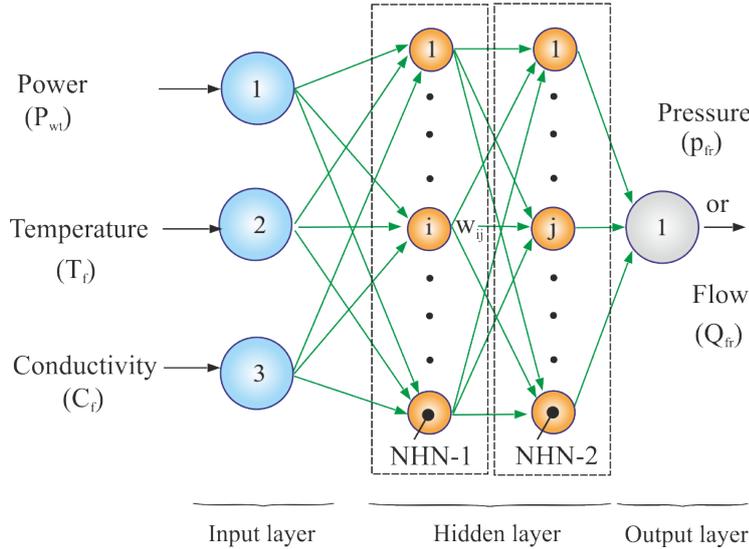


Fig. 6.5: Diagrama esquemático de la arquitectura de red neuronal empleada, con tres neuronas en la capa de entrada, dos capas ocultas (con NHN-1 y NHN-2 número de neuronas, respectivamente) y una neurona en la capa oculta (presión de referencia o caudal de referencia).

La arquitectura de partida utilizada en los modelos de este trabajo corresponde a una topología *feed-forward MLP* con una capa de entrada, dos capas ocultas y una capa de salida. La capa de entrada dispone de tres neuronas y cada una de ellas lee independientemente la temperatura del agua de mar, la conductividad del agua de mar y la potencia consumida por la planta durante el registro de datos. Estas entradas se multiplican por unos pesos w_{ij} , se le suman una unidad bias y los resultados se distribuyen hacia las neuronas que componen la primera capa oculta. De igual manera se repite el proceso y se distribuyen los nuevos valores resultantes de esta primera capa oculta hacia las neuronas de la segunda capa oculta. Finalmente, los valores resultantes de la segunda capa oculta se distribuyen hacia la capa de salida, que tendrá una única salida en cada modelo, Fig. 6.5.

El entrenamiento de los modelos es supervisado, es decir, conociendo el resultado que se quiere obtener por la capa de salida se actualizan todos los pesos

sinápticos w_{ij} ² de las neuronas para que, con las variables introducidas por la capa de entrada, se logre el mínimo error entre el resultado esperado y el obtenido por la red neuronal. Este proceso se realiza empleando el algoritmo de entrenamiento *Rprop*, detallado más adelante.

Respecto al número de capas ocultas utilizadas, se puede apuntar que, teóricamente, no hay razón para usar más de dos capas [181]. De hecho, para la mayoría de problemas, no hay razones teóricas que justifiquen el uso de más de una capa oculta [181, 182]. Las redes neuronales que poseen dos capas ocultas pueden generar regiones de decisión arbitrarias capaces de ajustar los resultados de un modelo mediante regiones de decisión no-convexas y disjuntas [151].

Sin embargo, el número de capas ocultas y neuronas que necesita un MLP para resolver un problema de ingeniería concreto parece una cuestión en la que se requieren múltiples ensayos [143]. En trabajos publicados previamente en los que se emplean estos modelos para simular procesos de OI, generalmente se usan una [16–18, 130, 142] y dos [14, 16, 17, 130, 146] capas ocultas de neuronas. Incluso, algún autor utiliza de forma excepcional hasta 20 capas ocultas [146]. Teniendo esto presente, el estudio desarrollado en este trabajo se centra en el análisis de arquitecturas de ANNs con una y dos capas ocultas, con el objetivo de determinar el número óptimo de neuronas en cada una de las capas ocultas.

6.3.2.2 Métricas utilizadas para evaluar los diferentes modelos estudiados

Para realizar una evaluación de los modelos precisa y rigurosa desde el punto de vista estadístico, es necesario recurrir a métricas que permitan cuantificar el error de forma absoluta y relativa.

Las métricas empleadas para evaluar los modelos de ANN propuestos son: el error absoluto medio (MAE - *mean absolute error*) y el error absoluto medio porcentual (MAPE - *mean absolute percentage error*)

²Los pesos sinápticos (w_{ij}) definen la fuerza de la conexión sináptica entre dos neuronas, la neurona pre-sináptica i y la neurona post-sináptica j . Estos pesos pueden tomar valores positivos, negativos o nulos. Un peso positivo actúa como excitador mientras que un peso negativo actúa como inhibidor. En el caso de que el peso sea nulo, no hay comunicación entre la pareja de neuronas.

El MAE lo define la Ec.(6.1), donde los n valores estimados por los modelos quedan representados por la letra « e » y los n valores observados por la letra « o ».

$$MAE = \frac{\sum_{i=1}^n |e_i - o_i|}{n} \quad (6.1)$$

Con el MAE, todos los tamaños de error se tratan de manera uniforme, según su magnitud. Esta métrica se expresa en las mismas unidades que usan los parámetros que se comparan.

El MAPE se define por la Ec.(6.2)

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{e_i - o_i}{o_i} \right| \quad (6.2)$$

Esta última es una métrica relativa que expresa el error como un porcentaje del dato observado.

6.3.2.3 Proceso de diseño, optimización y evaluación de las redes neuronales seleccionadas

La búsqueda de la arquitectura de ANN apropiada lleva consigo el entrenamiento y autoajuste de los pesos de la ANN. Para ello se utiliza el algoritmo heurístico de entrenamiento supervisado *Rprop* (*Resilient backpropagation algorithm*), Fig. 6.6, [158]. Este algoritmo es, junto con el algoritmo de correlación en cascada y el algoritmo Levenberg–Marquardt, uno de los más rápidos actualizando los pesos de una red neuronal y se considera como uno de los métodos de entrenamiento más eficientes para redes neuronales con topologías arbitrarias [183].

Para resolver el problema de optimización que supone la búsqueda de los pesos adecuados de una red neuronal, el algoritmo *Rprop* actúa independientemente en cada peso y tiene en cuenta solamente las derivadas parciales del error total respecto al peso correspondiente (no tiene en cuenta la magnitud del error) [158]. Para cada peso, se comprueba en cada iteración si cambia el signo en la derivada parcial de la función de error respecto a su valor en la iteración anterior. Si existe cambio de signo, se multiplica el valor del peso por un factor η^- , donde $\eta^- < 1$. Si la última iteración produce el mismo signo, la actualización del peso se multiplica por un

factor η^+ , donde $\eta^+ > 1$. Finalmente, se actualiza cada peso sumando o restando la multiplicación anterior, de forma inversa al signo de su derivada parcial. Con ello se busca compensar o minimizar el error total. El autor del algoritmo recomienda utilizar por defecto $\eta^+ = 1,2$ y $\eta^- = 0,5$. Para un mayor nivel de detalle, puede estudiarse el pseudo-código del algoritmo en el trabajo publicado por Riedmiller y Braun [184].

Uso de Algoritmos Genéticos

Para terminar de diseñar y optimizar cada una de las redes neuronales utilizadas no sólo es necesaria una topología, como la señalada en apartados anteriores, sino que también es necesario especificar el número de neuronas en cada capa y el ajuste óptimo de los pesos correspondientes a cada neurona.

Proceso de búsqueda del número de neuronas óptimo para cada capa de cada modelo de ANN empleado

Con respecto a la búsqueda del número de neuronas óptimo en cada capa, hay que mencionar que, en esta tesis, el número de neuronas de la capa de entrada así como el de la capa de salida viene impuesto por el número de variables de entrada y de salida utilizadas (ver Fig. 6.5). Esto se debe a que, para cada uno de los cuatro modelos de ANN desarrollados, siempre se utilizan las mismas variables de entrada y salida (Fig. 6.4). Por este motivo, se simplifica el trabajo de optimización que se realiza en este apartado y se centra la búsqueda en el número óptimo de neuronas de cada capa oculta.

Por otra parte, tal y como se dijo anteriormente hay que tener en cuenta que, la búsqueda del número óptimo de neuronas queda supeditada al proceso de ajuste óptimo de los pesos sinápticos de cada neurona, ya que cada propuesta de modelo de ANN debe ser previamente entrenada (ajuste de pesos) y evaluada (validación de resultados) para poder comprobar si se trata de la configuración que dispone del número de neuronas óptimo.

Todo este proceso descrito en este apartado se lleva a cabo implementando un Algoritmo Genético (AG) mediante el cual, partiendo de un número inicial de neu-

ronas en cada capa oculta, se entrena y se evalúa cada arquitectura iterativamente hasta lograr una configuración óptima (Fig. 6.6).

Uso de algoritmos genéticos para la búsqueda del número óptimo de neuronas

Los algoritmos genéticos están inspirados en las leyes de la evolución natural descritas por Darwin. Y, al igual que ocurre en la Teoría de la Evolución Natural, los algoritmos genéticos emplean unos operadores de selección, mutación y cruce para seleccionar los individuos (soluciones) mejor adaptados y proceder a la reproducción de la cual se obtienen nuevas generaciones de individuos (soluciones) mejor capacitadas que las anteriores para resolver el problema planteado [185].

Más específicamente, en este trabajo se utiliza un AG pensado para la optimización de problemas cuyas variables sean de tipo mixto. Es decir, problemas compuestos por variables de tipo real y/o de tipo entero. El algoritmo empleado fue desarrollado por Deep et. al y se llama MI-LXPM [184]. Usa las funciones *Laplace Crossover* y *Power Mutation* desarrolladas por Deep y Thakur en [186] y [187], respectivamente. Para su ejecución, se utiliza la implementación de la función *ga* de la *Matlab's Global Optimization Toolbox* [188]. El proceso global de búsqueda que sigue el AG empleado para obtener la configuración de red neuronal óptima se representa en la Fig. 6.6 y puede resumirse de la siguiente manera:

1. En primer lugar, el AG genera una *población* inicial compuesta por 40 *individuos* («1» en Fig. 6.6). Esta *población* inicial no es más que un conjunto de varias soluciones (*individuos*) generadas aleatoriamente³ que representan, cada una, una propuesta de configuración óptima de modelo de ANN. Por tanto, cada solución (o «*individuo*») de una «*población*» (o conjunto de soluciones) está compuesta por un «*código genético*» de dos números enteros: i) el número de neuronas óptimo de la primera capa oculta y ii) el número de neuronas óptimo en la segunda capa.

Los valores que puede tomar el número de neuronas de la primera capa oculta se restringen a los números enteros que se encuentran dentro del rango [2,

³La *población* inicial se genera siguiendo una distribución aleatoria uniforme usando la función *@gacreationuniform* de la *Matlab's Global Optimization Toolbox* [188]

150]. Análogamente, en la segunda capa, el número de neuronas sólo puede ser un número entero entre 0 y 150. De esta manera, se permite que el AG pueda obtener una solución óptima en la que sólo haya una única capa oculta. Es decir, una solución en la que el número de neuronas en la primera capa oculta esté entre 2 y 150 y el número de neuronas en la segunda capa oculta sea 0.

2. Con el nuevo conjunto de posibles soluciones óptimas generado («población actual»), se evalúan todas las soluciones de forma independiente aplicando validación cruzada. Esta técnica, ampliamente aceptada en la comunidad de la Minería de Datos [143], permite la evaluación de cada modelo evitando un sobreajuste del mismo en los datos. La validación cruzada se ejecutó subdividiendo los datos en diez partes (*10-folds*). Es decir, usando los datos registrados según el proceso descrito en el apartado 6.3.1:

- a) se subdivide el conjunto total de datos en diez subconjuntos disjuntos y de tamaño similar. Esto se realiza mediante la función *cvpartition* de la *Matlab's Statistics and Machine Learning Toolbox* [174].
- b) Se ejecuta un bucle diez veces para escoger, en cada iteración, uno de estos diez subconjuntos de datos y usarlo como «subconjunto *test*». Este subconjunto, que contiene una décima parte de los datos de entrada y de salida observados durante el proceso descrito en el apartado 6.3.1, se reserva para validar el modelo. El resto de datos se agrupan formando el «subconjunto de entrenamiento».
- c) En cada iteración del bucle anterior, se van cambiando los subconjuntos «*test*» y «entrenamiento» para entrenar y validar una de las arquitecturas de red neuronal propuesta por el AG con datos diferentes.

De esta manera, para un mismo número de capas ocultas e igual número de neuronas en cada capa, se realizan diez entrenamientos distintos usando los diez posibles subconjuntos de entrenamiento obtenidos anteriormente.

El entrenamiento de cada modelo se lleva a cabo mediante la función *fitnet* de Matlab [159], configurada para usar el algoritmo de entrenamiento *Rprop* detallado anteriormente. Para ello, se aplicó la filosofía de «*early-stopping*» que se detalla a continuación:

- c.I) se vuelven a subdividir los datos del «subconjunto de entrenamiento» en dos bloques (un nuevo conjunto de entrenamiento, que representa un 90 % de dichos datos, y un nuevo conjunto llamado de validación, que representa un 10 % de los datos);
 - c.II) se ejecuta el algoritmo *Rprop* descrito anteriormente;
 - c.III) y se detiene el proceso de entrenamiento cuando se produce alguna de las siguientes circunstancias: a) el error obtenido por el nuevo conjunto de entrenamiento disminuye y el error obtenido por el conjunto de validación se incrementa durante seis iteraciones consecutivas; b) el número de iteraciones en el proceso de entrenamiento alcanza el valor de 1000; o c) se alcanza un error de ajuste menor que el mínimo establecido ($MSE = 10^{-4}$).
- d) Los «suconjuntos *test*» obtenidos sirven para que, en cada iteración, pueda obtenerse una medida de ajuste entre el resultado del modelo y el resultado real. En dicho subconjunto se separan las variables de entrada de las variables de salida.

Las variables de entrada se emplean para simular el modelo entrenado previamente obteniendo unos resultados estimados a partir de dichas entradas. Estos resultados se etiquetan como «*datos estimados*».

Las variables de salida de los «suconjuntos *test*» se reservan y se etiquetan como «*datos observados*»,

- e) En cada iteración se calcula un error parcial que especifica el nivel de ajuste que tiene la arquitectura analizada con los datos correspondientes a cada subdivisión (Fig. 6.6).

Es decir, en total, aparte de entrenar diez veces el mismo modelo y obtener así diez configuraciones de pesos diferentes que usan diez subconjuntos de datos de entrenamiento distintos, también se simula el modelo

diez veces usando los datos reservados del «subconjunto *test*» y obteniendo una medida de error por iteración. Como resultado de la validación cruzada, se obtienen diez errores parciales cometidos por la misma configuración de red neuronal (MAE_1, \dots, MAE_{10}) y ($MAPE_1, \dots, MAPE_{10}$) (Fig. 6.6).

f) Se calcula el valor medio de cada métrica \overline{MAE} , \overline{MAPE} .

Asimismo, puede utilizarse la varianza de los 10 muestras parciales de error obtenidas para estimar la variabilidad de estas medias parciales y, por tanto, determinar la estabilidad del comportamiento ante nuevos datos.

3. El valor medio de cada métrica se utiliza como valor comparativo entre cada una de las soluciones («individuos») de la «población» generada por el AG. Cada individuo de la población se asocia a un error y se ordena en función de ese error.
4. Se seleccionan los 40 individuos con mejor rendimiento utilizando la técnica de selección por torneo (función *@selectiontournament* de la Global Optimization Toolbox de Matlab [188]).
5. Se ejecutan los operadores de cruce (*Laplace Crossover*) y mutación (*Power Mutation*). Con el operador de cruce se combinan los distintos individuos dos a dos generando nuevos individuos y con el operador de mutación se seleccionan aleatoriamente varios individuos y se les cambia su codificación. Esto da lugar a una nueva «generación».
6. El AG (función *ga* de la Global Optimization Toolbox de Matlab [188]) chequea los valores de error cometidos por cada individuo \overline{MAE} y detiene la ejecución si se cumplen alguno de los siguientes criterios (Fig. 6.6): a) el número de generaciones (o iteraciones) alcanza el valor de 200, b) el valor medio del error cometido por todos los individuos de la población \overline{MAE} se estabiliza variando menos de 10^{-4} .
7. Si no se produce ninguno de estos eventos, se repite el proceso volviendo al punto número 2.

6.3.3 Aplicación experimental de los modelos ANN seleccionados

A continuación, se detalla el procedimiento experimental llevado a cabo para analizar rigurosamente la capacidad que tienen las Redes Neuronales para lograr el objetivo planteado.

Se pretende medir el grado de ajuste logrado por el sistema de control (al cual se le han integrado los modelos de ANN diseñados) al regular la potencia consumida por la planta desalinizadora e intentar igualarla a una variación de potencia eléctrica aleatoria. Para ello, se diseñan cuatro ensayos experimentales diferentes en los cuales se utiliza la misma secuencia de valores de entrada al proceso (misma serie de datos de viento escalonado por saltos aleatorios cambiantes cada dos minutos). La principal diferencia entre los cuatro ensayos radica en la variación de las características del agua de alimentación. Siguiendo la nomenclatura empleada por Montgomery [189], se utiliza un tipo de experimentación *factorial fraccionado* en la que se cambian varios factores en conjunto y sólo se ensayan algunos de ellos. En este caso, los factores a variar son:

- el factor de características del agua de mar (Fig. 6.7), que está compuesto por dos factores combinados (factor de temperatura del agua de mar y factor de conductividad del agua de mar). Este factor conjunto tiene cuatro niveles $NL=4$ (L-1, L-2, L-3 y L-4) donde cada nivel combina un rango acotado de temperatura y un rango acotado conductividad (ver Tabla 6.2)

Tabla 6.2: Factor de características de agua de alimentación

Niveles	Intervalo de temperatura (°C)	Intervalo de conductividad ($\mu S/cm$)
L-1	20.03-21.15	55440-56360
L-2	21.08-22.28	52730-53600
L-3	22.80-23.92	50460-50990
L-4	24.34-25.23	47280-47810

- y, el factor de potencia operativa de referencia, definido por 16 bloques de potencia (Tabla 6.3). Estos bloques tratan de representar a las potencias que deben ser consumidas por la planta o, en otras palabras, potencias que se supone que son generadas por la turbina eólica Vergnet GEV10/15 [98]). Se

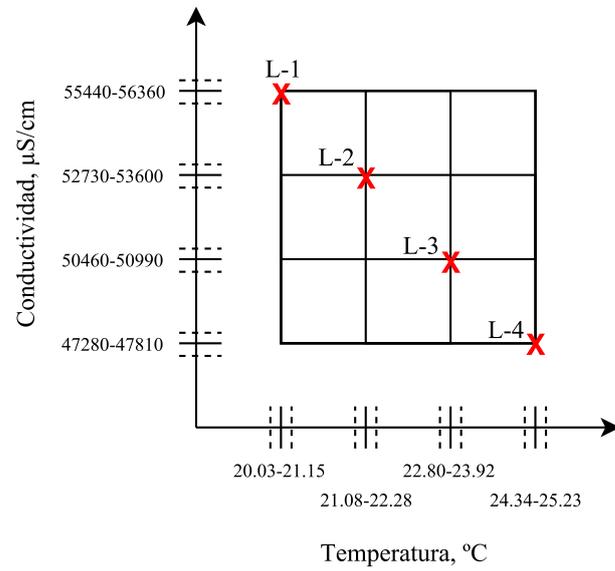


Fig. 6.7: Factor de características del agua de alimentación.

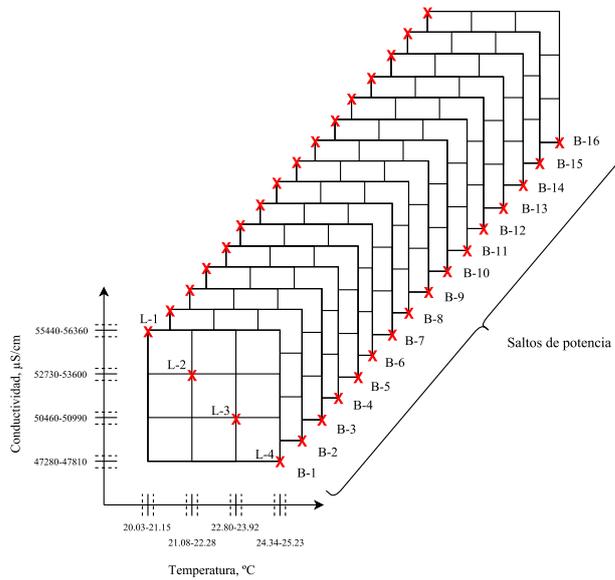


Fig. 6.8: Factor de características del agua de alimentación y factor de potencias de operación de referencia.

denominan B-1, B-2, ..., B-16, (Fig. 6.8) y se obtuvieron a partir de una muestra aleatoria⁴ de la cual se obtuvieron 16 valores que cumplían el requisito de estar dentro del rango operativo de la planta (2-11 kW) (Tabla 6.3) para el lugar de donde se encuentra actualmente instalada (Fig. 6.9).

Tabla 6.3: Factor de potencias de referencia

Bloques	Velocidades de viento (m/s)	SD (m/s)	Potencia de salida (kW)	PD (kW)
B-1	9.29	9.29	9.42	9.42
B-2	8.23	-1.05	7.15	-2.26
B-3	9.27	1.04	9.38	2.23
B-4	7.37	-1.90	5.24	-4.14
B-5	7.72	0.36	6.05	0.81
B-6	6.58	-1.14	3.38	-2.67
B-7	6.28	-0.30	2.65	-0.73
B-8	8.02	1.74	6.69	4.04
B-9	8.32	0.30	7.34	0.65
B-10	7.34	-0.98	5.17	-2.16
B-11	9.31	1.97	9.46	4.29
B-12	7.32	-1.99	5.12	-4.34
B-13	9.02	1.71	8.84	3.72
B-14	9.07	0.05	8.94	0.10
B-15	7.55	-1.52	5.66	-3.28
B-16	6.98	-0.57	4.33	-1.32

SD: Diferencias consecutivas de velocidades de viento.

PD: Diferencias consecutivas de potencias de referencia.

De acuerdo con el estudio llevado a cabo en el apartado 4.4, los cambios más frecuentes de velocidad eólica son de 0.0-0.5 m/s y 0.5-1.0 m/s, según las medias minutas de velocidades de viento registradas a 20 m. de altura sobre el nivel del mar en el lugar donde está instalado el prototipo. Los cambios en la velocidad de 1.5-2.0 m/s se dan con una frecuencia muy baja. Sin embargo, tal y como se observa en la Tabla 6.3, los bloques de saltos eólicos utilizados provocaron variaciones eólicas consecutivas de toda índole. Pueden observarse cambios consecutivos de 0.05

⁴La muestra aleatoria de viento se obtuvo utilizando la función de distribución de velocidad de viento que representa el régimen de viento en la localización del prototipo

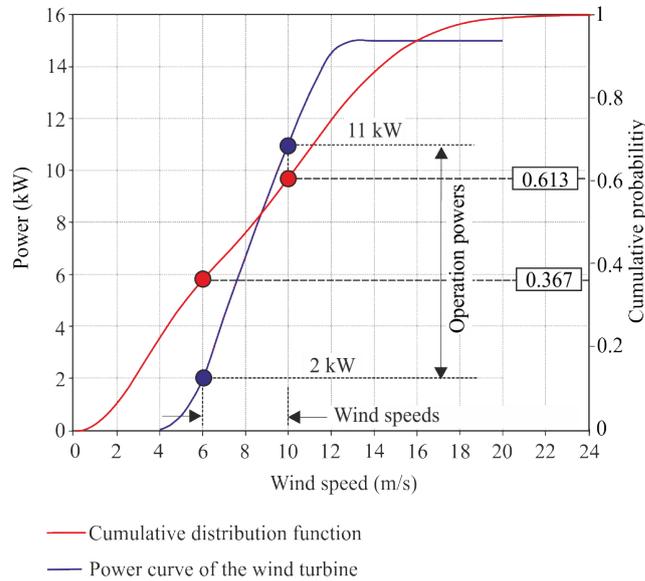


Fig. 6.9: Obtención de la muestra aleatoria de potencias operativas usando la función de distribución de viento que representa el régimen eólico en la localización del prototipo.

m/s hasta 9.29 m/s, que suponen variaciones de potencia de 0.1-9.42 kW. Estas variaciones aleatorias permiten analizar de una forma extremadamente rigurosa el funcionamiento de la planta, sometiéndola a cambios bruscos y a un amplio rango de circunstancias de operación, permitiendo así el análisis de los errores cometidos al operar con un solo tubo de presión, con dos tubos en paralelo y cuando se producen las conexiones y desconexiones del segundo tubo.

El análisis determinista llevado a cabo se realizó empleando las métricas MAE y MAPE definidas anteriormente. En cada bloque, se compara la potencias de referencia P_{wt} y la potencia instantánea consumida por la planta P_{RO} como consecuencia de las intervenciones que realiza el sistema de control dictadas por los modelos de ANN diseñados.

Una vez concluidos los test para cada uno de los niveles de características de agua de alimentación, se llevó a cabo un análisis de los errores MAE y MAPE generados en cada ensayo. El objetivo fue verificar la existencia o no de diferencias significativas entre los errores cometidos por los cuatro niveles del factor de características del agua de alimentación, dentro de cada uno de los bloques del factor de

potencias de referencia. El resultado permitió elaborar una serie de conclusiones sobre la capacidad que tienen las ANN desarrolladas (e implementadas en el sistema de control) para manejar las consignas operativas de la planta desalinizadora (teniendo en cuenta la variabilidad de la conductividad del agua de alimentación y de la temperatura) y conseguir adaptar la energía consumida por la planta a una amplia y aleatoria variación de la potencias eléctrica disponible.

6.4 Análisis y discusión de los resultados obtenidos

6.4.1 Análisis de los modelos ANN seleccionados

Las arquitecturas seleccionadas después de aplicar el proceso de diseño, entrenamiento y validación explicado en el apartado anterior se muestran en la Tabla 6.4. Se puede observar el número de capas ocultas de neuronas así como el número de neuronas en cada una de las capas. También en la Tabla 6.4 se indican los errores \overline{MAE} y \overline{MAPE} y sus desviaciones estándar. Es posible observar que todos los modelos disponen de dos capas ocultas y que el número de neuronas de las capas ocultas sigue una forma piramidal. El número de neuronas va decreciendo desde la primera capa hasta la segunda capa. Es decir, se cumple la regla de geometría piramidal ya expuesta previamente en la literatura científica [182]. Sin embargo, el número de neuronas no sigue la fórmula aproximada que recomienda un número de neuronas para cada capa oculta de una ANN de cuatro capas [182]. En este caso, si se empleara esta fórmula, el número de neuronas requerido se subestimaría. Esto es probablemente porque el número de entradas (tres) y salidas (una) es reducido y porque la complejidad del problema es elevada [182]. Estos resultados corroboran la ventaja de usar algoritmos genéticos en oposición al uso de una aproximación mediante fórmulas, cuando se desea seleccionar el número de neuronas en cada una de las capas ocultas de una red neuronal artificial.

Tabla 6.4: Arquitecturas de los cuatro modelos ANN seleccionados

Tubo	Variable	NHN-1	NHN-2	MAE		MAPE	
				Media	Stdev	Media	Stdev
1	Caudal	38	4	0.026 (m ³ /h)	0.005 (m ³ /h)	1.305	0.259
	Presión	56	9	0.252 (bar)	0.040 (bar)	0.579	0.098
2	Caudal	69	13	0.038 (m ³ /h)	0.005 (m ³ /h)	0.847	0.118
	Presión	71	17	0.175 (bar)	0.036 (bar)	0.405	0.084

NHN-1: Número de neuronas en la primera capa oculta;

NHN-2: Número de neuronas en la segunda capa oculta; Stdev: Desviación estándar.

6.4.2 Análisis de los errores generados en los ensayos experimentales

En la figura Fig. 6.10, para el caso del nivel L-1, se muestran los valores la potencia real consumida por la planta desalinizadora en cada instante así como los valores de las consignas de referencia de potencia a consumir por la planta (Fig. 6.10-a). También se muestran los valores de presiones reales medidas en la planta y los valores de referencia de presión calculados por las ANN (Fig. 6.10-b). Asimismo se muestran los valores de caudales de alimentación reales medidos en la planta y los valores de referencia de caudal calculados por las ANN (Fig. 6.10-c). Todos estos valores han sido obtenidos al aplicar el procedimiento descrito en la sección 6.3.3.

Además, en la Fig. 6.10-d se muestra la tasa de recuperación de permeado, en la Fig. 6.10-e los valores de caudal de permeado y rechazo obtenidos y, por último, en la Fig. 6.10-f se muestra la conductividad de permeado obtenida como consecuencia de las variaciones aplicadas en cada momento sobre las variables de caudal y presión de alimentación.

El comportamiento de estas mismas variables comentadas ha sido similar para los niveles L-2, L-3 y L-4 definidos previamente. Dichas variaciones se representan en las Fig. 6.11, Fig. 6.12 y Fig. 6.13 respectivamente. Tras una simple observación de tales variaciones para los niveles L-2, L-3 y L-4, se puede intuir que, a

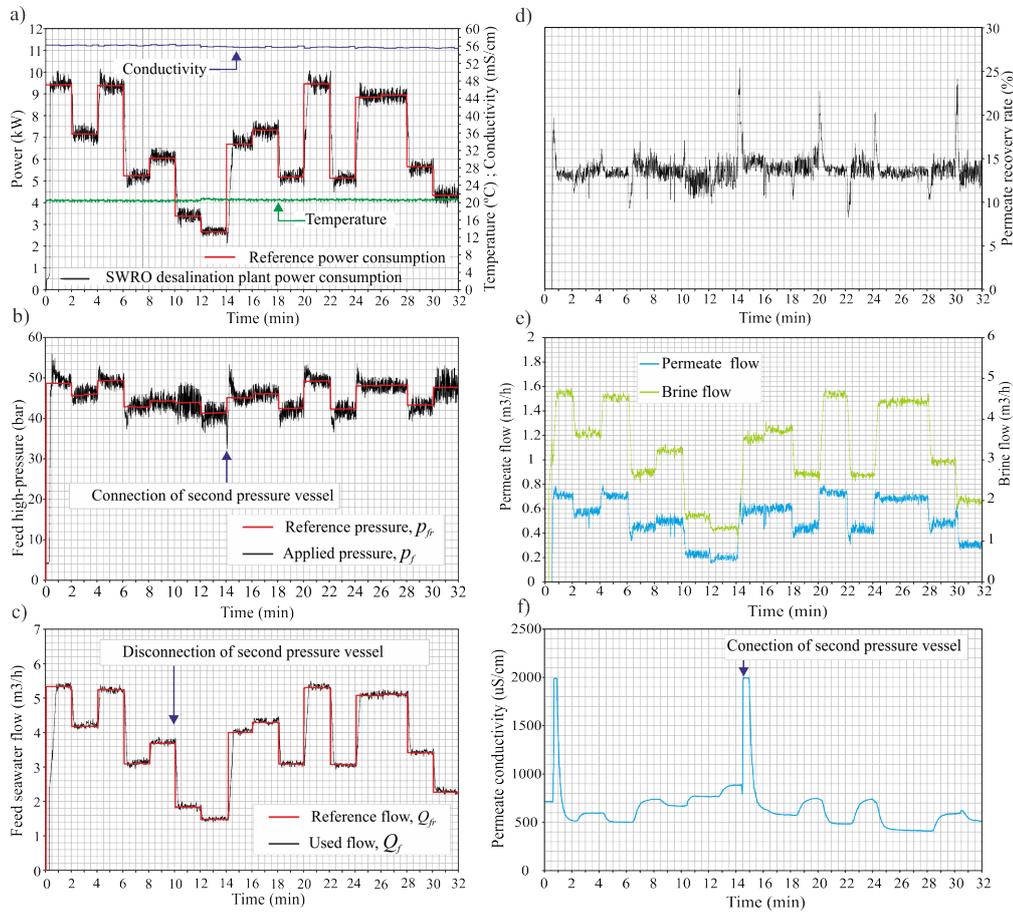


Fig. 6.10: Nivel L-1. a) Potencias consumidas de referencia y oscilaciones medidas de la potencia consumida por la planta de OI vs. tiempo de operación. b) Presiones de referencia y oscilaciones de las presiones reales medidas en la planta de OI vs. tiempo de operación de la planta. c) Caudales de referencia y oscilaciones de los caudales reales medidos en la planta de OI vs. tiempo de operación de la planta. d) Tasa de recuperación de permeado registrada para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c). e) Caudales de permeado y rechazo registrados para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c).

pesar de que las consignas son diferentes, no se aprecian diferencias entre estas y los valores obtenidos para el nivel L-1 (Fig. 6.10). Por ello, la Tabla 6.5 muestra para cada factor de bloque de potencia (B-1,...,B-16) y para cada factor de niveles de características de agua de alimentación (L-1, L-2, L-3 y L-4) las consignas de caudal y presión de operación. En esta tabla se puede ver como la red neuronal

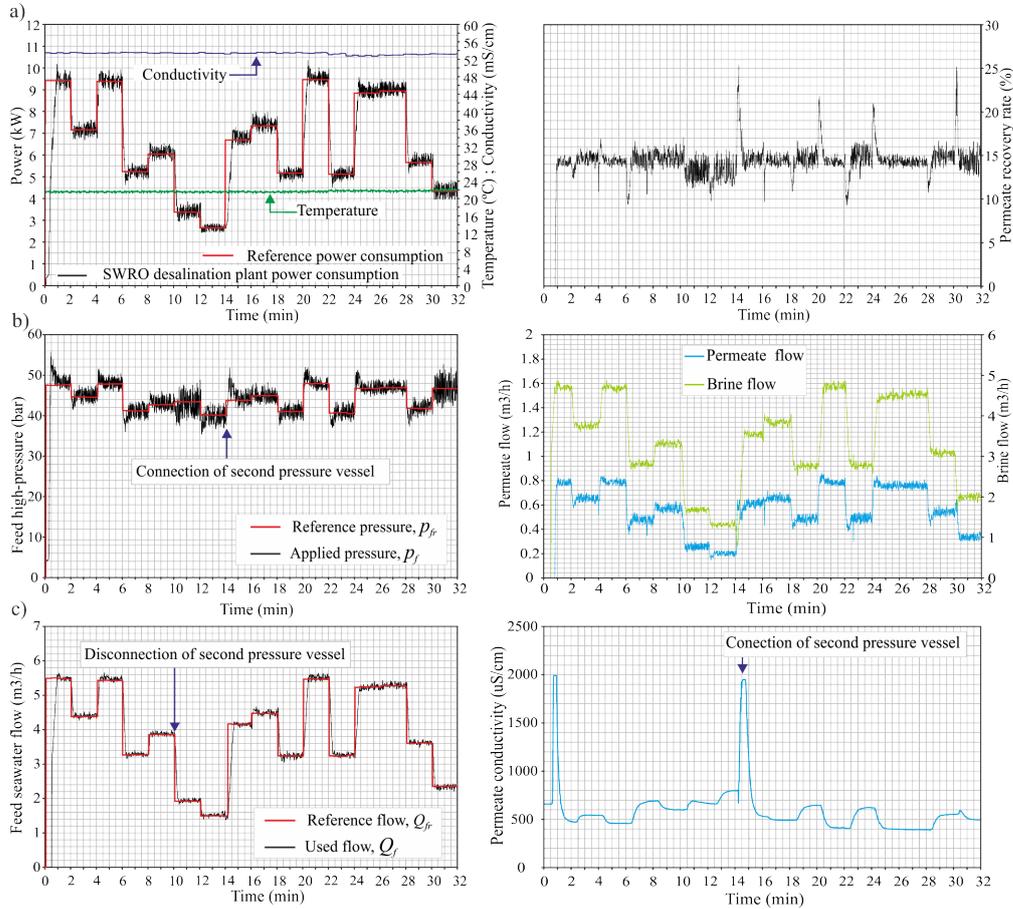


Fig. 6.11: Nivel L-2. a) Potencias consumidas de referencia y oscilaciones medidas de la potencia consumida por la planta de OI vs. tiempo de operación. b) Presiones de referencia y oscilaciones de las presiones reales medidas en la planta de OI vs. tiempo de operación de la planta. c) Caudales de referencia y oscilaciones de los caudales reales medidos en la planta de OI vs. tiempo de operación de la planta. d) Tasa de recuperación de permeado registrada para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c). e) Caudales de permeado y rechazo registrados para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c).

genera diferentes consignas para la misma potencia de referencia, dependiendo de la temperatura y de la conductividad que tenga el agua en cada momento. También en la Tabla 6.5 se muestra el consumo de energía específico de la planta desalinizadora en función de los factores de bloque de potencia y de los niveles L-1, L-2, L-3 y L-4.

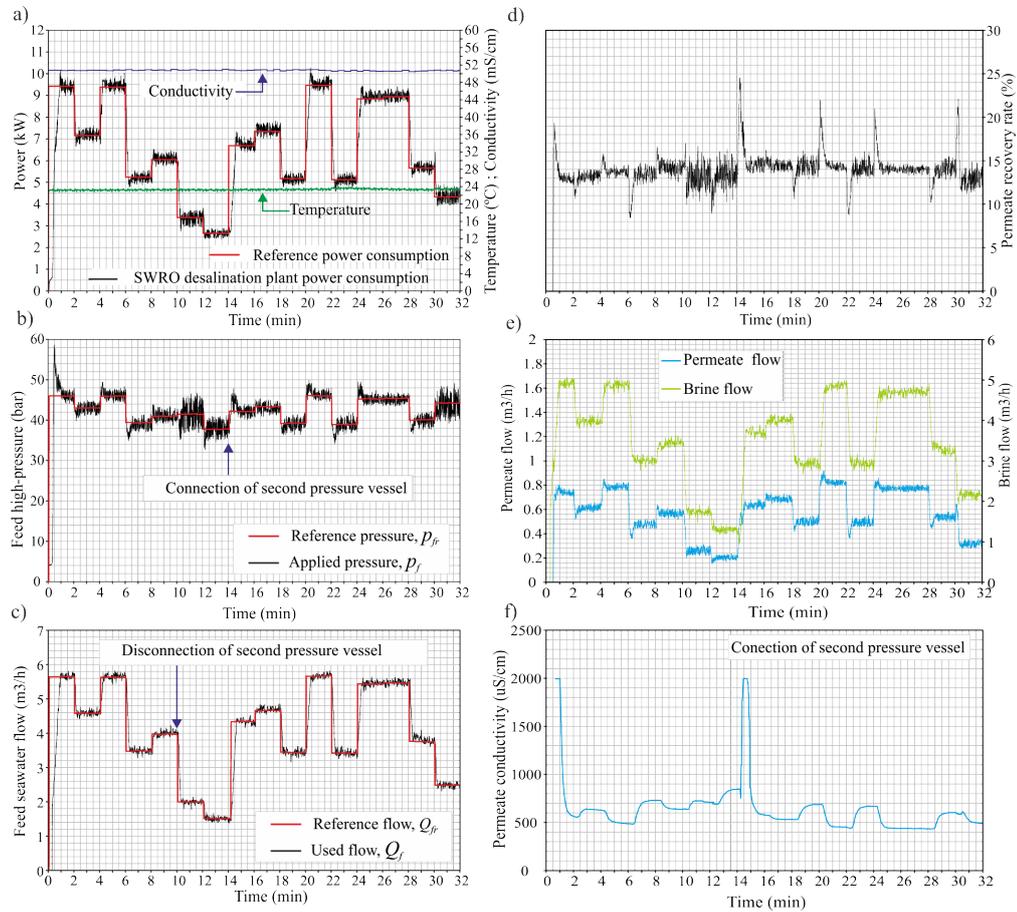


Fig. 6.12: Nivel L-3. a) Potencias consumidas de referencia y oscilaciones medidas de la potencia consumida por la planta de OI vs. tiempo de operación. b) Presiones de referencia y oscilaciones de las presiones reales medidas en la planta de OI vs. tiempo de operación de la planta. c) Caudales de referencia y oscilaciones de los caudales reales medidos en la planta de OI vs. tiempo de operación de la planta. d) Tasa de recuperación de permeado registrada para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c). e) Caudales de permeado y rechazo registrados para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c).

Tal y como se observa en la Fig. 6.10-b, las mayores desviaciones entre la presión de operación y la presión de referencia se producen en aquellos instantes en los que el sistema de control (siguiendo las órdenes de los modelos ANN) actúan sobre la válvula PSV (Fig. 6.3) para adaptar la potencia consumida a los cambios en la referencia de potencia. Después de un primer instante, la presión de operación

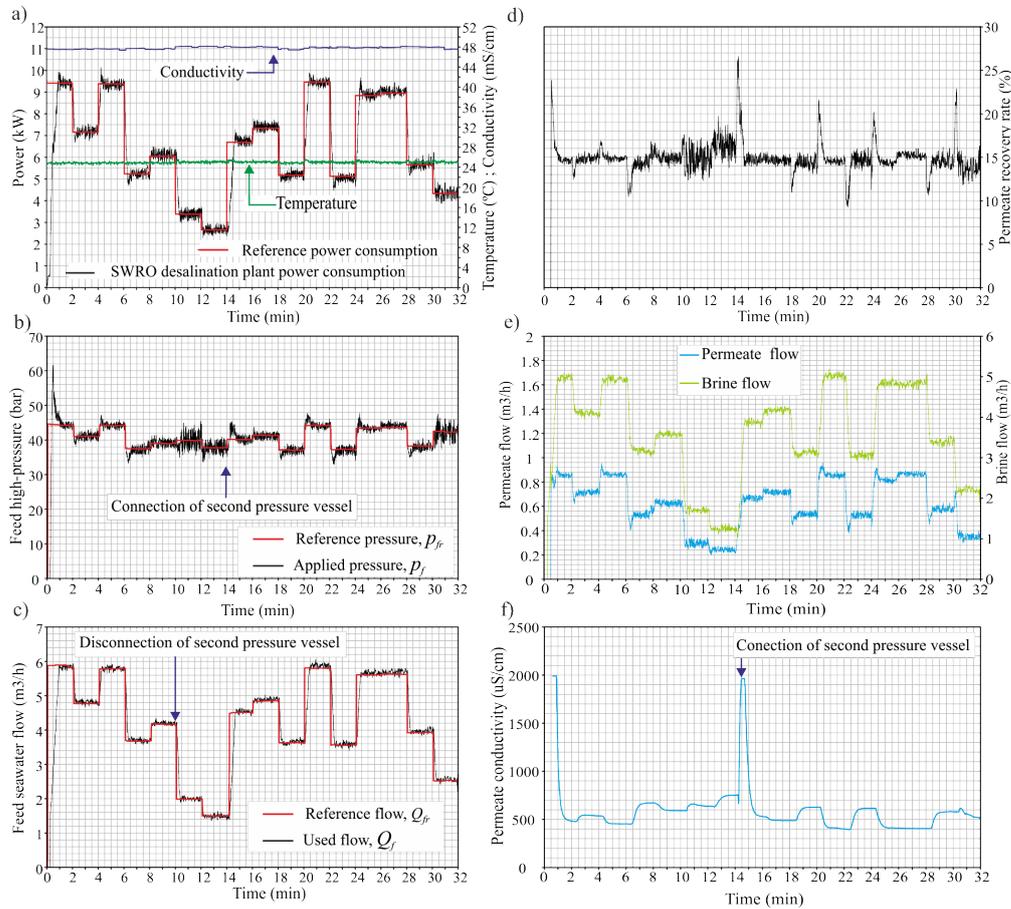


Fig. 6.13: Nivel L-4. a) Potencias consumidas de referencia y oscilaciones medidas de la potencia consumida por la planta de OI vs. tiempo de operación. b) Presiones de referencia y oscilaciones de las presiones reales medidas en la planta de OI vs. tiempo de operación de la planta. c) Caudales de referencia y oscilaciones de los caudales reales medidos en la planta de OI vs. tiempo de operación de la planta. d) Tasa de recuperación de permeado registrada para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c). e) Caudales de permeado y rechazo registrados para el tiempo en el que la planta de OI operó en las condiciones representadas en a), b) y c).

oscila respecto a la presión de referencia. La amplitud de dicha oscilación es menor cuando el caudal de alimentación es elevado. Para caudales pequeños la oscilación de presión es mayor. Estos picos instantáneos de presión son consecuencia directa de los valores asignados al controlador PID del lazo de control que regula la presión

Tabla 6.5: Consignas de presión y caudal de operación y consumo de energía específico (SEC) obtenidos cuando la planta desalinizadora opera siguiendo el procedimiento descrito en la sección 6.3.3.

Factor de potencia		Niveles del factor de características de agua de alimentación											
Bloq.	Pot. (kW)	L-1			L-2			L-3			L-4		
		Pres. (bar)	Caud. (m ³ /h)	SEC (kWh/m ³)	Pres. (bar)	Caud. (m ³ /h)	SEC (kWh/m ³)	Pres. (bar)	Caud. (m ³ /h)	SEC (kWh/m ³)	Pres. (bar)	Caud. (m ³ /h)	SEC (kWh/m ³)
B-1	9.42	48.63	5.34	13.63	47.62	5.48	12.20	45.99	5.65	12.60	44.24	5.86	10.97
B-2	7.15	45.80	4.17	12.63	44.59	4.38	11.13	43.02	4.58	11.88	41.04	4.77	10.16
B-3	9.38	49.32	5.24	13.17	47.83	5.43	11.89	45.96	5.63	11.99	44.17	5.79	10.76
B-4	5.24	42.80	3.09	12.00	41.21	3.27	11.39	39.40	3.48	11.39	37.48	3.67	10.16
B-5	6.05	44.30	3.68	12.36	42.70	3.85	10.74	40.99	3.97	10.80	39.01	4.16	9.73
B-6	3.38	43.89	1.83	14.63	43.43	1.92	12.95	41.49	2.00	12.60	39.85	1.99	11.16
B-7	2.65	41.33	1.47	13.98	40.16	1.49	13.45	37.72	1.51	13.36	37.74	1.50	11.03
B-8	6.69	45.07	4.00	11.08	43.79	4.16	10.73	42.17	4.34	10.28	40.13	4.51	9.99
B-9	7.34	46.06	4.29	12.27	44.93	4.47	11.47	43.34	4.66	10.79	41.31	4.85	10.34
B-10	5.17	42.48	3.08	12.01	41.03	3.24	10.86	39.24	3.44	10.46	37.12	3.63	9.85
B-11	9.46	49.23	5.30	12.57	47.89	5.47	11.83	46.00	5.67	11.29	44.19	5.80	10.68
B-12	5.12	42.32	3.07	12.29	40.70	3.24	11.00	38.96	3.42	10.86	37.22	3.56	9.99
B-13	8.84	48.04	5.07	12.78	46.73	5.24	11.52	45.27	5.43	11.31	43.41	5.60	10.63
B-14	8.94	48.19	5.11	13.02	46.93	5.27	11.89	45.41	5.47	11.59	43.58	5.62	10.42
B-15	5.66	43.31	3.41	11.90	41.76	3.61	10.86	40.10	3.75	10.84	38.24	3.92	10.08
B-16	4.33	47.65	2.27	13.60	46.72	3.36	12.49	44.23	2.48	13.12	42.39	2.53	11.87

y que fue implementado en el PLC que controla al sistema (Fig. 6.3).

En la Fig. 6.14 se observa un histograma y un digrama de bigotes de los valores instantáneos de tasa de recuperación de permeado obtenidos en los cuatro ensayos realizados. Se puede observar que la media (14.22 %), la moda (14.24 %) y la mediana (14.18 %) son prácticamente la misma y que el rango intercuartílico es 1.44 %. Esta tasa de recuperación de permeado presenta un incremento de un 4.94 % con respecto al valor de tasa de recuperación establecida para situaciones en las que la planta opera en régimen estacionario (13.55 %) y en las que fueron entrenadas las ANN. Los valores atípicos (aquellos con un punto más que el tercer rango intercuartílico) localizados a la izquierda del bigote más bajo se encuentran dentro de los límites de operación teóricos de las membranas calculados en el capítulo 4. Sin embargo, hay algunos valores atípicos (con una muy baja frecuencia de ocu-

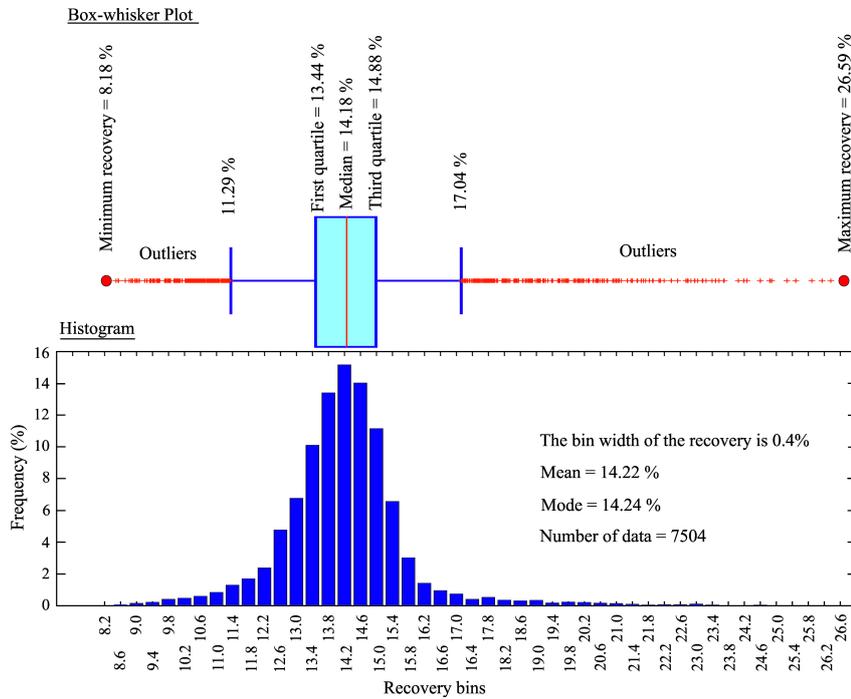


Fig. 6.14: Histograma y diagrama de bigotes de los valores instantáneos de tasa de recuperación de permeado obtenidos en los cuatro ensayos realizados.

rencia) localizados a la derecha del bigote más alto que exceden instantáneamente los márgenes de seguridad establecidos por el fabricante de las membranas. Estos valores atípicos (Fig. 6.10-d) se observan cuando los picos de presión previamente citados son relativamente altos. Esto se debe a que los incrementos instantáneos de presión (que, a su vez, producen incrementos en el caudal de agua producto que se encuentra en el numerador de la expresión que define la tasa de recuperación de permeado) están asociados con respuestas lentas en el caudal de alimentación (Fig. 6.10-c) con una consecuente reducción en el denominador de la expresión que define la tasa de recuperación de permeado. Se puede señalar que las variaciones en el caudal son derivadas del comportamiento del algoritmo que regula al convertidor de frecuencia (Fig. 6.3). Este algoritmo está basado en un lazo de control PI realimentado que actúa gradualmente (con rampas) antes de alcanzar una nueva consigna. De esta forma se garantiza la adaptación del caudal a la consigna en un periodo designado por el usuario.

Con vistas a prevenir el establecimiento de una tasa de recuperación de permeado que pudiera hacer operar a las membranas fuera de los límites operativos aceptables, se requiere una optimización y ajuste de los parámetros de los controladores.

En la Tabla 6.6 se muestran los errores MAE y MAPE obtenidos cuando la planta desalinizadora de OI opera siguiendo el procedimiento descrito en la sección 6.3.3. Se observa que los rangos de los errores medios MAE y MAPE, obtenidos para los distintos niveles del factor de características de agua de mar, se encuentran entre 0.338 kW y 0.364 kW y 5.684 % y 6.064 %, respectivamente. Por ello, se considera que puede ser de interés científico analizar si el uso de alguna otra técnica de Machine Learning puede obtener modelos capaces de reducir estos errores.

Tabla 6.6: Errores MAE y MAPE obtenidos cuando la planta desalinizadora opera siguiendo el procedimiento descrito en la sección 6.3.3.

Bloques del factor de potencia	Niveles del factor de características de agua de alimentación							
	L-1		L-2		L-3		L-4	
	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)	MAE (kW)	MAPE (%)
B-1	0.225	2.39	0.251	2.67	0.266	2.83	0.183	1.95
B-2	0.302	4.23	0.275	3.84	0.243	3.40	0.245	3.43
B-3	0.343	3.66	0.314	3.34	0.296	3.15	0.273	2.91
B-4	0.470	8.98	0.419	8.01	0.417	7.97	0.431	8.24
B-5	0.230	3.80	0.245	4.05	0.209	3.45	0.207	3.43
B-6	0.344	10.17	0.381	11.27	0.361	10.68	0.404	11.96
B-7	0.139	5.25	0.155	5.84	0.163	6.12	0.144	5.42
B-8	0.761	11.37	0.883	13.19	0.850	12.71	0.919	13.73
B-9	0.231	3.16	0.237	3.23	0.227	3.09	0.172	2.34
B-10	0.321	6.21	0.259	5.01	0.288	5.56	0.216	4.17
B-11	0.526	5.56	0.553	5.85	0.438	4.63	0.497	5.25
B-12	0.471	9.19	0.465	9.08	0.356	6.95	0.458	8.94
B-13	0.504	5.70	0.483	5.46	0.477	5.40	0.540	6.11
B-14	0.217	2.43	0.226	2.53	0.181	2.02	0.158	1.77
B-15	0.367	6.49	0.358	6.33	0.329	5.81	0.289	5.11
B-16	0.304	7.02	0.318	7.33	0.311	7.17	0.316	7.28
Media	0.360	5.976	0.364	6.064	0.338	5.684	0.341	5.753
Stdev	0.156	2.766	0.176	3.082	0.164	2.941	0.200	3.513

Con vistas a verificar la existencia o no de diferencias significativas entre los errores registrados para los cuatro niveles del factor de características de agua de mar en cada bloque del factor de potencia de referencia, la intención inicial fue desarrollar un análisis de varianza con medidas repetidas. Un análisis de varianza con medidas repetidas es equivalente a un análisis de varianza pero con relación entre grupos (no independientes). Sin embargo, dado que los datos no cumplen con las suposiciones que asume el análisis de varianza [190], se decidió emplear un método no-paramétrico, que no requiere que las muestras sigan una distribución específica. Más específicamente, se empleó un test de Friedman [191, 192], que utiliza rangos y constituye una versión no-paramétrica de un análisis de varianza de medidas repetidas.

Con el objetivo de poder aplicar el test de Friedmand [191, 192] a los errores mostrados en la Tabla 6.6, el contenido de las diferentes filas de la tabla debe ser independiente. Asimismo, el contenido de las diferentes columnas debe estar relacionado. Para analizar la independencia de los datos (coeficientes de autocorrelación cercanos a cero) de cada columna (cuyo correlograma se muestra en la Fig. 6.15), se utilizó la autocorrelación estadística, Q , Ec. 6.3, propuesta por Box and Pierce [193] y mejorada por Ljung and Box [194].

$$Q = NB(NB + 2) \sum_{k=1}^{z=lag} \frac{r^2(k)}{NB - k} \quad (6.3)$$

En la Ec. 6.3, $r(k)$ representa el coeficiente de autocorrelación (lineal) de orden k , y es dado por la (Ec. 6.4). En ella, m_1 es la media de los errores (MAE o MAPE) del nivel de características de agua de mar considerado.

$$r(k) = \frac{\sum_{i=k+1}^{NB} (error_i - m_1) (error_{i-k} - m_1)}{\sum_{i=1}^{NB} (error_i - m_1)^2} \quad (6.4)$$

El estadístico Q se distribuye en la hipótesis de independencia como χ^2 con $DL=lag$ grados de libertad. Por tanto, el valor crítico viene dado por la (Ec. 6.5).

$$Q > Q_c = \chi_{(1-\alpha, DL)}^2 \quad (6.5)$$

Sin embargo, se debe resaltar que este estadístico es válido si el proceso sigue una distribución gaussiana. Dado que la suposición de normalidad ha sido rechazada por los datos (de acuerdo con el test de normalidad de Anderson-Darling [195] usado con un nivel de significación de 0.05), se utilizó la transformación Box-Cox [196], Ec. 6.6, que permite convertir los datos a normales Fig. 6.16.

$$r^\lambda(k) = \frac{[r(k) + b]^\lambda - 1}{\lambda} ; k = 1 \dots NB - 1 \quad (6.6)$$

En la Ec. 6.6, λ es la potencia de la transformación que es estimada de los datos y la constante b es elegida de tal forma que $r(k) + b$ sea siempre positiva [196].

La aplicación de la Ec. 6.5 a los errores de la Tabla 6.6 muestra que la independencia entre los datos de cada columna puede ser aceptada con un nivel de significación de 0.05, si se usa un lag de 2 bloques (Fig. 6.15). Esto puede ser explicado por la circunstancia de que los datos de potencia de referencia alimentan secuencialmente a los modelos ANN y generan errores en un bloque que tiene cierta influencia en los errores del bloque que le sigue (como se comentó previamente, la mayor desviación de la presión de operación con respecto a la presión de referencia se produce como consecuencia de los cambios en las potencias de referencia).

Basado en lo anterior, se aplicó el test de Friedman [191] para cada tipo de error (MAE y MAPE) escogiendo los bloques situados alternativamente. Por un lado, se consideraron los 8 bloques (NB=8) cuya numeración es impar (B-1, B-3, ..., B-15), y por otra parte se consideraron los 8 bloques (NB=8) cuya numeración es par (B-2, B-4, ..., B-16).

En la Tabla 6.7 se muestran los altos coeficientes de correlación existentes entre los errores de las columnas de los bloques con numeración impar y entre los errores de los bloques con numeración par, corroborando la relación existente entre las columnas.

En la Fig. 6.17 se muestran los diagramas de bigotes y en la Tabla 6.8 los resultados de significación estadística con los valores del estadístico de Friedman [191], Ec.(6.7)

Tabla 6.7: Coeficientes de correlación entre los errores de los niveles del factor de características de agua de alimentación.

Dato	Muestra de bloques impares				Muestra de bloques pares				
	Niveles				Niveles				
	L-1	L-2	L-3	L-4	L-1	L-2	L-3	L-4	
MAE	L-1	1	0.989	0.975	0.967	1	0.976	0.965	0.973
	L-2		1	0.965	0.962		1	0.982	0.995
	L-3			1	0.970			1	0.981
	L-4				1				1
MAPE	L-1	1	0.976	0.912	0.935	1	0.971	0.956	0.966
	L-2		1	0.942	0.941		1	0.978	0.998
	L-3			1	0.921			1	0.978
	L-4				1				1

Tabla 6.8: Análisis de diferencias estadísticas para las métricas MAE y MAPE. Test de Friedman

Error	Muestra de bloques impares						Muestra de bloques pares					
	S	NB	NL	df	χ^2	p-valor	S	NB	NL	df	χ^2	p-valor
MAE	7.35	8	4	3	7.82	0.062	4.2	8	4	3	7.82	0.241
MAPE	7.35	8	4	3	7.82	0.062	4.2	8	4	3	7.82	0.241

$$S = \frac{12NB}{NL \cdot (NL + 1)} \sum_{j=1}^{NL} \left[R_j - \frac{(NL + 1)}{2} \right]^2 \quad (6.7)$$

donde R_j es la suma de los rangos de nivel j de las características de agua [191].

La hipótesis nula (H_0) para el test de Friedman es que no hay diferencia entre los errores generados por los cuatro niveles de características de agua de mar. El estadístico S sigue una distribución chi-cuadrado (χ^2) asintótica con $dl = NL - 1$ grados de libertad ⁵, cuando H_0 es verdad. Por tanto, la región crítica viene dada por la Ec.(6.8)

⁵Comparaciones numéricas han demostrado que esto es una buena aproximación siempre y cuando $NL > 7$ [191].

$$S \geq \chi_{1-\alpha, NL-1}^2 \quad (6.8)$$

Esto es, si la probabilidad calculada es baja (p-valor menor que un el nivel de significancia 0.05 seleccionado) entonces la hipótesis nula es rechazada y se puede concluir que al menos el error de dos niveles es significativamente diferente entre ellos.

Tal y como se puede ver en la Tabla 6.8, los p-valores son mayores que 0.05 en todos los casos. Por tanto, la hipótesis nula es aceptada y, por ello, se puede decir que no hay diferencias entre los errores cometidos por las ANN con respecto al nivel de características de agua de alimentación.

Esto quiere decir que los modelos ANN implementados en el sistema de control del pequeño prototipo de planta desalinizadora instalado en la isla de Gran Canaria, después del entrenamiento y de la validación presentan un comportamiento generalista con respecto a las distintas características de agua ensayadas. En otras palabras, los errores cometidos cuando se trataba de ajustar la potencia real consumida a la potencia de referencia no difirieron significativamente cuando las características del agua fueron cambiadas (conductividad y temperatura).

Finalmente, dado que los modelos ANN han sido usados durante un momento particular de la vida de las membranas y no contemplan el deterioro de las mismas debido al envejecimiento y/o la incrustación de sales, se requiere un entrenamiento cada periodo de tiempo para permitir que los modelos ANN aprendan los efectos de estos parámetros. Estudios más detallados son necesarios para investigar y determinar la frecuencia y metodología de estos entrenamientos.

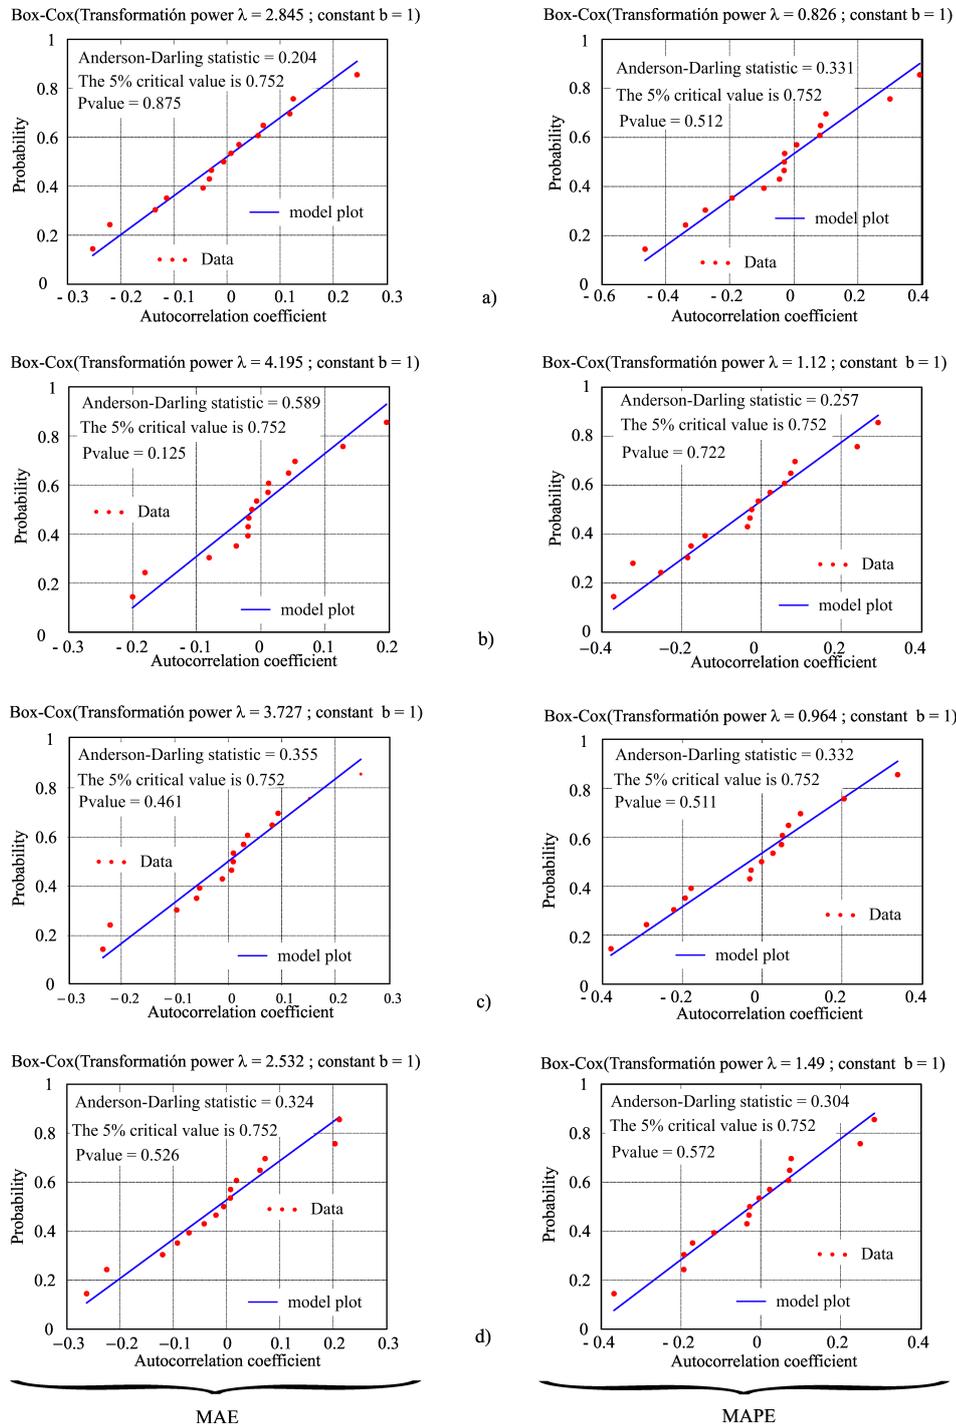


Fig. 6.16: Diagramas de probabilidad contruidos con los coeficientes de autocorrelación obtenidos con las series de datos de los cuatro niveles del factor de características de agua de mar. a) Nivel L-1, b) Nivel L-2, c) Nivel L-3, d) Nivel L-4. Las figuras a la izquierda se construyeron usando los errores MAE y las de la derecha usando los errores MAPE.

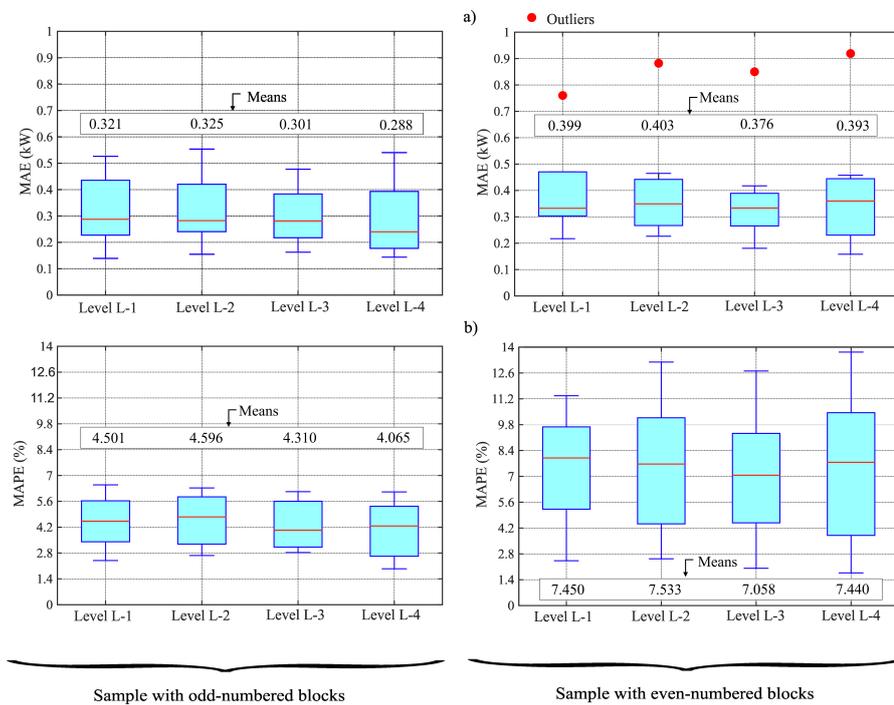


Fig. 6.17: Diagrama de bigotes hecho con las muestras de datos de los bloques del factor de potencias de operación de referencia. a) Errores MAE, b) errores MAPE. Las figuras de la izquierda corresponden a la muestra de los bloques con numeración impar. Las figuras de la derecha corresponden a la muestra de los bloques con numeración par.

Comparación de tres técnicas de *Machine Learning* usadas para modelar y simular del funcionamiento del prototipo considerado

7.1 Introducción

En este capítulo se escogen las tres técnicas de *Machine Learning* (*ML*) consideradas en este trabajo de investigación y se comparan los resultados obtenidos de las mismas al modelar y predecir el comportamiento de cuatro variables involucradas en el funcionamiento del prototipo de planta desalinizadora de agua de mar, accionado por una turbina eólica, en estudio.

7.2 Materiales

7.2.1 Variables y modelos a implementar

Las variables escogidas para modelar el sistema son las siguientes:

- **presión de alimentación del proceso de desalinización**, esta variable se obtiene a partir de la potencia consumida por la planta, la conductividad del agua de mar y la temperatura del agua de mar.
- **caudal de alimentación del proceso de desalinización**, esta variable se obtiene a partir de la potencia consumida por la planta, la conductividad del agua de mar y la temperatura del agua de mar.
- **caudal del agua producida por el proceso de desalinización**, esta variable se obtiene a partir de la presión y el caudal de alimentación de trabajo en la planta, la conductividad del agua de mar y la temperatura del agua de mar.
- **conductividad del agua producida por el proceso de desalinización**, esta variable se obtiene a partir de la presión y el caudal de alimentación de trabajo en la planta, la conductividad del agua de mar y la temperatura del agua de mar.

Tal y como se ha explicado en capítulos anteriores, la planta desalinizadora en estudio es capaz de trabajar con dos tubos de presión conectados, o bien con un sólo tubo. Por tanto, cada variable señalada, tendrá un modelo para trabajar con un tubo de presión y otro modelo para trabajar con dos tubos. Asimismo, cada variable ha sido modelada con cada una de las tres técnicas de *Machine Learning* consideradas, con el fin de comparar el resultado que ofrece cada una de ellas en cada variable.

En la Fig. 7.1 se sintetizan las formulaciones de los cuatro modelos utilizados para la estimación de las presiones y caudales de operación del prototipo de planta desalinizadora de OI evaluado (trabajando con uno o dos tubos de presión), así como los caudales de permeado y sus conductividades asociadas. El subíndice t indica el momento t o instante evaluado y el símbolo “hat” ($\hat{}$) indica estimación.

Asimismo, $f_A(B_1, \dots, B_p)$ representa los métodos de regresión utilizados donde se obtiene una estimación \hat{A} de la variable A con variables de entrada B_1, \dots, B_p .

El Modelo 1 (M1) tiene como entradas en cada instante t la potencia proporcionada por la turbina eólica y la conductividad y temperatura del agua de alimentación. Como salida proporciona la presión de operación estimada en dicho instante de tiempo t . El Modelo 2 (M2) se alimenta asimismo en cada instante t con la potencia proporcionada por la turbina eólica y con la conductividad y temperatura del agua de alimentación y es usado para estimar el caudal de alimentación. Dichas presiones y temperaturas estimadas en cada instante de tiempo t son tales que se mantiene prácticamente constante la tasa de recuperación de permeado (a veces también conocida como tasa de conversión). El Modelo 3 (M3) se entre para que pueda estimar el cauda del permeado y, el Modelo 4 (M4) para predecir las conductividades en el permeado. El Modelo 3 (M3) y el Modelo 4 (M4) tienen como variables de entrada en cada instante t las presiones y caudales estimados por los modelos M1 y M2, así como las temperaturas y conductividades del caudal de agua de alimentación (Fig. 7.1 y Tabla 7.1).

Tabla 7.1: Modelos considerados para estimar los parámetros del prototipo de planta desalinizadora

Modelo	Formulación
Modelo 1	$\hat{p}_{f,t} = f_{p_f}(P_{WT}, C_{f,t}, T_{f,t})$
Modelo 2	$\hat{Q}_{f,t} = f_{Q_f}(P_{WT}, C_{f,t}, T_{f,t})$
Modelo 3	$\hat{Q}_{p,t} = f_{Q_p}(p_f, Q_f, C_{f,t}, T_{f,t})$
Modelo 4	$\hat{C}_{p,t} = f_{C_p}(p_f, Q_f, C_{f,t}, T_{f,t})$

7.2.2 Datos utilizados

El procedimiento de recolección de datos llevado a cabo para realizar este estudio es el mismo que el explicado en el apartado 6.3.1 de este documento. El prototipo de planta desalinizadora de OI ha sido sometido a diferentes ensayos (usando uno y dos tubos de presión) con el propósito de determinar el comportamiento del mismo al ser alimentado por una amplia variación de la energía suministrada por la turbina eólica y bajo diferentes combinaciones de características de agua de

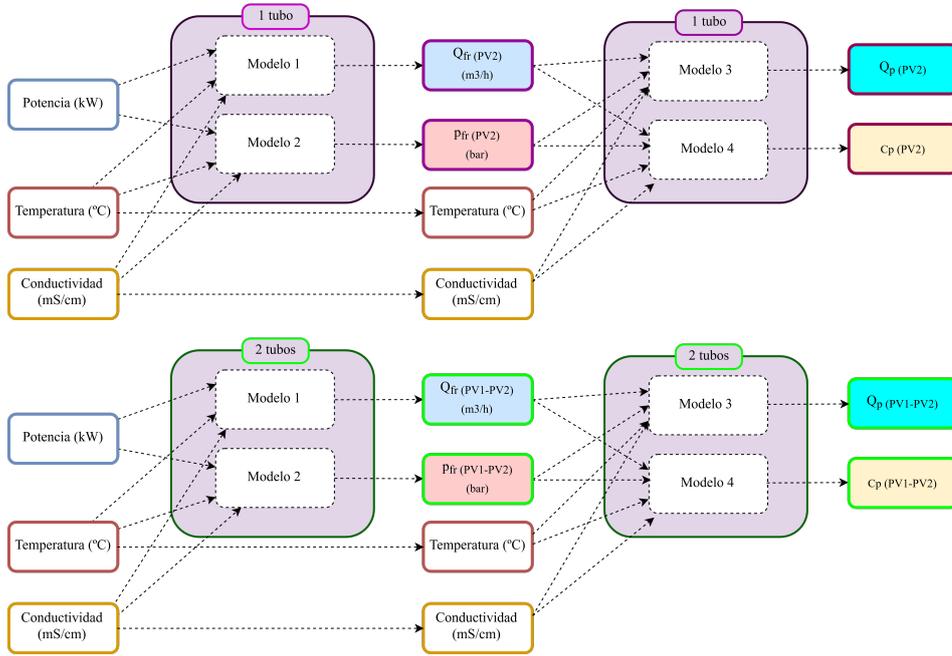


Fig. 7.1: Variables de entrada, modelos y variables de salida obtenidas para cada uno de los parámetros a modelar.

mar (conductividad y temperatura). También este procedimiento fue divulgado en [150].

Cuando el prototipo trabajó con un solo tubo de presión, se varió el caudal de alimentación (entre 0.96 m³/h y 3.07 m³/h), así como su conductividad (entre 45,032 μ S/cm y 52,875 μ S/cm) y la temperatura del agua de entrada a las membranas (entre 20.61 °C y 26.70 °C). Esto se realizó sin exceder ninguno los márgenes operativos de las membranas (ver apartado 4.2 de esta tesis) hasta obtener una tasa de recuperación de permeado en régimen estacionario y entre el estrecho margen entre 13.5 % and 13.6 % [150]. Cuando el prototipo trabajó con dos tubos de presión, se varió el caudal (entre 3.04 m³/h y 6.13 m³/h), así como su conductividad (entre 46,395 μ S/cm y 55,626 μ S/cm) y la temperatura a la entrada de las membranas (entre 19.88 °C y 26.18 °C) [150]. En la Tabla 7.2 se muestran, a título de ejemplo, los valores observados de diversos parámetros (la conductividad y temperatura del agua de alimentación, la potencia demandada medida antes del convertidor de frecuencia, los caudales y presiones de operación, el caudal de permeado y su

conductividad) a cada uno de los puntos operativos, correspondientes a las diferentes combinaciones (505 en el caso de un tubo de presión y 692 en el caso de dos tubos de presión) de los valores de las variables.

7.3 Metodología empleada en el entrenamiento, ensayo, validación y evaluación estadística de los cuatro modelos de simulación considerados

En la Fig. 7.2 se esquematiza el procedimiento metodológico utilizado con el propósito de comparar los cuatro modelos descritos en el apartado 7.2.1 y que han sido diseñados para simular el comportamiento en régimen variable del prototipo en estudio.

En la parte superior de la Fig. 7.2 se muestran las series de las variable predictoras y de las variables objetivo (*target*) de los cuatro modelos de simulación considerados. Así mismo, se especifica en dicho lugar el número total de datos disponibles de cada variable para llevar a cabo el entrenamiento y ensayo de los modelos. En los tres recuadros centrales de la Fig. 7.2 se muestra, de forma sucinta, para cada una de las ML consideradas (ANNs, SVMs y RFs), el método utilizado para estimar los errores de predicción (*10-Fold Cross Validation*) y las tareas realizadas para el ajuste de hiperparámetros a la hora de evaluar cada uno de los modelos (M1, M2, M3 y M4).

Hay que señalar que la mayoría de estudios desarrollados previamente [13, 16–18, 130] separan el conjunto de datos disponibles en dos subconjuntos disjuntos. Uno de los subconjuntos se utiliza para el aprendizaje del modelo y se denomina subconjunto de entrenamiento. El otro subconjunto, denominado de prueba se utiliza para evaluar el modelo, es decir, para calcular el error que comete el modelo una vez construido utilizando el subconjunto de entrenamiento. Generalmente, el reparto de los datos entre los subconjuntos de entrenamiento y ensayo se hace de forma aleatoria, dejando un porcentaje de aproximadamente el 80 % para el primero y del 20 % para el segundo [18]. El uso de los dos subconjuntos de datos persigue que el modelo no se sobreajuste a los datos de entrenamiento, ya que este fenómeno se favorecería si todos los datos disponibles se usasen para el entrenamiento y esos

Tabla 7.2: Muestra de datos registrados al operar la planta desalinizadora de OI con uno y dos tubos de presión. Estos datos fueron usados para llevar a cabo el entrenamiento, la validación y el ensayo de los modelos de ML empleados (*)

Un tubo de presión										Dos tubos de presión									
Fila	Cond.	Temp.	Pot.	Pres.	Caudal	Caud. Permeado	Cond. Permeado	Fila	Cond.	Temp.	Pot.	Pres.	Caudal	Caud. Permeado	Cond. Permeado				
Nº	($\mu\text{S/cm}$)	($^{\circ}\text{C}$)	(kW)	(bar)	(m^3/h)	(m^3/h)	($\mu\text{S/cm}$)	Nº	($\mu\text{S/cm}$)	($^{\circ}\text{C}$)	(kW)	(bar)	(m^3/h)	(m^3/h)	($\mu\text{S/cm}$)				
1	47645	23.45	1.84	33.43	1.05	0.14	748.81	1	47798	21.29	4.11	36.35	3.06	0.42	444.58				
2	45032	20.91	1.84	33.34	0.97	0.13	473.59	2	47251	24.93	4.12	35.25	3.07	0.42	556.01				
3	47763	23.44	1.85	33.38	1.04	0.14	755.17	3	46688	23.28	4.19	35.55	3.04	0.41	516.74				
:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:				
9	47645	23.54	1.87	33.27	0.98	0.13	768.12	171	55360	20.39	5.77	43.31	3.53	0.48	486.25				
10	47645	23.43	1.87	33.33	1.04	0.14	702.39	172	55626	20.56	5.78	43.33	3.51	0.48	489.76				
11	51611	23.98	1.87	34.08	1.00	0.14	866.32	173	47557	23.32	5.79	38.70	4.10	0.56	417.69				
:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:				
32	51241	26.45	2.09	38.11	0.96	0.14	867.13	318	51667	19.88	7.53	44.60	4.54	0.61	354.57				
33	53732	24.36	2.09	38.57	1.07	0.14	879.34	319	47167	24.89	7.55	40.65	5.04	0.68	388.94				
34	53813	24.11	2.09	37.76	1.01	0.13	766.64	320	54781	21.06	7.56	46.15	4.52	0.61	484.03				
:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:				
76	47298	20.61	2.63	37.13	1.50	0.20	463.80	383	53215	26.18	8.36	45.43	5.07	0.69	504.09				
77	50507	21.45	2.68	39.47	1.49	0.20	588.46	384	53215	25.89	8.36	45.19	5.03	0.68	503.99				
78	50668	21.28	2.69	39.76	1.52	0.20	462.32	385	52824	25.81	8.36	45.41	5.05	0.68	506.21				
:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:				
100	51206	26.70	2.83	40.38	1.50	0.20	683.35	550	46935	22.79	9.86	45.08	6.08	0.82	291.46				
101	53132	26.18	2.83	40.33	1.50	0.20	649.44	551	46395	22.71	9.87	44.83	5.97	0.81	295.25				
102	51206	26.38	2.84	40.38	1.51	0.21	661.09	552	47323	22.81	9.87	44.92	6.02	0.82	295.43				
:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:				
110	52875	26.23	2.88	40.16	1.46	0.20	683.54	682	53523	20.66	10.96	50.68	6.13	0.83	316.68				
111	51133	26.23	2.90	40.20	1.47	0.21	880.75	683	52832	20.93	10.96	50.40	6.05	0.82	318.72				
112	54180	20.75	2.98	42.33	1.49	0.20	683.72	684	53523	21.14	10.96	50.79	6.08	0.82	314.28				
:	:	:	:	:	:	:	:	:	:	:	:	:	:	:	:				
503	53655	21.21	6.21	52.83	3.03	0.41	331.00	690	52832	20.72	11.05	50.59	6.07	0.82	318.35				
504	53239	21.09	6.22	53.09	3.07	0.42	335.90	691	52832	20.99	11.06	50.63	6.07	0.82	320.47				
505	53239	21.11	6.22	52.77	2.97	0.40	339.05	692	52832	20.96	11.07	50.41	6.07	0.82	319.18				

(*) Los números en negrita indican los valores mínimos y máximos registrados para las cinco variables.

mismos datos se usasen para calcular el error. Sin embargo, hay que señalar que los errores obtenidos cuando se utiliza dicha partición aleatoria de datos dependen notablemente de cómo se haya hecho la misma. Por ello, en este trabajo en lugar de utilizar dicha partición para evaluar los modelos M1, M2, M3 y M4 de predicción con las tres técnicas de ML, se ha utilizado la técnica de validación cruzada con 10 folds [152]. Según Hastie et al. [152] esta es probablemente el método más simple y ampliamente utilizado para estimar la predicción del error. La validación cruzada permite reducir la dependencia de los errores obtenidos al evaluar los modelos del modo en el que se lleva a cabo la partición entre los datos de entrenamiento (utilizados para el aprendizaje) y los datos de ensayo (usados para evaluar los modelos).

7.3.1 Validación cruzada con ajuste de hiperparámetros

En la Fig. 7.3 se muestra un diagrama de bloques del proceso de validación cruzada con ajuste de hiperparámetros. La Fig. 7.3 se ha particularizado para el caso de los modelos M1 y M2, pero es extensible a los modelos M4 y M5, simplemente utilizando las correspondientes *features* (variables continuas de entrada) y *targets* (variables objetivo de salida) que se indican en Fig. 7.2.

Previo a la aplicación de la técnica de validación cruzada los datos indicados en la Tabla 7.2 (505 filas en el caso de un tubo de presión y 692 filas en el caso de dos tubos de presión) se han ordenado aleatoriamente. Seguidamente, se han dividido en 10 subconjuntos (*folds*) disjuntos de similar tamaño. Hay que señalar que dichas particiones aleatorias han sido las mismas para todos los modelos y técnicas de ML analizadas con el propósito de minimizar la varianza de la diferencia entre las métricas medias obtenidas por las tres técnicas.

Nueve de dichos *folds* se utilizan como datos de entrenamiento del modelo y el *fold* restante se utiliza para llevar a cabo el ensayo (*test*) del modelo. Utilizando iterativamente el procedimiento, pero con un *fold* diferente para realizar el ensayo y los nueve *folds* restantes para llevar a cabo el entrenamiento del modelo, se obtienen 10 errores. La media aritmética de los 10 errores obtenidos proporciona el error de la validación cruzada.

Para el ajuste de hiperparámetros en el caso de las ANNs, es decir, para la búsqueda del número de neuronas en la primera capa oculta (HL-1) y en la segunda capa oculta (HL-2) se ha utilizado a real-coded genetic algorithm [[184]. Sin embargo, en el caso de las técnicas SVM y RF se ha utilizado un método de *grid search* (Fig. 7.2 y Fig. 7.3).

Como puede observarse en Fig. 7.2 la evaluación de los modelos lleva aparejado, a diferencia de la mayoría de los modelos de predicción citados [13, 16–18, 130], un proceso de optimización de sus parámetros. Como se muestra en la Fig. 7.3 se trata de un proceso iterativo que finaliza cuando el criterio de parada es satisfecho. Dicho criterio se satisface cuando el error medio es menor de 10^{-4} o cuando el número de generaciones (o iteraciones) alcanzadas por el algoritmo empleado alcanza el valor de 200, en el caso de haber usado un algoritmo genético, o cuando todas las combinaciones de los valores de los parámetros candidatos han sido considerados, en el caso del *grid search*.

Una vez evaluados los cuatro modelos (M1, M2, M3 y M4) para cada uno de los tubos de presión con las tres técnicas de ML consideradas se dispone de las estimaciones de las distintas variables objetivo (\hat{p}_f , \hat{Q}_f , \hat{Q}_p , \hat{C}_p) para cada uno de los *folds* y pueden determinarse los errores medios producidos. También puede evaluarse la varianza de los 10 errores que permite estimar la variabilidad del método de aprendizaje con respecto a la evidencia.

Las métricas utilizadas en este caso, al igual que para la aplicación de las ANN vista en el capítulo 6 son el error absoluto medio (MAE - *Mean Absolute Error*) y el error absoluto medio porcentual (MAPE - *Mean Absolute Percentage Error*), Ec. 6.1 y Ec. 6.2 respectivamente.

7.3.2 Ensayo de hipótesis estadística de las métricas obtenidas por cada uno de los modelos para determinar si existe diferencia significativa entre modelos

La metodología propuesta, con el propósito de determinar si existe diferencia estadísticamente significativa entre las métricas obtenidas en cada modelo en función de la ML utilizada, contempla la realización de un ensayo de hipótesis estadística.

En este caso, se desea contrastar la hipótesis nula (H_0) de que la métrica media (μ_i) de un modelo con técnica de ML « i » es menor o igual, con un nivel de significación $\alpha = 0,05$, que la métrica media (μ_j) del modelo con técnica de ML « j » al estimar una determinada variable objetivo, frente a una hipótesis alternativa (H_1) unilateral, en la que se acepta que la μ_i es significativamente mayor μ_j , Ec. 7.1.

$$H_0 : \mu_i \leq \mu_j ; H_1 : \mu_i > \mu_j \quad (7.1)$$

Para ello se ha utilizado un test no-parámtrico de permutaciones para datos apareados [197] y los p-valores que se obtienen en cada par de comparaciones del test de permutación se han ajustado siguiendo el procedimiento propuesto por Benjamini and Hochberg (BH) [198].

7.4 Análisis y discusión de los resultados obtenidos

En este apartado se presentan y discuten los resultados alcanzados al comparar las tres técnicas de ML con el propósito de esclarecer cual de ellas es más apropiada para simular el comportamiento del prototipo analizado ante la variación de sus parámetros de operación.

En la Fig. 7.4 se recogen los valores medios y las desviaciones estándar de las métricas MAE y MAPE obtenidas de la validación cruzada al estimar con los cuatro modelos considerados las distintas variables objetivo (\hat{p}_f , \hat{Q}_f , \hat{Q}_p , \hat{C}_p) (con las tres técnicas de ML contempladas), en el caso de usar uno o dos tubos de presión.

En la Tabla 7.3 se muestran los hiperparámetros óptimos obtenidos para cada uno de los modelos ejecutados basados en las tres técnicas de ML empleadas (ANN, SVM, RF).

De la observación de las Fig. 7.4 se concluye que, en todos los modelos considerados, la técnica de ANN (la única utilizada hasta la fecha [13, 16, 18, 125, 130] para predecir el funcionamiento o gestionar [17] la operación de plantas de OI) ha generado valores mayores en las métricas de error (MAE y MAPE) que las técnicas SVM y RF, tanto cuando se han aplicado a un tubo de presión como aplicadas a

Tabla 7.3: Hiperparámetros de cada uno de los modelos configurados

Tubos de presión	Técnica ML	Hiperparámetros	Modelo 1	Modelo 2	Modelo 3	Modelo 4
			Pres. Al.	Caud. Al.	Caud. Prod.	Cond. Prod.
Un tubo de presión	ANN	NHN-1	56	38	58	40
		NHN-2	9	4	4	3
	SVM	C	101.02	1.8665	25.95	100.10
		ϵ	0.05	0.01	0.01	0.01
		σ	1.27	1.45	1.79	1.24
	RF	Ntree	339	35	86	142
		Nodesize	2	3	3	3
		Mtry	1	5	2	1
	Dos tubos de presión	ANN	NHN-1	71	69	18
NHN-2			17	13	4	7
SVM		C	53.97	10.52	0.50	99.90
		ϵ	0.03	0.03	0.01	0.01
		σ	0.91	1.09	2.15	0.534
RF		Ntree	281	372	118	281
		Nodesize	2	2	1	1
		Mtry	1	1	3	3

NHN-1: Número de neuronas en la primera capa oculta;
 NHN-2: Número de neuronas en la segunda capa oculta;
 Ntree: Número de árboles del bosque aleatorio;
 Nodesize: Tamaño del nodo final (hoja);
 Mtry: Número de variables para dividir los datos en el RF.

dos tubos de presión. La técnica RF ha proporcionado en el 62.50 % de los casos mejores valores en las dos métricas, en comparación con la técnica SVM.

Con el objetivo de comprobar si existen diferencias significativas entre las tres técnicas de ML empleadas en los distintos modelos se ha llevado a cabo un ensayo estadístico de hipótesis. En las Tabla 7.4 y Tabla 7.5 se muestran los p-valores correspondientes a las métricas MAE y MAPE. La primera columna de dichas tablas indica el modelo considerado (M1, M2, M3 y M4). Para cada modelo existen dos sub-tablas dentro de cada tabla, es decir, una sub-tabla para un tubo de presión y otra sub-tabla para dos tubos de presión.

Tabla 7.4: Análisis de las diferencias estadísticas de las métricas MAE. p-valores*

Modelo	Tubo	Técnica Machine Learning				Tubo	Técnica Machine Learning						
		i	ANN	SVR	RF		i	ANN	SVR	RF			
M1 (bar)	1 tubo	j	\overline{MAE}	0.278	0.174	0.188	2 tubos	j	\overline{MAE}	0.253	0.122	0.129	
		ANN	0.278	-	0.000	0.001		ANN	0.278	-	0.000	0.001	
		SVM	0.174	0.000	-	0.846		SVM	0.122	0.000	-	0.853	
		RF	0.188	0.001	0.846	-		RF	0.129	0.000	0.853	-	
	M2 (m^3/h)	1 tubo	i	ANN	SVR	RF	2 tubos	i	ANN	SVR	RF		
			j	\overline{MAE}	0.036	0.023		0.017	j	\overline{MAE}	0.047	0.031	0.030
			ANN	0.036	-	0.000		0.000	ANN	0.047	-	0.000	0.001
			SVM	0.023	0.001	-		0.000	SVM	0.031	0.000	-	0.155
RF	0.017	0.000	0.000	-	RF	0.03	0.001	0.155	-				
M3 (m^3/h)	1 tubo	i	ANN	SVR	RF	2 tubos	i	ANN	SVR	RF			
		j	\overline{MAE}	0.007	0.005		0.001	j	\overline{MAE}	0.008	0.005	0.002	
		ANN	0.007	-	0.000		0.000	ANN	0.008	-	0.000	0.000	
		SVM	0.005	0.000	-		0.000	SVM	0.005	0.000	-	0.000	
	RF	0.001	0.000	0.000	-	RF	0.002	0.000	0.000	-			
	M3 ($\mu S/cm$)	1 tubo	i	ANN	SVR	RF	2 tubos	i	ANN	SVR	RF		
			j	\overline{MAE}	56.09	31.26		28.30	j	\overline{MAE}	11.93	6.34	8.20
			ANN	56.09	-	0.000		0.000	ANN	11.93	-	0.000	0.000
SVM			31.26	0.000	-	0.095		SVM	6.34	0.000	-	0.999	
RF	28.30	0.000	0.095	-	RF	8.20	0.000	0.999	-				

* Para cada modelo y número de tubos de presión, leyendo por filas (j), la mejor técnica de Machine Learning es aquella con un mayor número de celdas escritas en negrita.

En cada sub-tabla de las Tabla 7.4 y Tabla 7.5 las técnicas de ML « i » representan las columnas y las técnicas de ML « j » las filas, Ec. 7.1. Si la lectura de las tablas se realiza por filas, las celdas con los p-valores escritos en negrita corresponden a aquellos casos donde la hipótesis nula ($H_0 : \mu_i \leq \mu_j$) es rechazada a favor de la hipótesis alternativa ($H_1 : \mu_i > \mu_j$).

Los p-valores indicados en las mencionadas tablas conducen a la aceptación de la hipótesis alternativa de que las métricas MAE y MAPE obtenidas con las técnicas SVM y RF son significativamente (con un nivel de significancia del 5 %) mejores que las obtenidas con la técnica ANN en todos los modelos (M1, M2, M3 y M4) aplicados tanto a uno como a dos tubos de presión.

Se observa en las Tabla 7.4 y Tabla 7.5 que en el 62.5 % de los casos analizados no se han presentado diferencias estadísticamente significativas entre las métricas obtenidas con las técnicas SVM y RF.

En el 37.5 % de los casos las métricas obtenidas con la técnica RF fueron significativamente mejores que las obtenidas con la técnica SVM. Por tanto, aunque la técnica ANN ha sido la utilizada hasta la fecha [13, 16, 18, 125, 130, 150] como técnica de regresión implementada en los modelos de predicción del funcionamiento de las plantas desalinizadoras de OI, los resultados aquí alcanzados nos llevan a recomendar la utilización de las técnicas SVM y RF (en especial, esta última), ya que se pueden lograr mejores métricas de los errores cometidos en las predicciones. Por ello, para desarrollar e estudio que se presenta a continuación, se ha escogido la técnica de RF.

CAPÍTULO 7. Comparación de tres técnicas de *Machine Learning* usadas para modelar y simular del funcionamiento del prototipo considerado

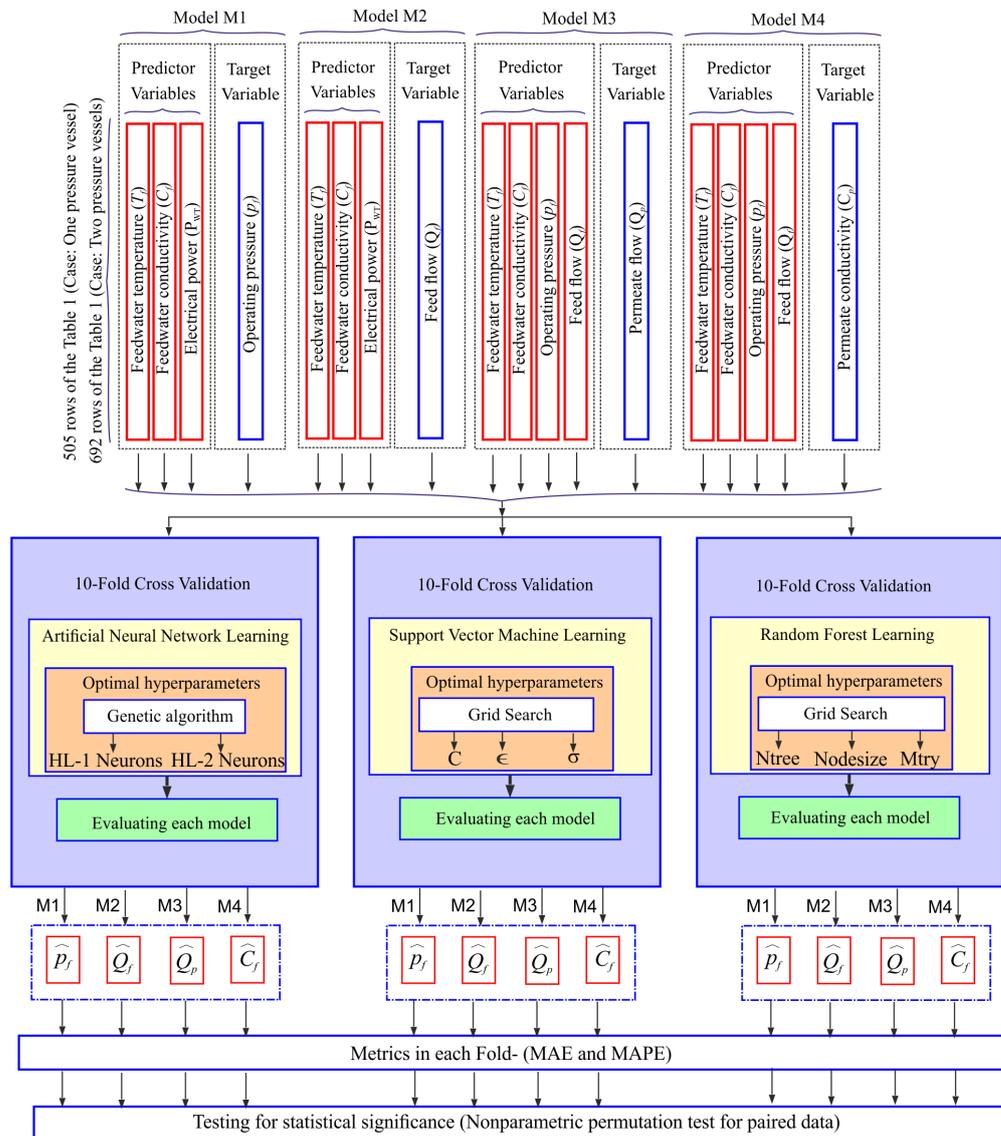


Fig. 7.2: Representación esquemática de la metodología empleada para comparar las tres técnicas de Machine Learning consideradas en esta tesis.

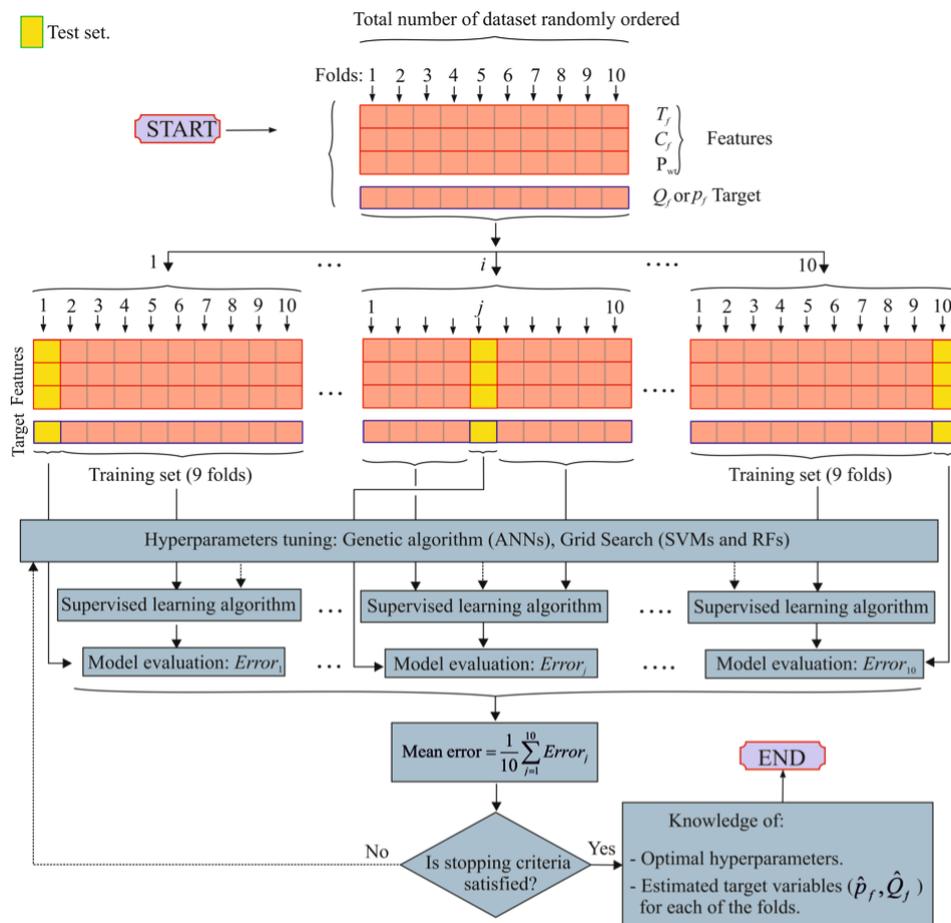


Fig. 7.3: Representación esquemática de la validación cruzada con el ajuste de hiperparámetros llevado a cabo.

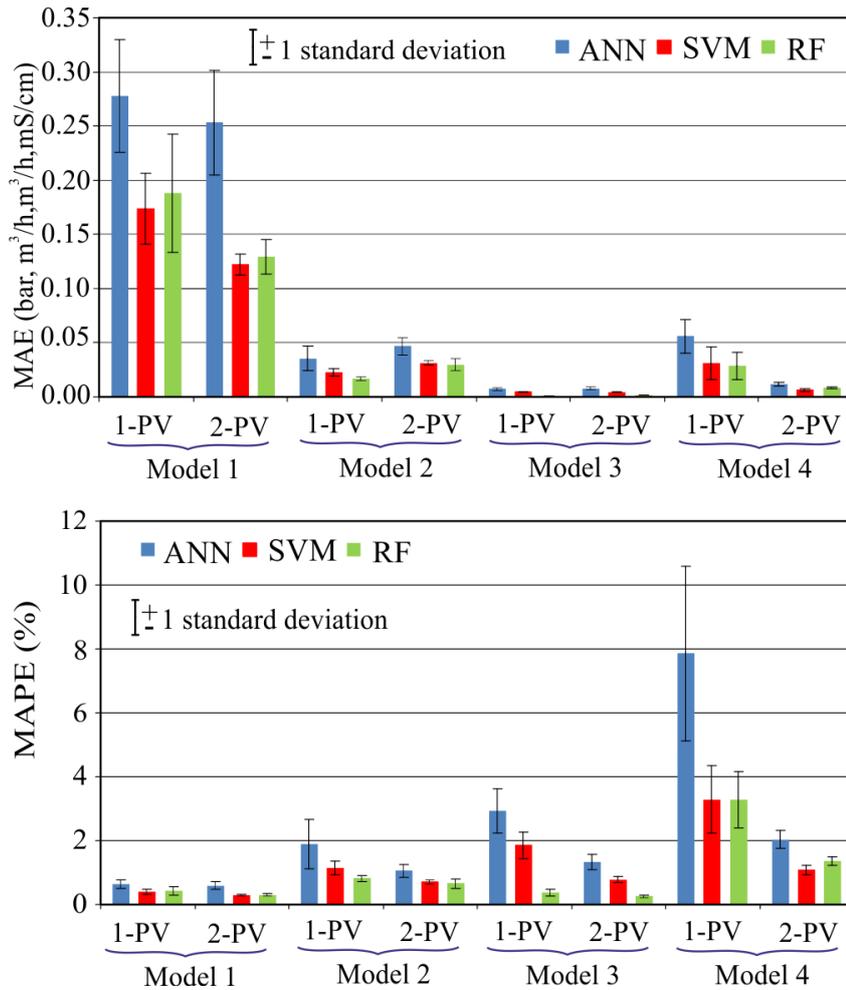


Fig. 7.4: Valores medios y desviaciones estándar de las métricas MAE y MAPE obtenidas de la validación cruzada cuando se han estimado las variables objetivo con los cuatro modelos analizados (con las tres técnicas de ML consideradas), en el caso de usar uno o dos tubos de presión.

Simulación del prototipo empleando una técnica de *Machine Learning* y comparación de su funcionamiento en régimen variable y en régimen constante

8.1 Introducción

En este capítulo se desarrolla un estudio en el que se usa uno de los algoritmos de Machine Learning (ML) analizados en el capítulo anterior para investigar dos posibles modos de funcionamiento del prototipo:

- a) un modo de funcionamiento en el que la presión y el caudal de operación en la planta desalinizadora operan en modo constante, al conectar la planta a una micro-red eléctrica con una turbina eólica y un banco de baterías (MG-1) ;

b) un modo de funcionamiento en el que la presión y el caudal de operación en la planta desalinizadora operan en modo variable, de tal forma que se adapta el consumo energético de la planta a la generación suministrada por una micro-red eléctrica basada en la misma turbina eólica pero sin almacenamiento energético (MG-2) ;

Con las potencias estimadas que genera la turbina eólica durante un año y las características de agua de alimentación, el algoritmo de ML considerado (*Random Forest*) estima las presiones y caudales a los que debe operar la planta desalinizadora en cada momento, así como los caudales de permeado y la conductividades de los mismos. La estrategia de operación en régimen variable ha sido comparada con la de un sistema que emplea almacenamiento masivo de energía en baterías y opera con presión y caudal constantes.

Hasta el momento han sido defendidas propuestas en contra [1, 104] y a favor [5, 6, 84, 86–88, 91, 92, 98, 150, 199–201] de la utilización de micro-redes que carecen de almacenamiento masivo de energía y que pretenden que las plantas desalinizadoras funcionen con presión y/o caudal variables, con el objetivo de que las mismas adapten su consumo energético a la variabilidad de la energía generada por las turbinas eólicas que les suministran energía. Los que se inclinan por el uso de sistemas de almacenamiento masivo de energía en este tipo de plantas argumentan una serie de problemas que se pueden presentar en las membranas de OI como consecuencia de los ciclos de arranques y paradas. También exponen algunos problemas al operar en carga parcial durante los periodos de oscilación de la potencia generada por las turbinas eólicas. Los que se decantan por descartar la utilización del almacenamiento masivo de energía argumentan los resultados positivos obtenidos en los ensayos que han realizado en prototipos [7, 84, 91, 98, 150, 199, 202] y sistemas comerciales [87, 88, 200, 201] y el incremento de los costes de inversión que implican el uso de bancos de baterías [5, 104] y de los requerimientos de mantenimiento en condiciones de climas duros [104].

Sin embargo, en la revisión bibliográfica realizada no se han encontrado resultados experimentales o simulados del comportamiento temporal anual (utilizando una escala con saltos de tiempo pequeños), para un régimen dado de viento, de una planta desalinizadora de agua de mar de OI operando en régimen variable de

presión y caudal. Hasta la fecha no se han comparado, de esta manera, el funcionamiento de una planta que opera en régimen variable con la operación de otra planta que opera con presión y caudal constantes estando esta última integrada en una micro-red que dispone de un sistema de almacenamiento masivo de energía en baterías. Por tanto, no se dispone de datos que permitan comparar frecuencias de arranque/paradas de ambos tipos de micro-redes y de otros parámetros de operación de las mismas durante un año de funcionamiento, de tal manera que puedan recogerse las variaciones diarias y estacionales del recurso eólico.

Hay que resaltar que las series temporales de resultados experimentales [84, 87, 200] de operación en régimen variable o auxiliados con baterías [104] de sistemas de desalación accionados por energía eólica que han sido divulgados han estado restringidas a cortos periodos de tiempo, ya que solo se ha pretendido demostrar la viabilidad técnica de operación de los diferentes sistemas. En este contexto, Carta et al. [84] presentó, en el marco del proyecto SDAWES [86, 91], un análisis operacional de un prototipo de sistema de desalinización accionado por una turbina eólica de forma completamente autónoma. El sistema consistía en un parque eólico, formado por dos turbinas y un volante de inercia que suministraban las necesidades energéticas de un grupo de seis módulos idénticos de OI así como de sus subsistemas de control asociados. Entre otras tareas, el sistema de control decidía el número de módulos de OI que, trabajando en régimen nominal de presión y caudal, debían conectarse o desconectarse en un momento dado para adaptarse a la oferta variable de energía eólica. El tamaño de las series temporales de operación divulgadas fue de algunos minutos. En dichas series se recoge: el proceso de creación de la red eléctrica aislada, el proceso de conexión de cargas, los caudales de agua y sus conductividades, las variaciones de presión en un módulo de OI durante la conexión, las variaciones de conductividad y caudal en el agua producida en función de la frecuencia, la conexión secuencial de los módulos de OI, los periodos de conexión y desconexión de los módulos de OI y el comportamiento del sistema en periodos de bajas velocidades de viento.

Helm et al. [200] han mostrado los resultados obtenidos con un prototipo de planta de desalación modular de OI (la planta de OI contiene ocho módulos idénticos) que es accionada por una turbina eólica y cuenta con un sistema de almace-

namiento de energía. Las series de datos de operación divulgadas se han centrado en: los valores medios diarios de velocidad de viento, el consumo energético en las unidades de OI y la producción de agua producto durante 60 días. Asimismo, se muestra en [200] un ciclo típico operación diaria en el rango crítico de carga parcial y datos de operación de un período de 15 minutos con un cambio rápido de los módulos de OI y de varios componentes periféricos.

Asímismo, Subiela et al. [104] han divulgado series temporales de resultados de operación de la micro-red denominada AEROGEDESA. AEROGEDESA es el acrónimo de las palabras en español AEROGenerador y DESAlinización que el Instituto Tecnológico de Canarias utiliza para referirse a dicha micro-red que se encuentra instalada en sus dependencias (Playa de Pozo Izquierdo, isla de Gran Canaria, España). Dicha micro-red, ya descrita en el apartado 3.2.1 de esta tesis dispone de una turbina de 15 kW de potencia nominal y un banco de baterías (120V, 190 Ah). La planta desalinizadora de agua de mar tiene una capacidad de 18 m³/día y operaba con una presión de 64 bar, un caudal de alimentación de 3125 l/h, y una tasa de conversión del 24 %. Las series temporales divulgadas [104] se limitan a reflejar, con saltos de tiempo de una hora, a) energía eólica frente al agua producto desalinizada durante un mes; b) energía eólica frente al agua producto desalinizada en un día con velocidades medias de viento intermedias y c) energía eólica frente al agua producto desalinizada en un día con velocidades medias de viento elevadas.

Miranda and Infield[5] llevan cabo la simulación dinámica de una micro-red compuesta por una pequeña turbina eólica de 2.2 kW directamente conectada a una planta desalinizadora. Con ello pretenden verificar su funcionamiento durante una operación transitoria normal, con viento turbulento. Las series de tiempo utilizadas son de 5 min de duración, con un viento medio de 8.3 m/s. Dichas series temporales muestran la velocidad del viento, el caudal de agua producto, la concentración del agua producto y el consumo específico de energía instantáneo.

Kim et al. [203] han limitado a horizontes temporales de algunos segundos y de unos pocos días la simulación del funcionamiento de una planta de OI integrada en un sistema de energía híbrido y que trabaja bajo condiciones de operación variables. Peñate et al. [204], utilizando saltos de tiempo de una hora, simularon la energía eólica anual producida y el agua obtenida con una turbina eólica acoplada a una

planta desalinizadora de agua de mar de 1000 m³/día de capacidad gradua, que trabaja a presión y caudal constantes.

En vista de lo anterior, y a modo de resaltar la aportación novedosa que hace este capítulo al nuevo cuerpo del conocimiento, se pretende llevar cabo, por primera vez, la simulación (mediante el uso de un algoritmo de ML) del comportamiento temporal anual del prototipo planta desalinizadora en estudio trabajando en régimen variable de presión y caudal [98], para adaptar su consumo energético a la variabilidad temporal de la energía generada por una turbina eólica que lo acciona. Asimismo, se pretende realizar una comparación del comportamiento temporal de dicho tipo de micro-red con el comportamiento de una micro-red en la que además de la planta desalinizadora y la turbina eólica se dispone de un sistema de almacenamiento masivo de energía en baterías y la planta opera con presión y caudal constantes. Asimismo, se pretenden analizar las variaciones temporales de las presiones y caudales de operación, así como los caudales de permeado asociados y sus conductividades con el propósito de extraer formación que facilite la toma de decisión a la hora de instalar uno u otro tipo de micro-red.

8.2 Materiales

A continuación se describen las configuraciones de las dos micro-redes empleadas, así como las características de los datos de viento utilizados para su simulación. La técnica de ML utilizada para simular el comportamiento del prototipo ha sido la de RF (*Random Forest*), dado que fue la que mejores resultados obtuvo en el análisis comparativo desarrollado en el capítulo anterior.

8.2.1 Descripción de las micro-redes

Tal y como se ha indicado en el apartado anterior, dos son las configuraciones de micro-redes cuyos funcionamientos se pretenden simular y comparar en esta tesis, que denominaremos MG-1 y MG-2. Los componentes de dichas micro-redes proceden de una micro-red denominada AEROGEDESA, Fig. 8.1, ampliamente referenciada en la bibliografía [24, 25, 98, 103, 104] y que se describe detalladamente en [98] así como en el apartado 3.2.1 de esta tesis.

CAPÍTULO 8. Simulación del prototipo empleando una técnica de *Machine Learning* y comparación de su funcionamiento en régimen variable y en régimen constante

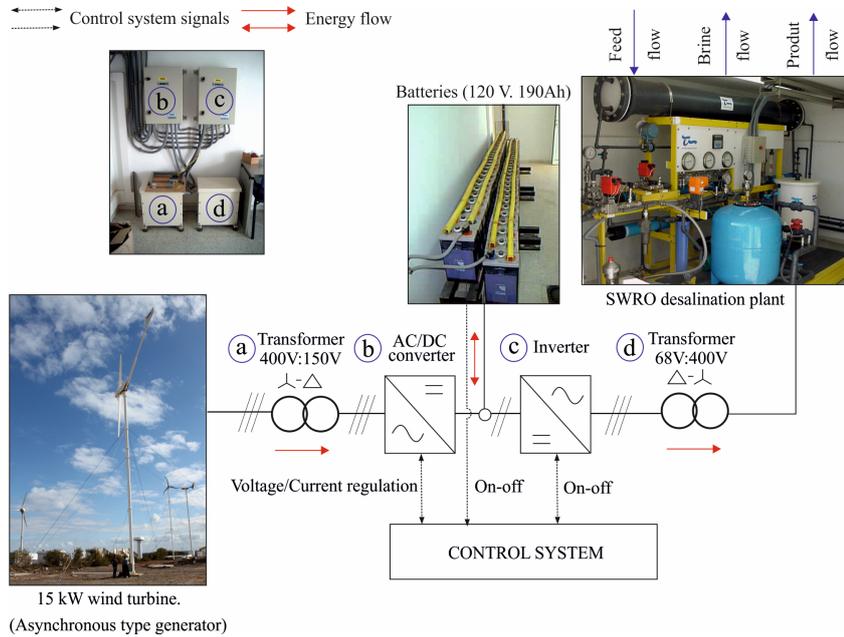


Fig. 8.1: Esquema general de la micro-red llamada AEROGEDESA.

El esquema básico de la MG-1 considerada en este estudio es idéntico al de la micro-red AEROGEDESA ya descrito previamente (apartado 3.2.1 y [98]), Fig. 8.1.

En la Fig. 8.2 se muestra el esquema elemental de la MG-2. Tanto en la MG-1 como en la MG-2 la turbina eólica y el prototipo de planta desalinizadora serán los mismos, aunque este último operará de forma diferente según el tipo de micro-red (MG-1 o MG-2). Hay que indicar que tanto la turbina eólica, de la marca Vergnet, modelo GEV10/15, como la planta desalinizadora que formaban parte de la micro-red AEROGEDESA han sido rediseñados antes de integrarlos en las nuevas micro-redes. La turbina eólica, también descrita en el apartado 3.2.1, con una altura del buje de 18 m, contaba con un generador síncrono de 15 kW de potencia nominal, excitado por un banco de condensadores y actualmente dispone de un aerogenerador síncrono de imanes permanentes. La planta desalinizadora tenía una capacidad de 18 m³/día y estaba compuesta por dos tubos de presión conectados en serie, de los cuales cada uno contenía tres membranas ubicadas en serie. Como ya se ha comentado previamente, dicha planta desalinizadora operaba con una presión de 64 bar, un caudal de 3125 l/h, con un 24 % de conversión.

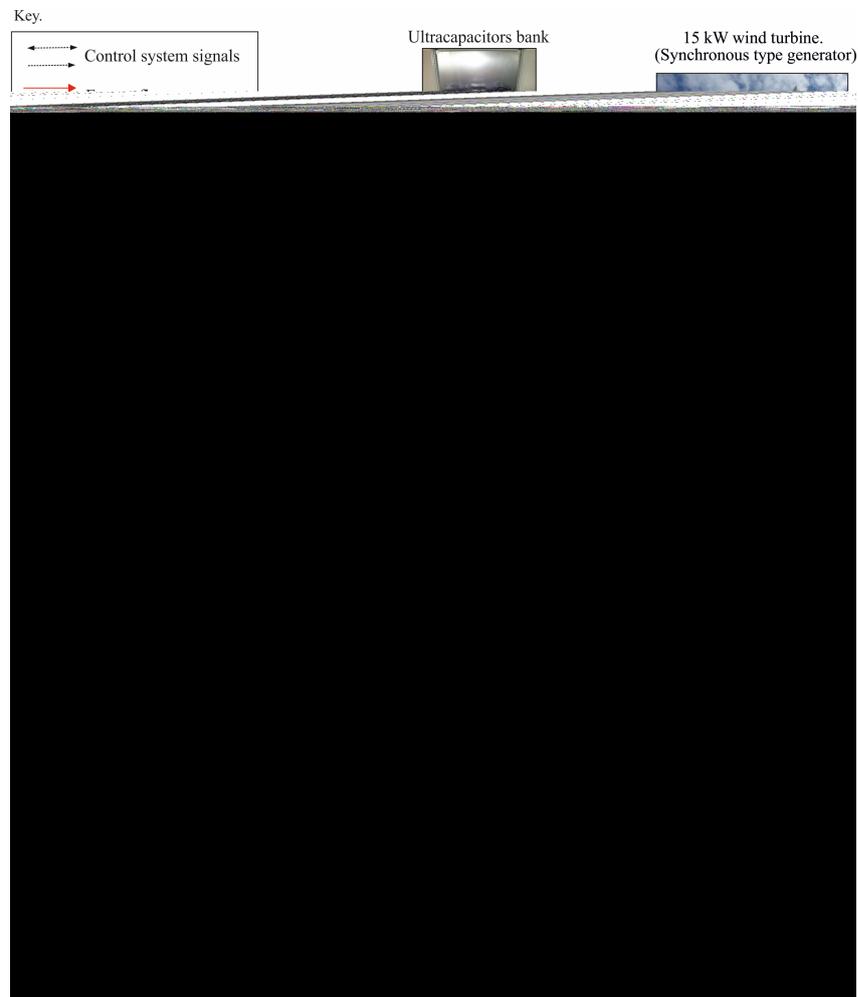


Fig. 8.2: Esquema general del la micro-red llamada MG-2.

El rediseño fundamental de la planta desalinizadora consistió en el cambio de la disposición en serie original de los dos tubos de presión (PV-1 y PV-2), a una disposición en paralelo de los mismos, Fig. 8.2. Diversos componentes de la planta desalinizadora fueron sustituidos para que la misma pudiese operar, en el caso de la MG-2, con una capacidad variable escalonada (con una estrategia similar a la utilizada en el proyecto SDAWES [91]). En el caso de la MG-2, el rediseño realizado permite no solo que se pueda seleccionar el número de tubos de presión que estén conectados en cada momento (PV-2 o PV-1 y PV-2), por la actuación de las válvulas SV-3 y SV-2, sino que puede variarse de forma continua la presión y cau-

dal (actuando sobre las válvula PSV y el convertidor de frecuencia). En el capítulo 4, se indica detalladamente el proceso seguido para adaptar de forma continua el consumo de la planta desalinizadora a la variabilidad de la energía generada por la turbina eólica. El banco de supercondensadores actúa como un elemento amortiguador de los cambios transitorios producidos cuando el sistema de control trata de ajustar la potencia demandada por la planta a la potencia suministrada por la turbina eólica. Este banco no será considerado en la simulaciones realizadas en este trabajo.

Como señalan Pohl et al. [6], las estrategias para variar la presión y el caudal de una planta desalinizadora de ósmosis inversa pueden ser diversas. En este contexto, Kim et al. [203] utilizan la estrategia de mantener la presión lo más constante posible y variar el caudal de alimentación para adaptar el consumo de una planta desalinizadora de OI a la variabilidad de la energía eólica. Sin embargo, la MG-2 ha sido ensayada con la estrategia de variar la presión y el caudal de alimentación para mantener una tasa de recuperación de permeado aproximadamente constante. En esta tesis (capítulos 4 y 6) y en algunos estudios que han sido publicados a partir de los resultados derivados de esta [98, 150], se demuestra que dicha estrategia es la más adecuada para operar una planta de este tipo con una amplia variación de la potencia generada por una turbina eólica, ya que proporciona mejores resultados, en cuanto a consumo específico de energía, calidad del agua producida y márgenes de variación de la presión de alimentación se refiere.

De acuerdo con los análisis teóricos realizados (capítulo 4 y [98]), el mayor rango de variación de potencia se obtiene con la tasa de recuperación que se obtiene al interceptar con los límites de flujo medio y máximo caudal de alimentación. Específicamente, en el sistema analizado en este estudio, la tasa de recuperación de permeado más apropiada es 13.56 %.

8.2.2 La técnica de *Machine Learning* considerada para realizar la simulación

Tal y como se detalló en el capítulo anterior, el prototipo ha sido sometido a diferentes ensayos con el propósito de determinar el comportamiento del mismo al

ser alimentado por una amplia variación de la energía suministrada por una turbina eólica y bajo diferentes combinaciones de características de agua de mar (conductividad y temperatura). Con dichos ensayos y los datos recogidos de ellos, se modelaron las técnicas analizadas en el capítulo anterior. Este análisis de las tres técnicas consideradas muestra como resultado que la técnica que mejor modela el sistema en estudio es la técnica *Random Forest*. Por ello, se ha empleado esta técnica para realizar la simulación.

8.2.3 Características de los datos de viento usados en las simulaciones

Las medias minutales de la velocidad del viento utilizadas en este estudio fueron medidas durante el año 2010 a una altura de 20 m sobre el nivel del mar en el sitio donde se encuentra instalado el prototipo ensayado. En la Fig. 8.3 se representan las velocidades medias horarias del viento, la velocidades medias mensuales del viento, los patrones intra-día de la velocidad del viento correspondientes a todo el año y a los meses de enero y julio (más alta y más baja velocidad media del viento) y el histograma de frecuencia de las velocidades del viento. En lugar de usar la distribución típica de Weibull de dos parámetros se ha usado una *Singly Truncated Normal–Weibull mixture distribution* [98], ya que esta provee un muy buen ajuste tanto para distribuciones de frecuencia de velocidades observadas en un sitio unimodales como para aquellas que son bimodales [141]. Las mínimas y máximas velocidades medias minutales del viento han sido 0 y 26.1 m/s.

8.3 Metodología

8.3.1 Simulación de la operación de la MG-2

En la Fig.4 se muestra un diagrama de bloques representativo del proceso seguido para simular el comportamiento temporal anual de la MG-2.

A partir de las velocidades medias minutales del viento (registradas durante un año a la altura del buje de la turbina eólica en el sitio donde se encuentra instalada la micro-red) se estiman las potencias $P_{WT,t}$ generadas en cada tiempo t por

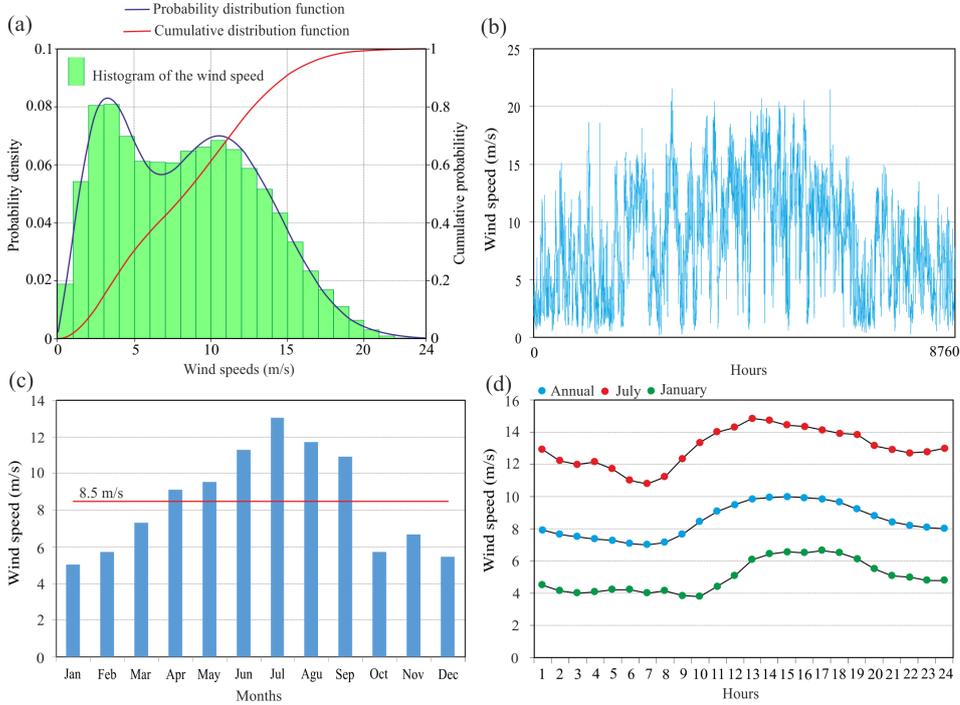


Fig. 8.3: a) Histogramas de frecuencias de velocidades de viento, b) velocidades medias horarias, c) velocidades medias mensuales y d) patrón intra-día de velocidades de viento.

la turbina eólica (WT), haciendo uso de la curva de potencia de la misma (dichas potencias son corregidas teniendo en cuenta el rendimiento η del convertidor de alterna a continua (AC/DC), que se ha estimado en 97 %. Las pérdidas de potencia del convertidor de continua a alterna (DC/AC) son aprendidas por los modelos ensayados). Si dicha potencia es mayor que la potencia $P_{cut-in(1-pressure\ vessel)}$ necesaria para que pueda operar un tubo de presión se conecta uno de ellos y mediante los modelos M1, M2, M3 y M4 calculados en el capítulo anterior y definidos por la Tabla 7.1 (los cuales han sido entrenados en este caso para aprender el funcionamiento del prototipo trabajando con un tubo de presión), se estiman la presión ($p_{f,t}$) y el caudal ($Q_{f,t}$) a los que debe operar la planta desalinizadora de OI en dicho momento t , así como el caudal de permeado ($Q_{p,t}$) y la conductividad del mismo ($C_{p,t}$).

En el caso de que la potencia generada por la turbina eólica y corregida con el

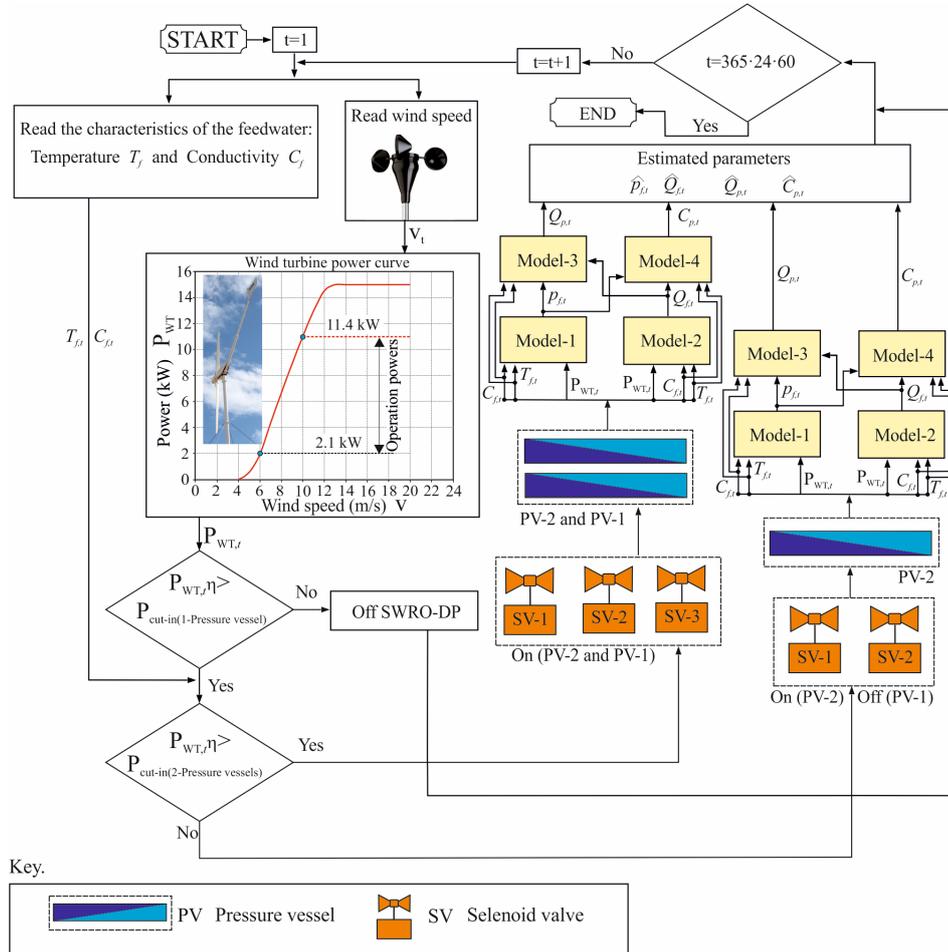


Fig. 8.4: Diagrama de bloques representativo del proceso seguido para simular el comportamiento temporal anual de la MG-2.

rendimiento del convertidor AC/DC ($P_{WT,t,\eta}$) sea mayor que la potencia $P_{cut-in(2-pressure\ vessel)}$ necesaria para que puedan operar dos tubos de presión se conecta adicionalmente el PV-1 (si el PV-2 ya estaba conectado) o los dos tubos (si no había ninguno conectado) y mediante los modelos M1, M2, M3 y M4 definidos en la Tabla 7.1 (los cuales han sido entrenados para aprender en este caso el funcionamiento del prototipo trabajando con dos tubos de presión), se estiman la presión ($p_{f,t}$) y caudal ($Q_{f,t}$) a los que debe operar la planta desalinizadora en dicho momento t , así como el caudal de permeado ($Q_{p,t}$) y la conductividad del mismo ($C_{p,t}$).

8.3.2 Simulación de la operación de la MG-1

En la Fig. 8.5 se muestra un diagrama de bloques que muestra la metodología utilizada para llevar a cabo la simulación el comportamiento temporal anual de la MG-1. Si las potencias $P_{WT,t}$ generadas en cada tiempo t por la turbina eólica y corregidas por el rendimiento del convertidor AC/DC son mayores que la potencia que precisa la planta desalinizadora para funcionar en régimen nominal $P_{SWRO-DPdemand}$ esta operará y la energía sobrante ($P_{WT,t} \cdot \eta - P_{SWRO-DPdemand}$) se destinará a la carga de las baterías, si estas no están llenas.

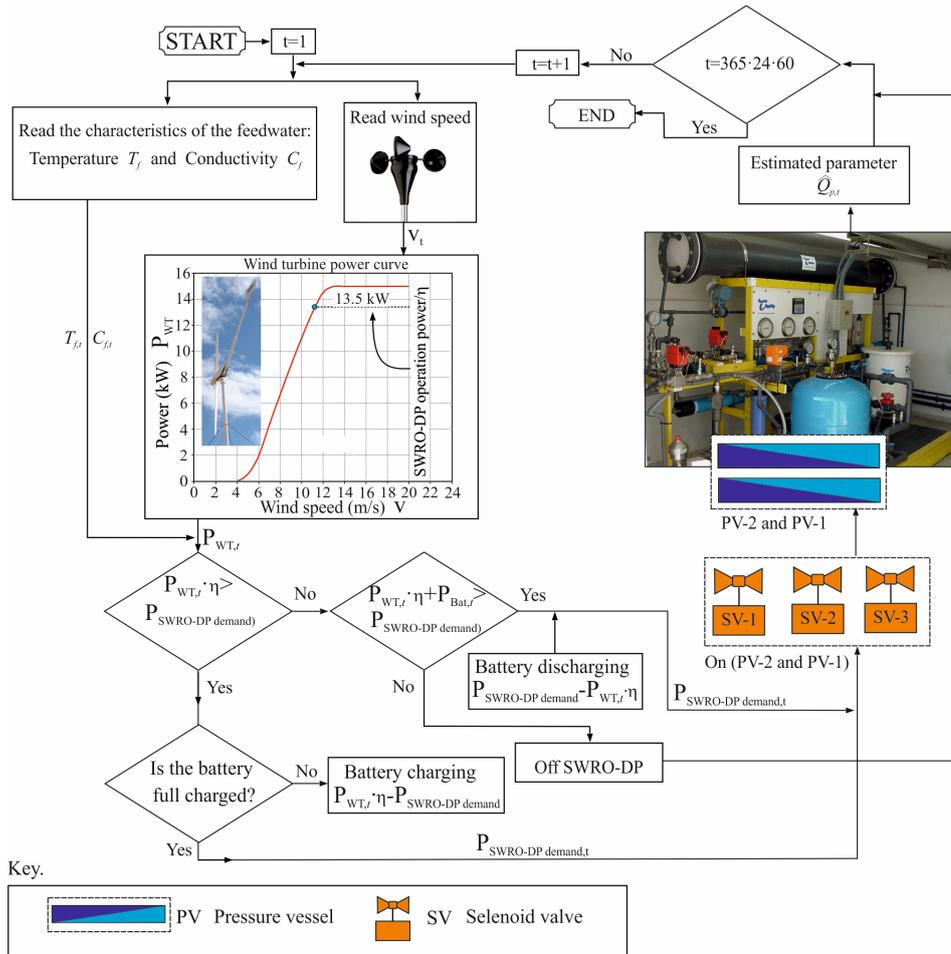


Fig. 8.5: Diagrama de bloques representativo del proceso seguido para simular el comportamiento temporal anual de la MG-1.

Si las potencias $P_{WT,t}$ generadas en cada tiempo t por la turbina eólica y corregidas con el rendimiento del convertidor AC/DC son menores que la potencia que precisa la planta desalinizadora para funcionar en régimen nominal $P_{SWRO-DPdemand}$ está operará si existe suficiente energía disponible en las baterías para ello. Las baterías deberán proporcionar la diferencia de potencias necesaria ($P_{SWRO-DPdemand} - P_{WT,t} \cdot \eta$). En este caso, cuando la planta desalinizadora esté operativa se consideran constantes las presiones y caudales de operación, así como los caudales de permeado y sus conductividades, a diferencia del caso en el que la planta desaladora trabaja en la MG-2.

Para determinar la cantidad de energía que puede ser absorbida o suministrada por el banco de almacenamiento energético en cada salto de tiempo, se ha utilizado el *kinetic battery model* propuesto por Manwell and McGowan [205].

8.4 Análisis y discusión de los resultados alcanzados al comparar el funcionamiento de las dos micro-redes

Como puede observarse en la Fig. 8.6, en la que se representan los porcentajes de operación mensual del prototipo de planta desalinizadora de OI en función de la micro-red en la que esté integrado, la planta de OI de la MG-2, dada su capacidad para adaptarse a las variaciones de la potencia generada por la turbina eólica como consecuencia de las variaciones de las velocidades del viento (Fig. 8.3), opera un 62.5 % del tiempo, mientras que cuando forma parte de la MG-1 con el banco de baterías (60 baterías de 2V cada una, unidas en serie: 120 V y 190 Ah) que disponía la micro-red AEROGEDESA (Fig. 8.1) el porcentaje de operación anual es del 51.6 %.

Dado el régimen de vientos de la zona (Fig. 8.3), el 56.5 % del tiempo la planta de OI de la MG-2 trabaja con dos tubos de presión y el 6 % con un solo tubo de presión. Por tanto, en este caso, dado el bajo porcentaje de operación del prototipo con un solo tubo de presión podría descartarse la estrategia de operación con capacidad variable y trabajar siempre con dos tubos de presión con presión y caudal variables. Ello, simplificaría el control de la planta desalinizadora y eliminaría los

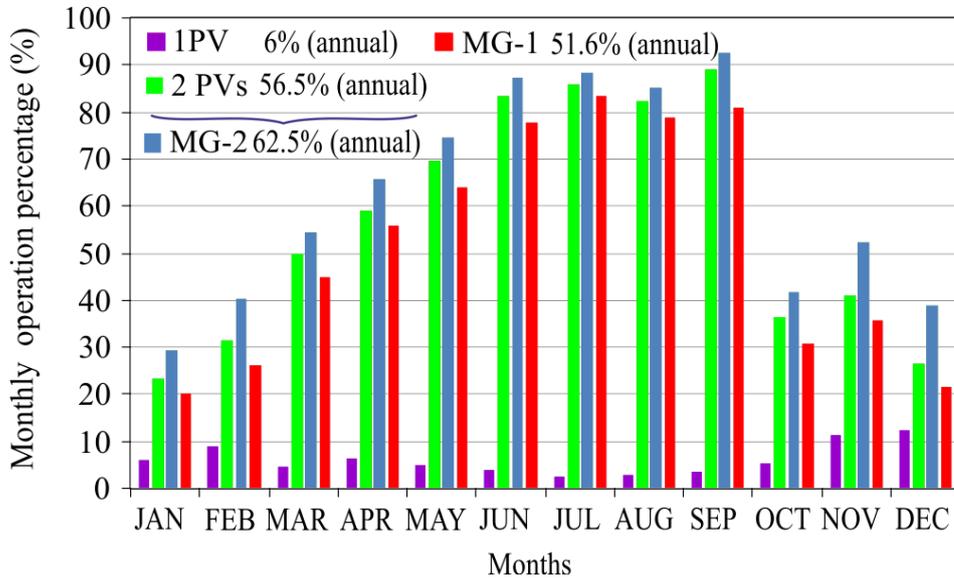


Fig. 8.6: Porcentajes de operación mensual del prototipo de planta desalinizadora en función de la micro-red (MG-1 o MG-2) en la que esté integrado.

inconvenientes que se presentan en los periodos transitorios de conexión/desconexión de los tubos de presión [98, 150]. Sin embargo, en el caso de regímenes de viento con mayores frecuencias de vientos bajos no debería descartarse a priori la estrategia de operación con capacidad variable de la planta desalinizadora.

En la Fig. 8.7 se muestra el cociente entre los arranques/paradas de la planta de OI de la MG-1 y los arranques/paradas del PV-2 y del PV-1 de la planta desalinizadora de OI de la MG-2. En este caso, las paradas de la planta de la MG-1 son superiores a las producidas por cualquiera de los dos PVs de la planta desalinizadora de la MG-2, contradiciendo este resultado uno de los argumentos que suelen esgrimirse para descartar el empleo de plantas desalinizadoras de OI operando en régimen variable.

Sin embargo, como puede observarse en la Fig. 8.8, donde se muestran los caudales mensuales de permeado producidos por el prototipo en función de la micro-red (MG-1, MG-2) donde se encuentra integrado, la planta desalinizadora de la MG-2 dado que opera con una tasa de recuperación de permeado entre 13.5 % y 13.6 % (para lograr un amplio margen de operación [98]), produce caudales mensuales de permeado menores a los que logra producir integrada en la MG-1, donde

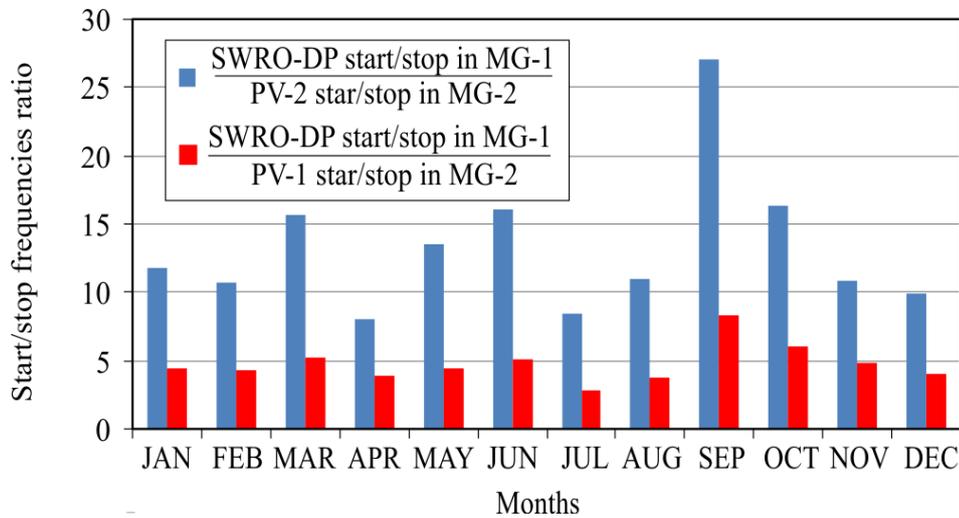


Fig. 8.7: Relación entre las frecuencias de arranques/paradas de la planta desalinizadora de la MG-1 y las frecuencias de arranques/paradas de los tubos de presión de la planta desalinizadora de la MG-2.

la tasa de recuperación de permeado es de 18.5 %. Según los resultados obtenidos con la planta desalinizadora integrada en la MG-1 se lograr producir 1.2 veces más caudal de permeado anual que si la misma operase integrada en la MG-2.

Puede observarse en la Fig. 8.9 que la conductividad media anual del agua de permeado producida por la planta desalinizadora de la MG-2 es de 425.38 $\mu\text{S}/\text{cm}$. Es decir, solo 1.08 veces mayor que la conductividad del permeado producido por la planta de OI de la MG-1.

En la Fig. 8.10 se indican las presiones de operación medias, máximas y mínimas de cada mes, mientras que en la Fig. 8.11 se indican los caudales de alimentación medios, máximos y mínimos.

El caudal medio anual de alimentación de la planta desalinizadora de la MG-2 es de 5.14 m^3/h , mientras que en la MG-1 dicho caudal de alimentación es de 5.86 m^3/h . Los caudales de alimentación de la planta desalinizadora de OI integrada en la MG-2 han oscilado entre 1y 6.05 m^3/h . El valor mínimo corresponde al caudal de alimentación mínimo necesario para que opere un tubo de presión y el valor máximo corresponde al caudal máximo de operación de la planta desalinizadora con dos tubos de presión.

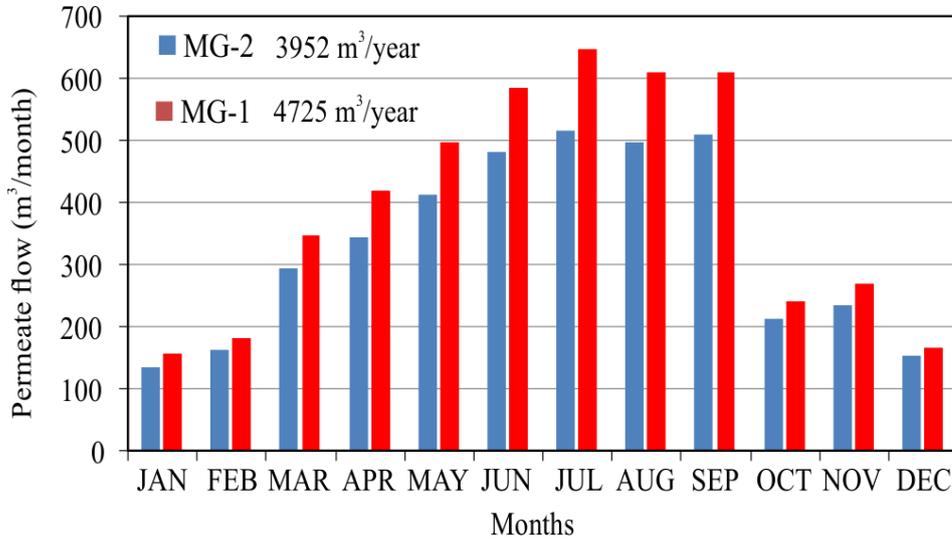


Fig. 8.8: Caudales medios mensuales de agua producto obtenidos en las simulaciones realizadas con las dos micro-redes.

La presión media de operación de la planta desalinizadora en la MG-2 ha sido de 45.71 bar, mientras que en la planta de OI integrada en la MG-1 dicha presión es de 57.8 bar. Los límites del intervalo de presiones en el que ha trabajado la planta de la MG-2, de acuerdo con las simulaciones minutas realizadas han sido 33.9 bar y 45.7 bar.

A título de ejemplo, en la Fig. 8.12 se representan las simulaciones (con saltos de tiempo de un minuto) de los comportamientos de ambas micro-redes en un día con una velocidad media del viento de 10.4 m/s y una desviación estándar de 2.6 m/s. Puede observarse en este caso como la planta desalinizadora de la MG-2 opera desde que las potencias generadas por la turbina eólica superan los 2.1 kW, produciéndose en todo el día 10 arranques/paradas, mientras que la planta desalinizadora de la MG-1, con el banco de baterías utilizado, requiere de mayores potencias para operar y se ve sometida a 36 arranques/paradas.

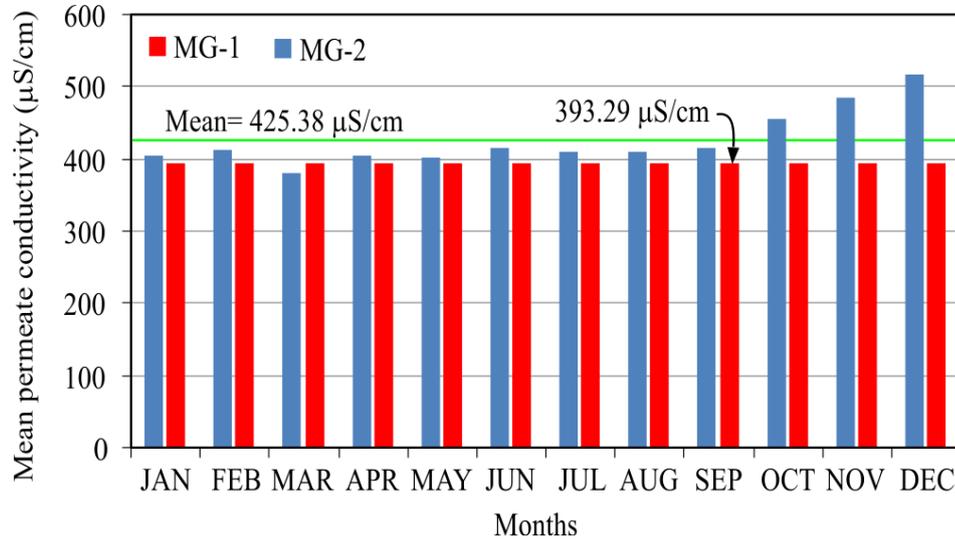


Fig. 8.9: Conductividades medias mensuales obtenidas en las simulaciones realizadas con las dos micro-redes.

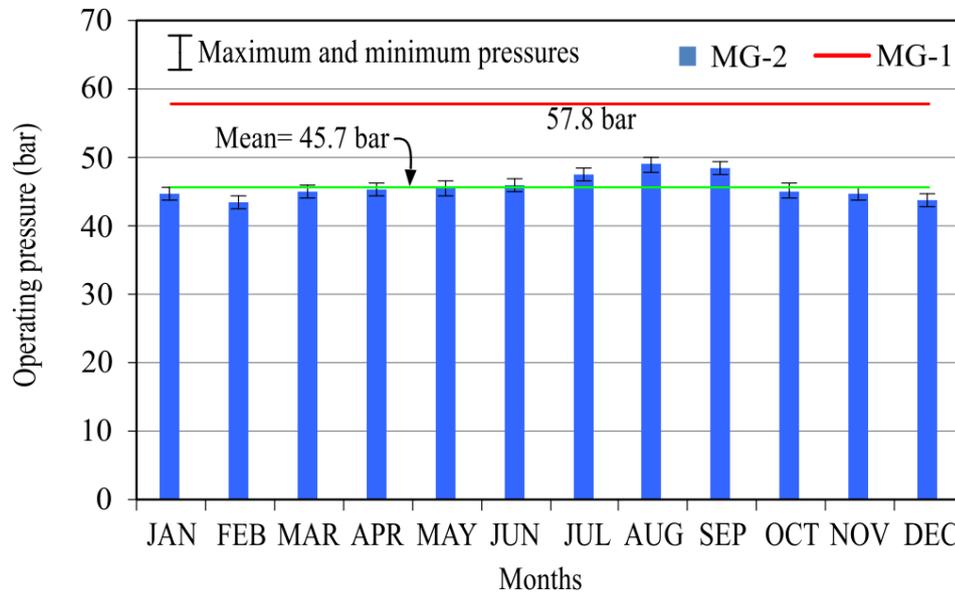


Fig. 8.10: Presiones de operación medios, máximos y mínimos registrados cada mes.

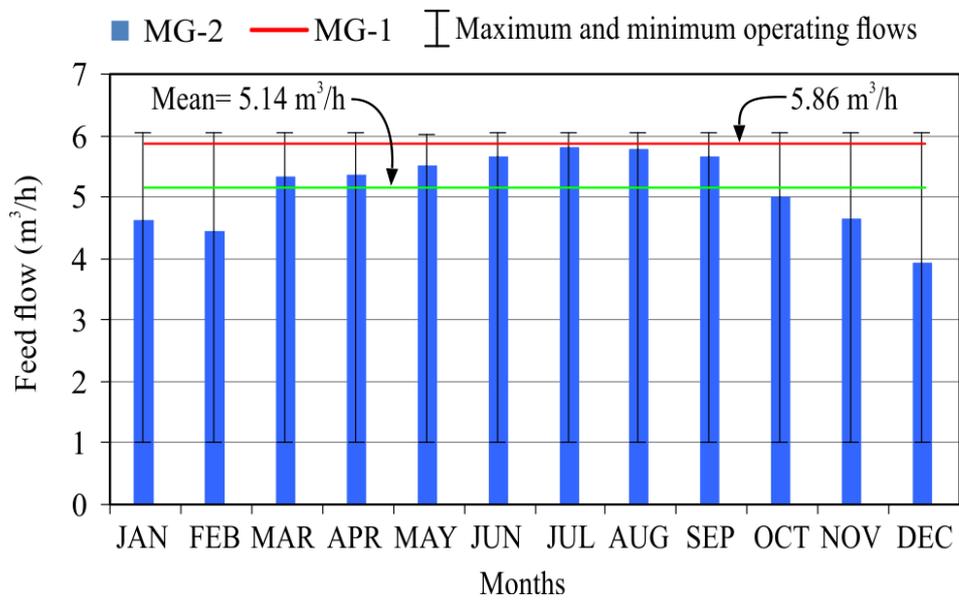


Fig. 8.11: Caudales de operación medios, máximos y mínimos en cada mes.

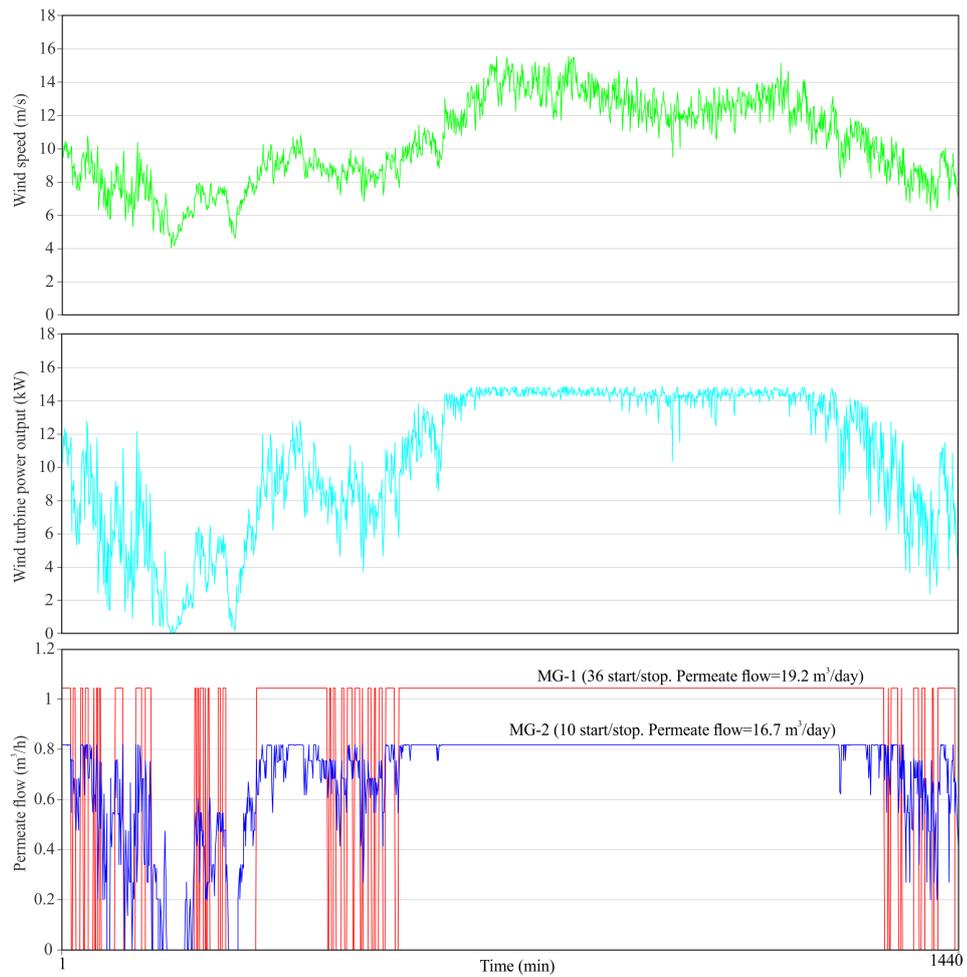


Fig. 8.12: Simulación del comportamiento de las micro-redes (MG-1 y MG-2) en un día con una velocidad media del viento elevada.

Conclusiones

En este último capítulo se pretende recopilar las aportaciones más relevantes que esta tesis doctoral hace al cuerpo del conocimiento, las conclusiones generales tras el análisis de los resultados obtenidos y las líneas de actuación que se proponen para que, a partir de este trabajo, continúe desarrollándose esta línea de investigación.

9.1 Aportaciones que hace esta tesis doctoral al cuerpo del conocimiento

A continuación, se expone un listado de las aportaciones más relevantes que esta tesis hace al cuerpo del conocimiento, en este trabajo:

- Se estudia y se analiza experimentalmente un prototipo de planta desalinizadora de OI, el cual se conecta a la red eléctrica convencional, pero en el que se gestiona el número de tubos de presión que actúan en cada momento y se regulan las variables de presión y caudal de operación en los mismos (dentro de los límites admisibles determinados), siguiendo la estrategia de mantener la tasa de recuperación de permeado constante para adaptar el consumo

de la planta a una amplia oferta de potencia eólica simulada y minimizar las frecuencias de arranques-paradas de la misma. Los estudios preliminares que derivan en esta aportación han sido desarrollados en el capítulo 4 de esta tesis y han servido de fundamento para publicar el artículo «Preliminary experimental analysis of a small-scale prototype SWRO desalination plant, designed for continuous adjustment of its energy consumption to the widely varying power generated by a stand-alone wind turbine» [98], que puede encontrarse en el Apéndice A.

- Se propone el uso de técnicas de ML para gestionar y adecuar *on-line* y en tiempo-real el consumo energético de una planta desalinizadora a la potencia proporcionada por una turbina eólica. Se implementa e integra una de estas técnicas (ANNs) en el sistema de control del prototipo para demostrar la capacidad de las técnicas de ML para generar las señales de referencia apropiadas que permiten la adaptación del consumo energético de la planta a una amplia variación de la energía suministrada por la turbina eólica (capítulo 6, [150]). La técnica implementada ha sido capaz de hacer operar la planta desalinizadora con una conversión aproximadamente constante y sin violar los límites de operación del sistema de membranas (capítulo 4, [98]). Esta aportación ha sido descrita en el capítulo 6 y forma parte del artículo «Artificial neural networks applied to manage the variable operation of a simple seawater reverse osmosis plant» [150], que puede encontrarse en el Apéndice A.
- Dadas las particularidades del sistema que se pretende controlar y teniendo en mente el hecho de que las técnicas de ML son altamente dependientes de la muestra de datos empleada para su entrenamiento [206], se propuso una estrategia de captura de datos específica para el entrenamiento de las técnicas empleadas. Asimismo, se describió y se implementó una metodología para configurar este tipo de técnicas cuando se aplican en sistemas de desalinización como el analizado en esta tesis. La metodología, basada en el uso de algoritmos genéticos, ha sido descrita en el capítulo 6 y forma parte del artículo «Artificial neural networks applied to manage the variable operation

of a simple seawater reverse osmosis plant» [150], que puede encontrarse en el Apéndice A.

- Se comparan tres técnicas de ML empleadas para simular el comportamiento del prototipo analizado. Se calculan los errores cometidos por cada una y se analiza si existen diferencias estadísticamente significativas entre el uso de cualquiera de ellas. Este análisis ha sido desarrollado en el capítulo 7 y ha formado parte del artículo «Wind-driven SWRO desalination prototype with and without batteries: A performance simulation using machine learning models» [207], que puede encontrarse en el Apéndice A.
- Se simula y se compara el comportamiento de los dos tipos de micro-redes eléctricas más discutidos en el ámbito de las micro-redes eléctricas aisladas accionadas con energía eólica para desalinizar agua de mar mediante ósmosis inversa. Estos son:
 - a) el propio prototipo considerado en la tesis, que representa una micro-red eléctrica aislada basada en una turbina eólica y una planta desalinizadora, sin ningún sistema de almacenamiento masivo de energía, y
 - b) una mico-red eléctrica aislada con la misma planta desalinizadora y la misma turbina, pero que emplea un sistema de almacenamiento energético basado en baterías.

Ello se hace con el objetivo de dar un primer paso en el análisis de un fenómeno ampliamente citado en la literatura científica pero que, bajo nuestro punto de vista, no ha sido explorado debidamente. El fenómeno referido es: cómo afecta la interrumpibilidad en ambos tipos de micro-redes eléctricas. Este estudio se desarrolló en el capítulo 8 y ha formado parte del artículo «Wind-driven SWRO desalination prototype with and without batteries: A performance simulation using machine learning models» [207], que puede encontrarse en el Apéndice A.

9.2 Conclusiones

Las conclusiones más relevantes que se deducen tras la realización de esta tesis son las que se exponen a continuación:

- Se demuestra viable modificar el consumo de una planta desalinizadora de agua de mar, que utiliza el método de ósmosis inversa, y se adapta a una amplia variación de potencia eléctrica producida por una turbina eólica.
- Se considera probada de manera exitosa la propuesta de usar técnicas de ML como herramienta integrada en los sistemas de control de plantas desalinizadoras de pequeña escala accionadas por energía eólica. Se ha demostrado que el uso de modelos de redes neuronales artificiales, entrenados e incorporados al sistema de control de la planta desalinizadora, permite la adaptación continua de su consumo energético a una generación eléctrica variable basada en la fuente eólica. Esta adaptación se logra gracias a que las ANNs generan consignas de caudal y presiones de operación que tienen en cuenta la energía suministrada por la turbina, pero también las características cambiantes del agua de alimentación (temperatura y conductividad).
- Al comparar tres técnicas de ML propuestas para modelar y simular el comportamiento del prototipo empleado, se concluye que, si bien, la técnica ANN ha sido la utilizada hasta la fecha como técnica de regresión implementada en los modelos de predicción del funcionamiento de plantas de OI [13, 16, 18, 125, 130], los resultados obtenidos en este trabajo nos llevan a proponer la utilización de las técnicas *Support Vector Machines* y *Random Forest* (en especial esta última), en lugar de aquella, ya que se puede lograr que los errores cometidos en las predicciones sean significativamente menores. De la observación de los resultados obtenidos (Fig. 7.4) se concluye que, en todos los modelos considerados, la técnica de ANN ha generado mayores métricas de error que las técnicas SVM y RF. La técnica RF ha proporcionado en el 62.50 % de los casos mejores métricas que la técnica SVM.
- Con respecto a la simulación llevada a cabo para comparar el comportamiento de los dos tipos de micro-redes eléctricas aisladas más discutidos en este

ámbito de estudio, se concluye que, cuando la planta desalinizadora está integrada en una micro-red que no utiliza sistema de almacenamiento de energía (pero que adapta su potencia al suministro energético de forma variable) opera un 62.5 % del tiempo. Sin embargo, cuando sí se utiliza un sistema de almacenamiento de energía basado en baterías (pero opera a régimen nominal constante, conectando los módulos de desalinización cuando existe energía suficiente), con el banco de baterías considerado (60 baterías de 2V cada una, unidas en serie: 120 V y 190 Ah) el porcentaje de operación anual es del 51.6 %. Las frecuencias de los arranques/paradas de la planta desalinizadora del segundo sistema (con baterías) son mayores que las producidas por el sistema que no emplea baterías, contradiciendo este resultado uno de los argumentos que se suelen esgrimir para descartar el empleo de plantas desalinizadoras de ósmosis inversa operando en régimen variable. No obstante, con la planta desalinizadora que emplea baterías, donde la tasa de recuperación de permeado es más elevada, se lograr producir 1.2 veces más caudal de permeado anual que si la misma operase integrada en una micro-red eléctrica sin baterías pero con un sistema de control que permite su operación variable. Además, la conductividad media anual del permeado producido por esta última es 1.08 veces mayor que la conductividad del permeado producido por el sistema con baterías.

9.3 Líneas futuras de investigación propuestas

Durante la realización de este trabajo de investigación se han ido resolviendo las hipótesis inicialmente planteadas pero también se han ido generando nuevas hipótesis e incógnitas no previstas al comienzo. Algunas de ellas han sido resueltas en este trabajo pero otras, dada la imposibilidad material de llevarlas a cabo en el marco de esta tesis, requieren de actuaciones futuras e, incluso, de la apertura de nuevas líneas de investigación. Por tanto, a continuación se señalan aquellas líneas de trabajo en las que, en base a los resultados y conclusiones obtenidas en esta tesis, se considera necesario profundizar en el futuro.

En primer lugar, se enumeran las líneas de trabajo específicas a desarrollar en el prototipo desarrollado:

- Los estudios desarrollados en esta tesis se han centrado en la gestión inteligente y en la flexibilización de una planta desalinizadora integrada en una micro-red eléctrica cuya fuente energética principal es una turbina eólica. Sin embargo, hasta la fecha, todos los ensayos realizados han considerado un comportamiento simulado de la turbina eólica. Aunque los resultados obtenidos en la planta aventuran una buena integración de ambos sistemas (turbina y planta), es indispensable, como línea de actuación futura, validar dicha conexión.
- En los resultados de los diversos ensayos realizados en la planta se ha detectado una relativa lentitud del sistema de control para lograr adaptar instantáneamente el consumo de potencia de la planta a la potencia variable generada por la turbina eólica. Ello es debido a los tiempos de respuesta inherentes de los elementos de desalación. Por ello, se precisa implementar un dispositivo de regulación dinámica que sea capaz de suministrar y almacenar la energía necesaria para cubrir las variaciones instantáneas de la potencia generada por la turbina eólica respecto de las potencias de consumo reales. En esta tesis se ha propuesto el uso de un supercondensador como sistema de regulación dinámica, encontrándose ya la investigación en esta materia en fase de análisis y experimentación.
- Como ya se ha señalado previamente, los modelos de ML implementados en el sistema de control del prototipo han generado las consignas de operación (caudal y presiones de alimentación objetivo) manteniendo la tasa de recuperación de permeado constante, dentro de un margen de variación específico. Sin embargo, en situaciones muy concretas se han detectado valores instantáneos de presión y caudal que provocan que las membranas trabajen fuera de su límite óptimo de operación (capítulo 4, [98]). Estos valores de tasa de recuperación atípicos no son consecuencia de las consignas generadas por los modelos ANN sino del algoritmo empleado para regular el convertidor de frecuencia (y, por tanto, el caudal de alimentación) y del algoritmo

empleado para regular la servoválvula PSV (y, por tanto, la presión de operación). Una línea de trabajo a realizar es sustituir los tradicionales algoritmos de control (proportional-integral and proportional-integral-derivative) por algoritmos basados en técnicas ML con el objetivo de evaluar su eficacia frente aquellos al actuar como bucles de control cerrado. Esta tarea se plantea realizar en el marco del proyecto DESAL+ (MAC/1.1a/094) financiado por el programa INTERREG MAC 2014-2020 (fondos FEDER).

- Hay que señalar que los modelos basados en técnicas de ML usados en este trabajo no se han alimentado de las potencias que realmente produciría la turbina eólica en el lugar donde esta se encuentra ubicada, sino que el funcionamiento de la misma ha sido simulado haciendo uso de su curva de potencia y de las series temporales de viento registradas en el lugar. En este contexto, hay que resaltar que los modelos empleados en este trabajo para las simulaciones realizadas (de las dos configuraciones de micro-redes que integran un sistema de desalación y una turbina eólica) pueden ser mejorados si las ML son también adecuadamente entrenadas para aprender la operación real de la turbina eólica ante la variación de parámetros meteorológicos (velocidad y dirección del viento, presión atmosférica, temperatura y humedad relativa del aire). Ello, permitiría simular de forma más realista el comportamiento del prototipo de planta desalinizadora de OI empleado al variar los mencionados parámetros meteorológicos y las características del agua de alimentación.

En segundo lugar, se enumeran aquellas líneas que, a nivel general, pueden desarrollarse dentro del área de las microneas diseñadas con el propósito de desalinizar agua con turbinas eólicas aisladas:

- En este sentido, se propone el uso combinado de las técnicas de ML junto con modelos numéricos de predicción meteorológica [208] para predecir en horizontes temporales de muy corto plazo (pocos segundos hasta 30 minutos), de corto plazo de tiempo (30 minutos hasta 6 horas), de plazo medio (de 6 horas a 24 h) y de largo plazo (de 1 día hasta 7 días), variables como los caudales de agua de permeado y sus características, pero también parámetros relacionados con el procesado de alarmas, la detección de fallos, la evaluación de

seguridad en la planta y la optimización operativa. El uso de técnicas de ML (o de inteligencia artificial) para estas tareas ya fue prouesta por El-Hawary en 1993 [125]. Se propone la predicción a muy corto plazo para mejorar el control de las turbinas eólicas así como para controlar las presiones y caudales de operación de las plantas desalinizadoras que se implementen para adaptar su consumo a la generación eólica. Las predicciones a corto plazo pueden utilizarse para gestionar los tubos de presión [150] o los módulos/-bastidores [84] de una planta desalinizadora de OI que deben operar. Los pronósticos de medio plazo pueden utilizarse para la gestión del almacenamiento del agua producida en función de las predicciones de la demanda, la cual también puede ser estimada utilizando técnicas de ML [209–211]. Los pronósticos a largo plazo pueden ser útiles a la hora de programar el mantenimiento de la micro-redes y para reentrenar las técnicas de ML con los datos de operación que se hayan ido registrando de tal manera que estas tengan en cuenta factores tales como el envejecimiento de las membranas.

- También conviene investigar el uso de las técnicas de ML para apoyar las tareas de planificación de la gestión de operación de estos sistemas. En base a la literatura revisada y a los resultados logrados, se considera que estas técnicas pueden predecir la demanda de agua desalinizada como ha señalado El-Hawary [125]. Asimismo, pueden predecir la energía obtenible de una turbina eólica o de un parque eólico completo. En base a dichas predicciones pueden planificarse las estrategias de operación de las plantas desalinizadoras para satisfacer una demanda dada.

Por último, se señalan aquellas líneas de investigación que pueden desarrollarse aplicando este concepto de flexibilidad y gestión inteligente a plantas desalinizadoras de mayor tamaño.

- En este sentido, dado que todos los procedimientos y resultados alcanzados hasta la fecha han sido aplicados y han sido obtenidos en un prototipo de planta desalinizadora de pequeña escala, la primera cuestión a resolver es si el concepto expuesto en esta tesis es aplicable a plantas desalinizadoras de mayor escala. En relación a ello, aunque aún se necesitan realizar más

investigaciones experimentales con prototipos de pequeño tamaño antes de poder extrapolar resultados a sistemas de mayor tamaño, se pueden intuir algunas tendencias a partir de los resultados obtenidos en esta tesis:

- Por un lado, se puede decir que, en sistemas de desalación de mayor capacidad, pueden plantearse también estrategias que involucren el uso de energía eólica y de técnicas de ML. En base a ello, existen trabajos previos, desarrollados en este mismo grupo de investigación, en los que se ha diseñado y operado una planta de desalación modular de pequeña capacidad (8 módulos de 25 m³/día, es decir, una capacidad total de 200 m³/día) que ha trabajado accionada por dos turbinas eólicas de 230 kW cada una, aisladas de la red eléctrica convencional [84] . En este sistema se explotaba la modularidad de la planta desalinizadora, conectando y desconectando módulos (líneas), con el propósito de que la variación de la demanda de energía para desalinización esté en simpatía con la generación eólica. Si la generación era superior a la carga, se incrementaba la carga para mantener la tensión y la frecuencia constantes. Si la carga era superior a la generación, se disminuía la carga. Cada módulo (línea) operaba en régimen de presión y caudal de alimentación constantes (sin sistemas de recuperación de energía), pero podrían modificarse para operar dentro de un cierto rango de presión y caudal de alimentación haciendo uso de técnicas de ML.
- Por otro lado, este concepto también podría extrapolarse a sistemas de desalación con mayores capacidades integrados en las redes de abastecimiento de agua potable. En concreto, las técnicas de ML pueden ajustar los parámetros de operación de líneas de desalación para adaptar su capacidad de producción (entre ciertos márgenes) a una oferta energética variable y a la variabilidad de las características del agua de alimentación. En este contexto, conviene señalar que en la red de abastecimiento de agua potable de la isla de Gran Canaria existe una planta de desalación la cual puede variar su producción de forma continua entre 7500 y 10000 m³/día. Dicha planta está instalada en una zona donde

el agua de alimentación ve modificada sustancialmente su conductividad a lo largo del año como consecuencia de la mezcla del agua de mar con las corrientes subterráneas de agua dulce procedentes de las lluvias. Las técnicas de ML pueden colaborar en ajustar los parámetros de operación de dichas plantas para optimizar su operación. Es cierto, que todo ello requiere de una investigación más profunda.

- Asimismo, consideramos que el debate con respecto a los potenciales efectos perjudiciales en las membranas de OI de los ciclos de arranques-paradas y de variación de la carga durante periodos oscilatorios del recurso renovable aún no está cerrado. De hecho, existen algunos estudios muy recientes, como el recientemente aceptado en la revista *Desalination* [202], en los que se indica que el impacto de la operación intermitente en el ensuciamiento de la membrana todavía no se entiende bien y subrayan que este tema requiere más investigación. Por tanto, se propone iniciar una línea de investigación rigurosa en este sentido.

En otro orden, dada la capacidad de flexibilización demostrada por la planta desalinizadora de OI en estudio, también se considera oportuno iniciar una línea de trabajo más amplia para analizar cómo la desalinización puede ayudar a integrar una mayor cantidad de energías renovables en un sistemas energéticos completos. En base a ello, se propone analizar la máxima capacidad de integración de renovables alcanzada en un sistema energético en concreto al variar el consumo en las plantas desalinizadoras instaladas en el mismo. Además, se podría evaluar cómo afectan las distintas tecnologías de desalación a la integración de fuentes energéticas fluctuantes de origen renovable.

Conclusions

This last chapter is aimed to collect the most relevant contributions this PhD thesis makes to the body of knowledge, the general conclusions attained from the analysis of results and the proposed actuation lines to continue the development of this research work in the future.

9.1 Contributions of this PhD thesis to the body of knowledge

The most relevant contributions that this PhD thesis makes to the body of knowledge are exposed below.

- A small-scale SWRO desalination plant prototype is experimentally analysed after connecting it to the conventional grid while controlling the number of pressure vessels that are connected/disconnected to/from the system at each moment and regulating their operating pressures and flow rates (within predetermined acceptable limits). The control strategy followed attempts to maintain a constant permeate recovery rate, adapting the energy consumption of the plant to a widely varying simulated wind energy supply and minimising the frequency of plant start-up/shut-downs. That is, the results of a

hybrid operating strategy are presented based on a variation of the operating concept of the SDAWES project [91], replacing the flywheel with a super-capacitor bank, and on one of the operating strategies of variable pressure and flow rate as presented by Pohl et al. [6]. This contribution, developed in chapter 4, has been published on the paper «Preliminary experimental analysis of a small-scale prototype SWRO desalination plant, designed for continuous adjustment of its energy consumption to the widely varying power generated by a stand-alone wind turbine» [98], found in Appendix A.

- The use of ML techniques is proposed to manage and to fit, in real-time and on-line, the energy consumption in SWRO desalination plant prototype to the energy provided by a wind turbine.

For the first time the modelling (training and validation) and use of ANNs as control system tools for the small-scale prototype SWRO desalination plant have been tested with a view to enabling continuous adaptation of the plant's energy consumption to the simulated variable electrical energy generation of a stand-alone wind turbine. This contribution has been exposed in chapter 6 and it is part of the paper «Artificial neural networks applied to manage the variable operation of a simple seawater reverse osmosis plant» [150], found in Appendix A.

- Given the particularities of the system that is intended to manage and bearing in mind the fact that operation of ML techniques is highly dependent on the selection of the data used for their training, a specific strategy is proposed and implemented to carry out the capture of the operating data of the SWRO desalination plant which are used for training and validation of the ML models. Likewise, a methodology, based on genetic algorithm, is described and implemented which justifies the selection of the number of hidden layers and the number of neurons which the ANNs need to resolve the engineering problem under consideration (capítulo 6, [150]).
- Three ML techniques have been compared with a view to determining which technique best simulates the performance of the system in the face of variation of these operating parameters. This analysis has been exposed in chapter

7 and it is part of the paper «Wind-driven SWRO desalination prototype with and without batteries: A performance simulation using machine learning models» [207], found in Appendix A.

- A simulation (using ML models) of the year-long performance of an SWRO desalination plant prototype working under variable pressure and flow conditions [98], adapting its energy consumption to the varying nature of the energy generated by a wind turbine used to power it. It is also undertaken a comparison of the behaviour over time of this type of microgrid with the behaviour of a microgrid which, in addition to the SWRO desalination plant and wind turbine, includes a battery-based massive energy storage system and in which the desalination plant operates under constant pressure and flow conditions. This contribution, developed in chapter 8, is part of the paper «Wind-driven SWRO desalination prototype with and without batteries: A performance simulation using machine learning models» [207], found in Appendix A.

9.2 Conclusions

The most relevant conclusions that are deduced after carrying out this thesis are exposed below:

- From the tests performed to date, adaptation of the energy consumption of the prototype SWRO desalination plant to widely varying (simulated) wind turbine-generated power is demonstrated feasible.
- The analysis undertaken has demonstrated the ability of ML techniques and, concretely ANN models, to manage the operating setpoints of the SWRO desalination plant and to successfully adapt the energy consumption of the plant to the wide and random variation of the available electrical power.

The ANN models implemented in the control system generate the operating feed flow and pressure setpoints while attempting to ensure that the permeate recovery rate is kept within a particular variation range.

- In the comparison of the three ML proposed techniques, as a result of the statistical hypothesis testing which was performed to verify whether the differences between the metrics generated with the three ML techniques were significant, the RF technique gave better results in 62.50 % of the cases than the SVM technique. Moreover, in 37.5 % of the cases, the results obtained with the RF technique were significantly (5 % significance level) better than those obtained with the SVM technique. The results obtained in the present study therefore suggest recommendation of the SVM and RF techniques (especially the latter) to undertake prediction of SWRO desalination plants performance rather than the ANN technique (the most used until now [13, 16, 18, 125, 130]), as better metrics of the errors committed in the predictions can be obtained.
- Related to the performance simulation carried out for comparing the behaviour of the two types of micro-grids discussed in the present work, the SWRO desalination plant integrated in the micro-grid which does not use batteries (MG-2) operates 62.5 % of the time, whereas when it forms part of the micro-grid with batteries (MG-1) with its battery bank (60 × 2 V batteries connected in series: 120 V and 190 Ah) the annual operating percentage is 51.6 %. The frequencies of the starts/stops of the SWRO desalination plant of MG-1 are greater than those produced by either of the two pressure vessels of the SWRO desalination plant of MG-2, with this result contradicting one of the arguments commonly put forward to reject the use of SWRO desalination plants operating under variable conditions.

However, with the SWRO desalination plant of MG-1, which had a permeate recovery rate of 18.5 %, it was possible to achieve an annual permeate flow rate of 1.2 times higher than if operating when integrated in MG-2, which operates with permeate recovery rates of between 13.5 % and 13.6 % (to achieve a wide operating margin). In addition, the mean annual conductivity of the permeate produced by the SWRO desalination of MG-2 was 1.08 times higher than the conductivity of the permeate produced by the SWRO desalination plant of MG-1.

9.3 Future proposed research lines

While this research work has been carried out, the hypotheses initially raised have been solved but also it has been generating new and unknown hypotheses which had not been expected when this work began. Some of them have been solved in this work. However, others, given the material impossibility, require future actuations and even the opening of new research lines. In the following lines it will be highlighted those research lines in which, regarding results and conclusions derived from this thesis, it is considered necessary to deepen in the future.

First, the specific lines focused in the developed prototype are enumerated:

- The developed studies in this thesis have focused on the smart managing and increasing of flexibility of a desalination plant integrated in an electrical micro-grid with a wind turbine as main energy source. However, until now, all tests carried out have considered the simulated behaviour of the wind turbine. Although obtained results on desalination plants advance a good integration of both systems (wind turbine and desalination plant), it is considered indispensable to validate this connection.
- In results obtained in different tests carried out, it has detected that there is a relatively slowness of the control system for adapting the power consumption to the variable power generation supplied by the wind turbine. Given this slowness of the control system as well as the response times inherent to the desalination elements, a dynamic regulation device needs to be incorporated to achieve the goal of instantaneous adaptation of the SWRO desalination plant power consumption to the variable wind turbine generated power.
- As it was commented before, ML models implemented in the control system generate the operating feed flow and pressure setpoints while attempting to ensure that the permeate recovery rate is kept within a particular variation range.

However, some instantaneous values of this rate (with a very low level of occurrence) were observed which pushed the membrane system beyond its acceptable operating limits (chapter 4, [98]). These permeate recovery rate

outliers are not a consequence of the interventions of the ANN models, but are the result of the algorithm which regulates the frequency converter (and hence the feed flow) and of the proportional-integral-derivative control algorithm which regulates the PSV valve (and hence the operating pressure). With a view to preventing the generation of a permeate recovery rate that would see the membrane system working beyond its acceptable operating limits, optimal adjustment of the parameters of the controllers is required with the restriction that the errors between the reference and actual operating powers are bounded. One interesting research line to work into is to analyse the replacement of traditional control algorithms (proportional-integral and proportional-integral-derivative) by ML based algorithms. This task is planned to carry out in the framework of DESAL+ project (MAC/1.1a/094) co-funded by FEDER funds, INTERREG MAC 2014-2020 program.

- it should be stressed that the models based on ML techniques used in the present study for simulation of the operation of the SWRO desalination plant prototype were not fed with the power outputs that the wind turbine would actually generate at the site where it is located. Instead, operation of the wind turbine was simulated using its power curve and the time series of wind data recorded over a period of one year at the site in question. In this respect, it should be noted that the simulation models of micro-grids comprised of wind-powered desalination systems with RO technology can be improved if the ML techniques are also appropriately trained to learn the actual operation of the wind turbine when considering variation of the meteorological parameters (wind speed and direction, atmospheric pressure and relative air humidity). This would allow a more realistic simulation of the performance of the SWRO desalination plant prototype with variation of these meteorological parameters and the feed water characteristics.

Secondly, those lines which can be developed are enumerated. They are in general within the field of micro-grids designed for the purpose of water desalination with stand-alone wind turbines.

- In this respect, we propose the use of ML techniques together with numerical weather prediction models (NWP) [208] to predict, in very short-term (a few seconds up to 30 minutes), short-term (30 minutes up to 6 hours), medium-term (6 hours to 24 h) and long-term (from 1 day to 7 days) time horizons, wind-powered desalination plants permeate flow rates and other permeate characteristics and, in addition, parameters related to alarm processing, fault detection, security assessment and operational optimization. The use of ML (or some other technique from artificial intelligence field) for these purposes has been proposed by El-Hawary in 1993 [125].
- Very short-term forecasts can be employed for wind turbine control as well as to control the operating pressure and flow rates of a SWRO-DP to adapt its consumption to wind energy generation. Short-term forecasts can be used to manage the pressure vessels [150] or the modules or lines [84] of an SWRO desalination plant that need to operate. Medium-term forecasts can be used to manage product water storage according to predictions of the demand (which can also be estimated using ML techniques [209–211]). Long-term forecasts can be useful when scheduling micro-grid maintenance and to retrain the ML techniques with the operating data that have been recorded so that the techniques can take into account factors such as membrane ageing.
- As for operation management planning tasks of these systems, we consider that ML techniques could be used to predict desalinated water demand, as reported by El-Hawary [125] and to predict the energy that can be obtained from a wind turbine or wind farm. Based on such predictions, the operating strategies of SWRO desalination plants could be planned with a view to satisfying a given demand.

Finally, what is stressed are those research lines which can be developed applying this flexibility and smart managing concepts to larger-scale desalination plants.

- In this sense, given all procedures and results until now have been applied and obtained from a small-scale desalination plant prototype, the first question to solve is if this exposed concept can be applied to larger-sized desalination

plants. On this basis, given the current state of the research we are conducting, we would like to state that in our opinion more experimental research is still required with small-scale prototypes before the results can be extrapolated to larger-sized systems. However, what can be advanced is some trends from the attained results:

- In response to this question, on the one hand we would like to point out that strategies can also be considered for higher capacity desalination systems that involve the use of wind energy and ML techniques. In previous works developed by directors of this thesis, small-capacity modular desalination plants have been designed and worked with (8 modules of 25 m³/day or, in other words, a total capacity of 200 m³/day) [84] which were powered by two 230 kW wind turbines, isolated from the conventional electrical grid. In these systems, the modularity of the SWRO desalination plants were exploited by connecting and disconnecting modules (lines) with the purpose of ensuring that the variation in the desalination energy demand was in sympathy with the wind energy generation. If the generation was higher than the load, then the load was increased to maintain the voltage and frequency. If the load was higher than the generation, then the load was decreased. Each module (line) operated under constant pressure and feedwater flow rates (without energy recovery systems), but could have operated within a specific pressure and feedwater flow rate range through the use of ML techniques.
- On the other hand, the concepts applied in this PhD can be implemented in larger plants, for example, using ML techniques for adjusting the operating parameters of the desalination lines to adapt their production capacity (between certain margins) to a variable energy supply and to the variability of the feedwater characteristics. In this context, we would like to point out that on the island of Gran Canaria there is a desalination plant capable of varying its production continuously between 7500 and 10000 m³/day. This plant has been installed in an area where the conductivity of the feedwater varies considerably over

the year as a consequence of the mixing of seawater with the freshwater underground currents produced by rainfall. ML could collaborate in adjusting the operating parameters of these plants to optimise their operation. It should be commented, however, that the above system is still at research stage.

- Likewise, we consider that the debate remains inconclusive with respect to the potential harmful effects to the RO membranes of the ON/OFF cycles and of the load variation during oscillatory periods of the renewable source. In this context, in a recently paper accepted for publication in *Desalination* (currently in press), titled «Experimental quantification of the effect of intermittent operation on membrane performance of solar powered reverse osmosis desalination systems» [202], the authors report that the impact of intermittent operation on membrane fouling is still not well understood and that this topic requires further investigation.

In another order, given the flexibility demonstrated by SWRO desalination plant prototype, it is also appropriate to start a wider new research line for analysing how desalination can help to integrate more renewable energy in whole energy systems. In this sense, it is proposed to analyse the maximum penetration capacity in a system varying the operation in desalination plants. Likewise, it can be evaluated how different desalination technologies affect the renewable energy integration.

Bibliografía

- [1] Wenyu Lai, Qingfen Ma, Hui Lu, Shaojie Weng, Junqing Fan, and Hai-xuan Fang. Effects of wind intermittence and fluctuation on reverse osmosis desalination process and solution strategies. *Desalination*, 395:17–27, 2016. xv, 2, 4, 12, 21, 23, 160
- [2] P. Feron. The use of wind power in autonomous reverse osmosis seawater desalination. *Wind Engineering*, 9(3):180–199, 1985. xv, xv, 3, 4, 13, 14, 25, 26, 27, 66
- [3] C.G. Warfel, J.F. Manwell, and J.G. McGowan. Techno-economic study of autonomous wind driven reverse osmosis desalination systems. *Solar & Wind Technology*, 5:549–561, 1988. xv, 3, 4, 13, 14, 26, 28, 66
- [4] Murray Thomson, Marcos S. Miranda, and David Infield. A small-scale seawater reverse-osmosis system with excellent energy efficiency over a wide operating range. *Desalination*, 153(1):229 – 236, 2003. xv, 22, 28, 29
- [5] M.S. Miranda and D.G. Infield. A wind-powered seawater reverse-osmosis system without batteries. *Desalination*, 153:9–16, 2003. xv, 2, 12, 14, 22, 28, 29, 66, 160, 162
- [6] R. Pohl, M. Kaltschmitt, and R. Holländer. Investigation of different operational strategies for the variable operation of a simple reverse osmosis unit. *Desalination*, 249:1280–1287, 2009. xv, xv, 4, 5, 14, 15, 29, 30, 31, 32, 62, 66, 160, 166, 190

- [7] G.L. Park, A.I. Schäfer, and B.S. Richards. Renewable energy powered membrane technology: The effect of wind speed fluctuations on the performance of a wind-powered membrane system for brackish water desalination. *Journal of Membrane Science*, 370:34–44, 2011. XVI, XVI, 22, 30, 32, 160
- [8] G.L. Park, A.I. Schäfer, and B.S. Richards. The effect of intermittent operation on a wind-powered membrane system for brackish water desalination. *Water Science and Technology*, 65:867–874, 2012.
- [9] Gavin Lawrence Park. *Wind-powered Membrane Desalination of Brackish Water*. PhD thesis, School of Engineering and Physical Sciences, Department of Mechanical Engineering, Heriot-Watt University, 2012.
- [10] G.L. Park, A.I. Schäfer, and B.S. Richards. Renewable energy-powered membrane technology: Supercapacitors for buffering resource fluctuations in a wind-powered membrane system for brackish water desalination. *Renewable Energy*, 50:126–135, 2013. 30
- [11] B.S. Richards, G.L. Park, T. Pietzsch, and A.I. Schäfer. Renewable energy powered membrane technology: Brackish water desalination system operated using real wind fluctuations and energy buffering. *Journal of Membrane Science*, 468:224–232, 2014. 30
- [12] B.S. Richards, G.L. Park, T. Pietzsch, and A.I. Schäfer. Renewable energy powered membrane technology: Safe operating window of a brackish water desalination system. *Journal of Membrane Science*, 468:400–409, 2014. XVI, 22, 30, 32
- [13] KA Al-Shayji and YA. Liu. Predictive modeling of large-scale commercial water desalination plants: data-based neural network and model-based process simulation. *Industrial & Engineering Chemistry Research*, 41:6460–6474, 2002. XVI, 33, 35, 89, 147, 150, 151, 155, 182, 192
- [14] M. Jafar and A. Zilouchian. *Intelligent control systems using soft computing methodologies*, chapter Application of soft computing for desalination technology, pages 317–349. CRC Press, London, 2001. XVI, 34, 36, 73, 86, 115

- [15] A. Zilouchian and M. Jafar. Automation and process control of reverse osmosis plants using soft computing methodologies. *Desalination*, 135(1-3):51–59, 2001. cited By 0. XVI, 34, 36
- [16] ZVP Murthy and Mehul M Vora. Prediction of reverse osmosis performance using artificial neural network. *Indian Journal of Chemical Technology (IJCT)*, 11(1):108–115, 2004. XVI, 35, 36, 37, 86, 89, 115, 147, 150, 151, 155, 182, 192
- [17] Abderrahim Abbas and Nader Al-Bastaki. Modeling of an {RO} water desalination unit using neural networks. *Chemical Engineering Journal*, 114(1-3):139 – 143, 2005. XVI, 36, 38, 73, 86, 115, 151
- [18] Young Geun Lee, Yun Seok Lee, Jong June Jeon, Sangho Lee, Dae Ryook Yang, In S. Kim, and Joon Ha Kim. Artificial neural network model for optimizing operation of a seawater reverse osmosis desalination plant. *Desalination*, 247(1-3):180 – 189, 2009. XVI, 37, 39, 73, 86, 89, 115, 147, 150, 151, 155, 182, 192
- [19] P. Isasi and I. Galván. *Redes de Neuronas Artificiales. Un enfoque práctico*. Madrid: Pearson Educación, S.A., 2004. XIX, 87, 88, 89
- [20] A. Gómez and G. Hernández. Utilización de las máquinas con vectores de soporte para regresión: m^2 de construcción en Bogotá. *Revista Avances en Sistemas e Informática*, 6:21–28, 2008. XIX, 93
- [21] A.J. Smola and B. Schölkopf. A tutorial on support vector regression. *Statistics and Computing*, 14(3):199–222, 2004. cited By (since 1996)1211. XIX, 93, 94
- [22] B. Scholkopf and A.J. Smola. *Learning with Kernels*. MIT Press, 2002. XIX, 93, 94, 95, 96, 97
- [23] M. Friendly. Classification and regression trees. <http://ddar.datavis.ca/pages/extra/titanic-tree-ex.pdf>, December 2015. [Accesed 03/03/2017]. XIX, 98

- [24] Eftihia Tzen. *Seawater desalination. Conventional and renewable energy processes.*, chapter Wind and Wave Energy for Reverse Osmosis, pages 213–245. Springer Berlin Heidelberg, Berlin, Heidelberg, 2009. XXIII, 13, 21, 22, 163
- [25] E. Tzen, K. Rossis, J. González, P. Cabrera, B. Peñate, and V.J. Subiela. *Renewable energy technologies for water desalination*, chapter Wind technology design and reverse osmosis systems for off-grid and grid-connected applications., pages 73–106. CRC Press, 2017. XXIII, 21, 22, 163
- [26] Mark A. Shannon, Paul W. Bohn, Menachem Elimelech, John G. Georgiadis, Benito J. Marinas, and Anne M. Mayes. Science and technology for water purification in the coming decades. *Nature*, 452:301–310, 2008. 1, 2, 11, 12
- [27] M. A. Montgomery and M. Elimelech. Water and sanitation in developing countries: including health in the equation. *Environment Science and Technology*, 41:17–24, 2007.
- [28] Guidelines for drinking-water quality. http://apps.who.int/iris/bitstream/10665/44584/1/9789241548151_eng.pdf, 2011. [accessed on 10/11/2017].
- [29] Naciones Unidas. World urbanization prospects: The 2011 revision. http://www.un.org/en/development/desa/population/publications/pdf/urbanization/WUP2011_Report.pdf, 2012. [accessed on 10/11/2017].
- [30] The United Nations World Water Development Report 2016-Water and Jobs, 2016. <http://unesdoc.unesco.org/images/0024/002439/243938e.pdf> [Accessed 10/11/2017]. 1, 11
- [31] Coping with water scarcity-an action framework for agriculture and food security, 2012. <http://www.fao.org/docrep/016/i3015e/i3015e.pdf> [Accessed on 10/11/2017].

- [32] N. Alexandratos and J. Bruinsma. World agriculture towards 2030/2050: The 2012 revision. <http://www.fao.org/docrep/016/ap106e/ap106e.pdf>, 2012. [Accessed on 10/11/2017].
- [33] David Molden, editor. *Water for food water for life: A Comprehensive assessment of water management in agriculture*. Earthscan - International Water Management Institute (IWMI), London, 2007. 1, 11
- [34] Gary Amy, Noreddine Ghaffour, Zhenyu Li, Lijo Francis, Rodrigo Valladares Linares, Thomas Missimer, and Sabine Lattemann. Membrane-based seawater desalination: Present and future prospects. *Desalination*, 401:16–21, 2017. 50th anniversary of Desalination. 1, 2, 11, 12
- [35] J. Veza, A. Gómez, and J. Pérez. Desalination technology in the Canary Islands, 1990. *Desalination*, 85:147–159, 1992.
- [36] J. Malleaville, P. Odendaal, and M. Wiesner. *Water Treatment Membrane Processes*. McGraw-Hill, 1996. 58, 67, 68
- [37] Ismail Serageldin. Looking ahead: Water, life and the environment in the twenty-first century. *International Journal of Water Resources Development*, 15:17–28, 1999. 67
- [38] J. Veza, B. Peñate, and F. Castellano. Electrodialysis desalination designed for wind energy (on-grid tests). *Desalination*, 141:53–61, 2001.
- [39] J. Veza. Desalination in the Canary Islands: an update. *Desalination*, 133:259–270, 2001.
- [40] N. Tsiourtis. Desalination and the environment. *Desalination*, 141:223–236, 2001.
- [41] J. Contruvo, N. Voutchkov, J. Fawell, P. Payment, D. Cunliffe, and S. Lattemann. *Desalination Technology: Health and Environmental Impacts*. CRC Press, 1st edition, 2010.

- [42] H. Ettouney and M. Wilf. *Seawater desalination. Conventional and renewable energy processes*, chapter Commercial desalination technologies. An overview of the current status of applications of commercial seawater desalination processes, pages 77–107. Springer, Palermo, 2009.
- [43] V.G. Gude, N. Nirmalakhandan, and S. Deng. Renewable and sustainable approaches for desalination. *Renewable and Sustainable Energy Reviews*, 14:2641–2654, 2010.
- [44] A. Al-Karaghoul and LL Kazmerski. Energy consumption and water production cost of conventional and renewable-energy-powered desalination processes. *Renewable and Sustainable Energy Reviews*, 24:343–356, 2013. 1, 11
- [45] Noredine Ghaffour, Thomas M. Missimer, and Gary L. Amy. Technical review and evaluation of the economics of water desalination: Current and future challenges for better water supply sustainability. *Desalination*, 309:197–207, 2013. 2, 11, 12
- [46] Dmitriy Sergeyevich Likhachev and Feng-Chen Li. Large-scale water desalination methods: a review and new perspectives. *Desalination and Water Treatment*, 51(13-15):2836–2849, 2013. 2, 12
- [47] S. Veerapaneni, B. Long, S. Freeman, and R Bond. Reducing energy consumption for seawater desalination. *American Water Works Association Journal*, 99:95–106, 2007. 2, 12
- [48] Ron S. Faibish and Toshio Konishi. Nuclear desalination: a viable option for producing freshwater. *Desalination*, 157:241–252, 2003. Desalination and the Environment: Fresh Water for all. 2, 12
- [49] B.M. Misra. Seawater desalination using nuclear heat/electricity-prospects and challenges. *Desalination*, 205:269–278, 2007.
- [50] N. Bouzguenda, S. Nisan, and M. Albouy. Financing of an integrated nuclear desalination system in developing countries. *Desalination*, 205:317–331, 2007.

- [51] Mohamed M. Megahed. Feasibility of nuclear power and desalination on el-dabaa site. *Desalination*, 246:238–256, 2009.
- [52] Hussam Jouhara, Vladimir Anastasov, and Ibrahim Khamis. Potential of heat pipe technology in nuclear seawater desalination. *Desalination*, 249:1055–1061, 2009.
- [53] Anne-Perrine Avrin, Gang He, and Daniel M. Kammen. Assessing the impacts of nuclear desalination and geoengineering to address china’s water shortages. *Desalination*, 360:1–7, 2015.
- [54] I. Khamis and R.S. El-Emam. IAEA coordinated research activity on nuclear desalination: the quest for new technologies and techno-economic assessment. *Desalination*, 394:56–3, 2016. 2, 12
- [55] S. Al-Kharabsheh and D. Yogi-Goswami. Analysis of an innovative water desalination system using low-grade solar heat. *Desalination*, 156:323–332, 2003. Joint EDS, WSTA and IWA conference on Desalination and the Environment Fresh Water for All UN International Year of Fresh Water 2003. 2, 12
- [56] V Belessiotis and E Delyannis. Solar energy: some proposals for future development and application to desalination. *Desalination*, 105:151–158, 1996. Proceedings of the 1st Symposium of the European Desalination Society ‘Desalination for Europe’.
- [57] Vassilis Belessiotis, Soteris Kalogirou, and Emmy Delyannis. Chapter one-desalination methods and technologies-water and energy. In Vassilis Belessiotis, , Soteris Kalogirou, , and Emmy Delyannis, editors, *Thermal Solar Desalination*, pages 1–19. Academic Press, 2016.
- [58] E. Brauns. Towards a worldwide sustainable and simultaneous large-scale production of renewable energy and potable water through salinity gradient power by combining reversed electro dialysis and solar power? *Desalination*, 219:312–323, 2008.

- [59] M.T. Chaibi. An overview of solar desalination for domestic and agriculture water needs in remote arid areas. *Desalination*, 127:119–133, 2000.
- [60] Catherine Charcosset. A review of membrane processes and renewable energies for desalination. *Desalination*, 245:214–231, 2009.
- [61] L. García-Rodríguez. Seawater desalination driven by renewable energies: a review. *Desalination*, 143:103–113, 2002.
- [62] Lourdes García-Rodríguez and Carlos Gómez-Camacho. Perspectives of solar-assisted seawater distillation. *Desalination*, 136:213–218, 2001.
- [63] Lourdes García-Rodríguez, Ana I. Palmero-Marrero, and Carlos Gómez-Camacho. Comparison of solar thermal technologies for applications in seawater desalination. *Desalination*, 142:135–142, 2002.
- [64] L. García-Rodríguez, V. Romero-Ternero, and C. Gómez-Camacho. Economic analysis of wind-powered desalination. *Desalination*, 137:259–265, 2001.
- [65] Imed Houcine, Fethi Benjemaa, Mohamed-Hachemi Chahbani, and Mohamed Maalej. Renewable energy sources for water desalting in tunisia. *Desalination*, 125:123–132, 1999. European Conference on Desalination and the Environment.
- [66] António Joyce, David Loureiro, Carlos Rodrigues, and Susana Castro. Small reverse osmosis units using PV systems for water purification in rural places. *Desalination*, 137:39–44, 2001.
- [67] E. Mathioulakis, V. Belessiotis, and E. Delyannis. Desalination by using alternative energy: Review and state-of-the-art. *Desalination*, 203:346–365, 2007. EuroMed 2006 Conference on Desalination Strategies in South Mediterranean Countries.
- [68] R.G. Raluy, L. Serra, and J. Uche. Life cycle assessment of desalination technologies integrated with renewable energies. *Desalination*, 183:81–93, 2005. Desalination and the Environment.

- [69] Murray Thomson and David Infield. Laboratory demonstration of a photovoltaic-powered seawater reverse-osmosis system without batteries. *Desalination*, 183:105–111, 2005. Desalination and the Environment.
- [70] Eftihia Tzen and Richard Morris. Renewable energy sources for desalination. *Solar Energy*, 75:375–379, 2003. Solar Desalination.
- [71] E. Tzen, K. Perrakis, and P. Baltas. Design of a stand alone PV-desalination system for rural areas. *Desalination*, 119:327–333, 1998. Papers presented at the Conference on Membranes in Drinking and Industrial Water Production.
- [72] Muhammad Shuja Azhar, Ghaus Rizvi, and Ibrahim Dincer. Integration of renewable energy based multigeneration system with desalination. *Desalination*, 404:72–78, 2017.
- [73] Upeksha Caldera, Dmitrii Bogdanov, and Christian Breyer. Local cost of seawater RO desalination based on solar PV and wind energy: A global estimate. *Desalination*, 385:207–216, 2016.
- [74] Noreddine Ghaffour, Jochen Bundschuh, Hacene Mahmoudi, and Mathheus F.A. Goosen. Renewable energy-driven desalination technologies: A comprehensive review on challenges and potential applications of integrated systems. *Desalination*, 356:94–114, 2015. State-of-the-Art Reviews in Desalination.
- [75] Sangkeum Lee, Sunghee Myung, Junhee Hong, and Dongsoo Har. Reverse osmosis desalination process optimized for maximum permeate production with renewable energy. *Desalination*, 398:133–143, 2016.
- [76] Noam Lior. Sustainability as the quantitative norm for water desalination impacts. *Desalination*, 401:99–111, 2017. 50th anniversary of Desalination.
- [77] P. Malek, J.M. Ortiz, and H.M.A. Schulte-Herbrüggen. Decentralized desalination of brackish water using an electro dialysis system directly powered by wind energy. *Desalination*, 377:54–64, 2016.

- [78] Akbar Maleki, Fathollah Pourfayaz, and Mohammad Hossein Ahmadi. Design of a cost-effective wind/photovoltaic/hydrogen energy system for supplying a desalination unit by a heuristic approach. *Solar Energy*, 139:666–675, 2016.
- [79] R. Nagaraj, D. Thirugnanamurthy, Manik Murthy Rajput, and B.K. Panigrahi. Techno-economic analysis of hybrid power system sizing applied to small desalination plants for sustainable operation. *International Journal of Sustainable Built Environment*, 5:269–276, 2016.
- [80] R. Segurado, J.F.A. Madeira, M. Costa, N. Duijck, and M.G. Carvalho. Optimization of a wind powered desalination and pumped hydro storage system. *Applied Energy*, 177:487–499, 2016.
- [81] Mariem Smaoui, Achraf Abdelkafi, and Lotfi Krichen. Optimal sizing of stand-alone photovoltaic/wind/hydrogen hybrid system supplying a desalination unit. *Solar Energy*, 120:263–276, 2015.
- [82] İbrahim Halil Yilmaz and Mehmet Sait Söylemez. Design and computer simulation on multi-effect evaporation seawater desalination system using hybrid renewable energy sources in turkey. *Desalination*, 291:23–40, 2012. 2, 12
- [83] J.A. Carta. *Comprehensive renewable energy*, volume 2, chapter Wind power integration, pages 569–622. Elsevier, 2012. 2, 12
- [84] J.A. Carta, J. González, and V.J. Subiela. Operational analysis of an innovative wind powered reverse osmosis system installed in the Canary Islands. *Solar Energy*, 75:153–168, 2003. 3, 4, 12, 13, 84, 160, 161, 186, 187, 195, 196
- [85] J.A. Carta, J. González, and C. Gómez. Operating results of a wind-diesel system which supplies the full energy needs of an isolated village community in the canary islands. *Solar Energy*, 74:53–63, 2003.

- [86] V. Subiela, J.A. Carta, and J. González. The SDAWES project: lessons learnt from an innovative project. *Desalination*, 168:39–47, 2004. 4, 13, 22, 84, 160, 161
- [87] K. Paulsen and F. Hensel. Introduction of a new energy recovery system-optimized for the combination with renewable energy. *Desalination*, 184:211–215, 2005. 160, 161
- [88] K. Paulsen and F. Hensel. Design of an autarkic water and energy supply driven by renewable energy using commercially available components. *Desalination*, 203:455–462, 2007. 3, 12, 160
- [89] J.A. Carta. *Stand-alone and hybrid wind energy systems*, chapter Integration of renewable energy systems into remote micro-grids, pages 425–474. Woodhead Publishing Limite, 2010. 3, 12
- [90] E Kondili. *Stand-alone and hybrid wind energy systems*, chapter Hybrid wind energy systems for desalination, pages 506–535. Woodhead Publishing Limite, 2010. 3, 12
- [91] J.A. Carta, J. González, and V. Subiela. The SDAWES project: An ambitious R&D prototype for wind-powered desalination. *Desalination*, 161(1):33–48, 2004. 4, 6, 13, 22, 84, 160, 161, 165, 190
- [92] Savvina Loutatidou, Nikos Liosis, Robert Pohl, Taha B.M.J. Ouarda, and Hassan A. Arafat. Wind-powered desalination for strategic water storage: Techno-economic assessment of concept. *Desalination*, 408:36 – 51, 2017. 4, 160
- [93] Y. Zhou and R. S. J. Tol. Evaluating the costs of desalination and water transport. *Water resources research*, 41:1–10, 2005. 12
- [94] R. Calero and J.A. Carta. Action plan for wind energy development in the canary islands. *Energy Policy*, 32:1185–97, 2004. 12
- [95] J.A. Carta and J. González. Self-sufficient energy supply for isolated communities: wind-diesel systems in the canary islands. *The Energy Journal*, 22:115–145, 2001. 22, 84

- [96] E. Kondili. 15 - hybrid wind energy systems for desalination. In J.K. Kaldellis, editor, *Stand-Alone and Hybrid Wind Energy Systems*, Woodhead Publishing Series in Energy, pages 506 – 535. Woodhead Publishing, 2010.
- [97] Chris R. Henderson, James F. Manwell, and Jon G. McGowan. A wind/diesel hybrid system with desalination for star island, nh: feasibility study results. *Desalination*, 237(1):318 – 329, 2009. Issue 1: Water Resources Management: New Approaches and Technologies. 12
- [98] J.A. Carta, J. González, Cabrera P., and Subiela V.J. Preliminary experimental analysis of a small-scale prototype SWRO desalination plant, designed for continuous adjustment of its energy consumption to the widely varying power generated by a stand-alone wind turbine. *Applied Energy*, 137:222–239, 2015. 12, 22, 123, 160, 163, 164, 166, 167, 172, 180, 184, 190, 191, 193
- [99] Michael Papapetrou, Essam Sh. Mohamed, Dimitris Manolakos, George Papadakis, Vicente J. Subiela, and Baltasar Peñate. *Operating RE/Desalination Units*, pages 247–272. Springer Berlin Heidelberg, Berlin, Heidelberg, 2009. 12
- [100] V.J. Subiela, B. Peñate, F. Castellano, and F.J. Domínguez. Solar pv powered ro systems. *Renewable energy applications for freshwater production*, pages 135–160, 2012. cited By 2.
- [101] Qingfen Ma and Hui Lu. Wind energy technologies integrated with desalination systems: Review and state-of-the-art. *Desalination*, 277(1-3):274 – 280, 2011.
- [102] M. Papapetrou, C. Epp, and E. Tzen. Autonomous desalination units based on renewable energy systems-a review of representative installation worldwide. *Solar desalination for the 21st century. A review of modern technologies and researches on desalination coupled to renewable energies*, pages 343–353, 2007. 12, 13

- [103] E. Tzen. *Renewable energy applications for freshwater production*, chapter Wind energy powered technologies for freshwater production: fundamentals and case studies, pages 161–180. IWA Publishing, London, 2012. 163
- [104] V.J. Subiela, J.A. de la Fuente, G. Piernavieja, and B. Peñate. Canary islands institute of technology (ITC) experiences in desalination with renewable energies (1996-2008). *Desalination and Water Treatment*, 7(1-3):220–235, 2009. 13, 22, 42, 45, 47, 160, 161, 162, 163
- [105] C.C.K. Liu, J.W. Park, R. Migita, and G. Qin. Experiments of a prototype wind-driven reverse osmosis desalination system with feedback control. *Desalination*, 150:277–287, 2002. 14, 22
- [106] H. Liu, H. Tian, C. Chen, and Y. Li. An experimental investigation of two Wavelet-MLP hybrid frameworks for wind speed prediction using GA and PSO optimization. *Electrical Power and Energy Systems*, 52:161–173, 2013. 14
- [107] S.G.J. Heijman, E. Rabinovitch, Bos F., N. Olthof, and J.C. van Dijk. Sustainable seawater desalination: Stand-alone small scale windmill and reverse osmosis system. *Desalination*, 248:114–117, 2009. 14, 22
- [108] Ignacio de la Nuez Pestana, Francisco J. García-Latorre, and Celso Argudo Espinoza Antonio Gómez-Gotor. Optimization of RO desalination systems powered by renewable energies. Part i: Wind energy. *Desalination*, 160(3):293–299, 2004. 14, 28
- [109] S. Salomon. Le dessalement de l'eau de mer par l'énergie éolienne. *L'Éau*, 55:225–227, 1968. 21
- [110] E.R. Lising and R. Alward. Unsteady state operation of a reverse osmosis desalination unit. *Desalination*, 11:261–268, 1972. 21, 24
- [111] A. Maurel. Desalement et energies nouvelles. *Desalination*, 31:489–499, 1979. 22

- [112] G. Petersen, S. Fries, J. Mohn, and A. Müller. Wind and solar powered reverse osmosis desalination units. description of two demonstration projects. *Desalination*, 31:501–509, 1979. 22
- [113] G. Petersen, S. Fries, J. Mohn, and A. Müller. Wind and solar powered reverse osmosis desalination units - design, start up, operating experience. *Desalination*, 39:125 – 135, 1981. 22
- [114] J.E. Feustel. Medium-large wind power plant for the new diesel-powered energy supply system of helgoland. In *Proceedings of an International Conference, EWEC '84*, pages 656–662, 1985. 22
- [115] H. Nacfaire. *Wind-Diesel and wind autonomous energy systems*. Elsevier, 1988. 22
- [116] Rod Robinson, Goen Ho, and Kuruvilla Mathew. Development of a reliable low-cost reverse osmosis desalination unit for remote communities. *Desalination*, 86(1):9 – 26, 1992. 22
- [117] APAS RENA PROGRAMME 1994. Renewable energies. A selection of final reports. <http://bookshop.europa.eu/es/apas-rena-programme-1994-pbCGNA18028/>, 1998. [Accessed on 10/11/2017]. 22
- [118] D. Assimacopoulos. Water water everywhere... *Refocus*, 2(6):38 – 43, 2001. 22
- [119] MODESAL. Modular Desalination: Development and pilot-operation of a family of second generation modular wind powered seawater desalination plants. Final report. 22
- [120] L. García-Rodríguez. Renewable energy applications in desalination: state of the art. *Solar*, 75, 2003. 22
- [121] R. Calero, J.A. Carta, and J.M. Padrón. *Energía*, chapter 27. El futuro energético de Canarias. Gobierno de Canarias, Feb 2007. 22

- [122] C.C.K. Liu. The development of a renewable-energy-driven reverse osmosis system for water desalination and aquaculture production. *Journal of Integrative Agriculture*, 12:1357–62, 2013. 22
- [123] T. Witte, S. Siegfriedsen, and M. El-Allawy. Winddesalter® technology direct use of wind energy for seawater desalination by vapour compression or reverse osmosis. *Desalination*, 156, 2003. 22
- [124] Ma Qingfen and L. Hui. Wind energy technologies integrated with desalination systems: Review and state-of-the-art. *Desalination*, 277, 2011. 26
- [125] M.E. El-Hawary. Artificial neural networks and possible applications to desalination. *Desalination*, 92:125–147, 1993. 33, 86, 89, 151, 155, 182, 186, 192, 195
- [126] G.P. Rao, D.M.K. Al-Gobaisi, A. Hassan, A. Kurdali, R. Borsani, and M. Aziz. Towards improved automation for desalination processes. part ii: Intelligent control. *Desalination*, 8(97):507–28, 1994. 33
- [127] G. Stephanopoulos. Artificial intelligence in process engineering-current state and future trends. *Comput Chem Eng. .*, 14(11):1259–70, 1990. 33
- [128] K. Al-Shayji and Y.A. Liu. Neural networks for predictive modeling and optimization of large-scale commercial water desalination plants. In *Proc IDA World Congress Desalination Water Science*, volume 1, pages 1–15, 1997. 33
- [129] K.A. Al-Shayji. *Modelling, simulation, and optimization of Large-Scale commercial desalination plants*. PhD thesis, Virginia Polytechnic Institute and State University, Blacksburg, Virginia:, 1995. 33
- [130] Adnan M. Aish, Hossam A. Zaqoot, and Samaher M. Abdeljawad. Artificial neural network approach for predicting reverse osmosis desalination plants performance in the gaza strip. *Desalination*, 367(0):240 – 247, 2015. 38, 86, 89, 115, 147, 150, 151, 155, 182, 192

- [131] B. Peñate, F. Castellano, C. Henríquez, C. Blanco, F.J. Rocha, and G. Melián. Aerogedesa: Prototipo de desalación de agua de mar por ósmosis inversa alimentada con energía eólica. In *III Congreso AEDyR. Un recurso seguro.*, Málaga, Nov 2002. 44
- [132] C. Abbey and G. Joos. Supercapacitor energy storage for wind energy applications. *IEEE Transactions on Industry Applications*, 43:769–776, 2007. 46
- [133] R. Shah, N. Mithulananthan, and R.C. Bansal. Damping performance analysis of battery energy storage system, ultracapacitor and shunt capacitor with large-scale photovoltaic plants. *Applied Energy*, 96:235–244, 2012.
- [134] H. He, R. Xiong, K. Zhao, and Z. Liu. Energy management strategy research on a hybrid power system by hardware-in-loop experiments. *Applied Energy*, 112:1311–1317, 2013. 46
- [135] D.P. Zafirakis. *Stand-alone and hybrid wind energy systems*, chapter Overview of energy storage technologies for renewable energy systems, pages 29–80. Oxford: Woodhead Publishing Limited, 2010. 46
- [136] *Toray Software Download site*. <https://ap3.toray.co.jp/toraywater/> [accessed on 10/11/2017]. 58
- [137] J. Kucera. *Reverse osmosis. Design, processes, and applications for engineers*. Wiley, New Jersey, first edition, 2010. 58, 67, 68
- [138] C. Fritzmann, J. Löwenberg, T. Wintgens, and T. Melin. State-of-the-art of reverse osmosis desalination. *Desalination*, 216(1):1 – 76, 2007. 68
- [139] Mostafa H. Sharqawy, John H. Lienhard V, and Syed M. Zubair. Thermophysical properties of seawater: a review of existing correlations and data. *Desalination and Water Treatment*, 16(1-3):354–380, 2010. 68
- [140] Lauren F. Greenlee, Desmond F. Lawler, Benny D. Freeman, Benoit Marrot, and Philippe Moulin. Reverse osmosis desalination: Water sources, technology, and today’s challenges. *Water Research*, 43(9):2317 – 2348, 2009. 68

- [141] J.A. Carta, P. Ramírez, and S. Velázquez. A review of wind speed probability distributions used in wind energy analysis: Case studies in the canary islands. *Renewable and Sustainable Energy Reviews*, 13(5):933 – 955, 2009. 69, 167
- [142] Reza Soleimani, Navid Alavi Shoushtari, Behrooz Mirza, and Abdolhamid Salahi. Experimental investigation, modeling and optimization of membrane separation using artificial neural network and multi-objective optimization using genetic algorithm. *Chemical Engineering Research and Design*, 91(5):883 – 903, 2013. 73, 86, 115
- [143] J.C. Principe, N.R. Euliano, and W.C. Lefebvre. *Neural and Adaptive Systems. Fundamentals Through Simulations*. John Wiley & Sons, Inc, New York, 2000. 73, 89, 115, 120
- [144] N. Deng, Y. Tian, and C. Zhang. *Support vector machines. Optimization based theory, algorithms, and extensions*. CRC Press, New York, 1st edition, 2013. 73, 85
- [145] EC 60085. Electrical insulation - Thermal evaluation and designation. http://webstore.iec.ch/webstore/webstore.nsf/Artnum_PK/38542, 2007. [Accesed on 10/11/2017]. 83
- [146] M. Barello, D. Manca, R. Patel, and I.M. Mujtaba. Neural network based correlation for estimating water permeability constant in {RO} desalination process under fouling. *Desalination*, 345(0):101 – 111, 2014. 86, 115
- [147] N. Cristianini and J. Shawe-Taylor. *An Introduction to Support Vector Machines and other kernel-based learning methods*. Cambridge University Press, Cambridge, 1st edition, 2000. 86
- [148] L. Breiman. Random forests. *Machine Learning*, 45:5–32, 2001. 86, 94, 98
- [149] B. Martín and A. Sanz. *Redes neuronales y sistemas borrosos*. RA-MA, 2001. 87, 88

- [150] P. Cabrera, J.A. Carta, González J., and G. Melián. Artificial neural networks applied to manage the variable operation of a simple seawater reverse osmosis plant. *Desalination*, 416:140–156, 2017. 89, 146, 155, 160, 166, 172, 180, 181, 186, 190, 195
- [151] C. M. Bishop. *Neural Networks for Pattern Recognition*. Oxford University Press Inc., NY, 1995. 89, 115
- [152] Trevor Hastie, Robert Tibshirani, and Jerome Friedman. *The Elements of Statistical Learning*. Springer-Verlag, New York, 2nd edition, 2009. 89, 94, 97, 98, 99, 100, 149
- [153] S.A. Kalogirou. Artificial neural networks in renewable energy systems applications: a review. *Renewable and Sustainable Energy Reviews*, 5:373–401, 2001. 91
- [154] J.F. Addison, A. Hunter, J. Bass, and M. Rebbeck. A neural network version of the measure correlate predict algorithm for estimating wind energy yield. In *Proceedings of 13th International Congress on Condition Monitoring and Diagnostic Engineering, Houston, TX, 2000*. 91
- [155] D.A. Bechrakis, J.P. Deane, and E.J. McKeogh. Wind resource assessment of an area using short term data correlated to a long term data set. *Solar Energy*, 76:725–732, 2004. 92
- [156] D.A. Bechrakis and P.D. Sparis. Correlation of wind speed between neighboring measuring stations. *IEEE Transaction on Energy Conversion*, 19:400–406, 2004.
- [157] K.W. Stopenhagen, R. Sweet, and C. Meissner. A neural network alternative to traditional measure-correlate-predict algorithms in wind resource assessment. In *Proceedings of the AWEA 2012 Windpower Conference and Exhibition, Atlanta, GA USA, June 3-6, 2012*. 92
- [158] M. Riedmiller and H. Braun. A direct adaptive method for faster backpropagation learning: the RPROP algorithm. In *IEEE International Conference*

- on Neural Networks.*, pages 586–591, San Francisco, CA, 1993. 92, 104, 116
- [159] M.T. Hagan, H.B. Demuth, and M.H. Beale. *Neural Network Toolbox Users Guide*. http://www.mathworks.com/help/pdf_doc/nnet/nnet_ug.pdf, 2016. [Accessed 27.05.2017]. 92, 121
- [160] C.J.C. Burges. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2:121–167, 1998. 93
- [161] A.I. Belousov, S.A. Verzhakov, and J. Von Frese. A flexible classification approach with optimal generalisation performance: support vector machines. *Chemometrics and Intelligent Laboratory Systems*, 64:15–25, 2002. 93
- [162] V. Vapnik, S.E. Golowich, and A.J. Smola. Support vector method for function approximation, regression estimation, and signal processing. *Advances in Neural Information Processing System*, 9:281–287, 1996. 93
- [163] A.J. Smola and B. Schölkopf. *A tutorial on support vector regression*. UK, 1999. 93
- [164] J.D. Velásquez, Y. Olaya, and C.J. Franco. Predicción de series temporales usando máquinas de vectores de soporte. *Ingeniare. Revista chilena de ingeniería*, 18:64–75, 2010. 93
- [165] S. Mukherjee, E. Osuna, and F. Girosi. Nonlinear prediction of chaotic time series using support vector machines. In *Proceedings of IEEE NNSP'97*, Amelia Island, FL, 1997.
- [166] K.R. Müller, A.J. Smola, G. Rätsch, B. Schölkopf, J. Kohlmorgen, and V. Vapnik. Predicting time series with support vector machines. In *Proceedings of ICANN'97*, 1997. 93
- [167] S. Osowski and K. Garanty. Forecasting of the daily meteorological pollution using wavelets and support vector machine. *Engineering Applications of Artificial Intelligence*, 20:745–755, 2007.

- [168] F.E.H. Tay and L. Cao. Application of support vector machines in financial time series forecasting. *Omega*, 29:309–317, 2001.
- [169] U. Thissen, R. Vn Brakel, A.P de Weijer, Melssen W.J., and Buydens LMC. Using support vector machines for time series prediction. *Chemometrics and Intelligent Laboratory Systems*, 69:35–49, 2003. 93
- [170] V. Vapnik. *Statistical Learning Theory*. New York: Wiley, 1998. 93
- [171] J. Smola. Regression estimation with support vector learning machines. Master’s thesis, Technische Universität München, 1996. 93
- [172] D. Mattera and S. Haykin. *Advances in Kernel Methods-Support Vector Learning*, chapter Support vector machines for dynamic reconstruction of a chaotic system, pages 211–242. MIT Press, Cambridge, MA, 1999. 93
- [173] M. Stitson, A. Gammerman, V. Vapnik, V. Vovk, C. Watkins, and J. Weston. *Advances in Kernel Methods-Support Vector Learning*, chapter Support vector regression with ANOVA decomposition kernels, pages 285–292. MIT Press, Cambridge, MA, 1999. 93
- [174] Inc. The MathWorks. Statistics and Machine Learning Toolbox Users Guide. http://www.mathworks.com/help//pdf_doc/stats/stats.pdf, 2016. [Accessed 27.05.2017]. 97, 101, 120
- [175] Mathias Bourel. Métodos de agregación de modelos y aplicaciones (Model aggregation methods and applications). *Memoria de Trabajos de Difusión Científica y Técnica*, 10:19–32, 2012. 98, 99, 100
- [176] José María Matías. Técnicas de Aprendizaje para el Análisis de Datos (Machine Learning and Knowledge Building). Máster de Bioestadística - Universidad de Santiago de Compostela, March 2006. 98
- [177] J. Hernández Orallo, M.J. Ramírez Quintana, and C. Ferri Ramírez. *Introducción a la minería de datos*. Pearson educación, Madrid, 2004. 98, 100
- [178] L. Breiman, J.H. Friedman, R.A. Olshen, and C.J. Stone. *Classification and Regression Trees*. Wadsworth and Brooks/Cole, Monterrey, 1984. 98

- [179] E. Bradley and R. Tibshirani. *An Introduction to the Bootstrap*. Monographs on Statistics & Applied Probability. Chapman & Hall/CRC, 1994. 100
- [180] Rasit Ata. Artificial neural networks applications in wind energy systems: a review. *Renewable and Sustainable Energy Reviews*, 49(0):534 – 562, 2015. 110
- [181] K. Hornik, M. Stinchcombe, and H. White. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2:359–366, 1989. 115
- [182] T. Masters. *Practical Neural Network Recipes in C++*. Morgan Kaufmann Publishers, California, first edition, 1993. 115, 127
- [183] Christian Igel, Marc Toussaint, and Wan Weishui. Rprop using the natural gradient. In Detlef H. Mache, József Szabados, and Marcel G. de Bruin, editors, *Trends and Applications in Constructive Approximation*, pages 259–272. Birkhäuser Basel, Basel, 2005. 116
- [184] K. Deep, K.P. Singh, M.L. Kansal, and C. Mohan. A real coded genetic algorithm for solving integer and mixed integer optimization problems. *Applied Mathematics and Computation*, 212:505–518, 2009. 117, 118, 150
- [185] D.E. Goldberg. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley Longman Publishing Co., MA, first edition, 1989. 118
- [186] K. Deep and M. Thakur. A new crossover operator for real coded genetic algorithms. *Applied Mathematics Computer*, 188:895–912, 2007. 118
- [187] K. Deep and M. Thakur. A new mutation operator for real coded genetic algorithms. *Applied Mathematics Computer*, 193:211–230, 2007. 118
- [188] The MathWorks, Inc. *Global Optimization Toolbox Users Guide*, 2016. 118, 122
- [189] Douglas C. Montgomery. *Design and Analysis of Experiments*. John Wiley & Sons, Inc, New York, 2004. 123

- [190] T. Hill and P. Lewicki. *Statistics. Methods and applications*. StatSoft, Oklahoma, first edition, 2006. 136
- [191] J.D. Gibbons and S. Chakraborti. *Nonparametric Statistical Inference*. CRC Press, London, first edition, 2011. 136, 137, 138
- [192] M. Hollander, D.A. Wolfe, and E. Chicken. *Nonparametric statistical methods*. John Wiley & Sons, Inc., New Jersey, third edition, 2014. 136
- [193] G.E.P. Box and D.A. Pierce. Distribution of residual autocorrelations in autoregressive-integrated moving average time series models. *J Am Statist Assoc*, 65:1509–26, 1970. 136
- [194] G. Ljung and G.E.P. Box. On a measure of lack of fit in time series models. *Biometrika*, 65:297–303, 1978. 136
- [195] R.B. D’Agostino and M.A. Stephens. *Goodness of fit techniques*. Dekker, New York, first edition, 1986. 137
- [196] G.E.P. Box and D.R. Cox. An analysis of transformations. *J R Statist Soc*, 26:211–243, 1964. 137
- [197] K.J. Berry, J.E. Johnston, and P.W. Mielke. *A chronicle of permutation statistical methods*. Springer, 2014. 151
- [198] Y. Benjamini and Y. Hochberg. Controlling the false discovery rate: a practical and powerful approach to multiple testing. *Journal of the Royal Statistical Society*, 57:289–300, 1995. 151
- [199] Francisco J. García-Latorre, Sebastián O. Pérez-Báez, and Antonio Gómez-Gotor. Energy performance of a reverse osmosis desalination plant operating with variable pressure and flow. *Desalination*, 366:146 – 153, 2015. Energy and Desalination. 160
- [200] P. Helm, H. Ehmann, M. Stöhr, A. Wobben, M. Kuhlmann, I. Lührs, Z. Zervos, M. Rodríguez-Ruíz, M. Cendagorta, and F. Pérez. Design, set-up and

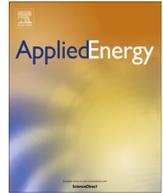
- operation of wind powered reverse osmosis desalination plants. In *Proceedings of the 1999 European Wind Energy Conference*, pages 52–56, London, 1999. 160, 161, 162
- [201] Solteq energy. http://solteq-energy.com/SolteQ_Energy-bv_FreshWaterMill_v20.pdf. (Accessed 08.08.2017). 160
- [202] M Freire-Gormaly and AM. Bilton. Experimental quantification of the effect of intermittent operation on membrane performance of solar powered reverse osmosis desalination systems. *Desalination*, In press, 2017. 160, 188, 197
- [203] JS Kim, J Chen, and HE. García. Modeling, control, and dynamic performance analysis of a reverse osmosis desalination plant integrated within hybrid energy systems. *Energy*, 112:52–66, 2016. 162, 166
- [204] B. Peñate, F. Castellano, A. Bello, and L. García-Rodríguez. Assessment of a stand-alone gradual capacity reverse osmosis desalination plant to adapt to wind power availability: A case study. *Energy*, 36:4372–4384, 2011. 162
- [205] J.F. Manwell and J.G. McGowan. Lead acid battery storage model for hybrid energy systems. *Solar Energy*, 50:399–405, 1993. 171
- [206] J.A. Carta, P. Cabrera, J.M. Matías, and F. Castellano. Comparison of feature selection methods using anns in mcp-wind speed methods. a case study. *Applied Energy*, 158:490–507, 2015. cited By 6. 180
- [207] P. Cabrera, J.A. Carta, J. González, and G. Melián. Wind-driven swro desalination prototype with and without batteries: A performance simulation using machine learning models. *Desalination*, InPress:xx–xx, 2018. 181, 191
- [208] J. Jung and R.P. Broadwater. Current status and future advances for wind speed and power forecasting. *Renewable and Sustainable Energy Reviews*, 31:762–777, 2014. 185, 195

- [209] M.Q. Raza and A. Khosravi. A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renewable and Sustainable Energy Reviews*, 50:1352–1372, 2015. 186, 195
- [210] S. Shabani, P. Yousefi, and G. Naser. Support vector machines in urban water demand forecasting using phase space reconstruction. *Procedia Engineering*, 186:537–543, 2017.
- [211] C. Bennett, R.A. Stewart, and C.D. Beal. ANN-based residential water end-use demand forecasting model. *Expert Systems with Applications*, 40:1014–1023, 2013. 186, 195

APÉNDICE

A

Papers published during PhD



Preliminary experimental analysis of a small-scale prototype SWRO desalination plant, designed for continuous adjustment of its energy consumption to the widely varying power generated by a stand-alone wind turbine



José A. Carta^{a,*}, Jaime González^b, Pedro Cabrera^a, Vicente J. Subiela^c

^a Department of Mechanical Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain

^b Department of Electronics and Automatics Engineering, Universidad de Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain

^c Water Department, Canary Islands Institute of Technology (ITC), Playa de Pozo Izquierdo s/n, 35119 Santa Lucía-Las Palmas de Gran Canaria, Spain

HIGHLIGHTS

- A prototype SWRO plant is presented operating with variable power consumption.
- The theoretical admissible operating limits of the plant are determined.
- The strategy of variable operating conditions is described for the SWRO plant.
- The results obtained when simulating the WT-generated power are analysed.

ARTICLE INFO

Article history:

Received 18 March 2014

Received in revised form 16 September 2014

Accepted 19 September 2014

Available online 24 October 2014

Keywords:

Wind energy

Seawater reverse osmosis

Desalination

Supercapacitors

Continuously adjustable load

Applied renewable energy

ABSTRACT

Given the significant water–energy problems associated with many remote and arid areas of the planet, most studies, projects and developments of installations for the production of fresh water using desalination technologies powered by renewable energy sources have focussed on small-scale stand-alone systems. The most commonly used energy sources have been solar photovoltaic and wind and the most widely applied desalination technology that of reverse osmosis (RO). Most of the systems use batteries as a means of mass energy storage and the RO plants normally operate at constant pressure and flow rate. This paper presents a small-scale prototype SWRO (seawater reverse osmosis) desalination plant designed to continuously adapt its energy consumption to the variable power supplied by a wind turbine (WT), dispensing with mass energy storage in batteries and proposing the use of a supercapacitor bank as a dynamic regulation system. A description is given of the tests performed to date with the SWRO desalination plant connected to the conventional grid while controlling the number of pressure vessels that are connected/disconnected to/from the system and regulating their operating pressures and flow rates (within predetermined admissible limits) to maintain a constant permeate recovery rate and adapt the energy consumption of the plant to a widely varying simulated wind energy supply.

One of the most important conclusions that can be drawn from the studies undertaken is the feasibility of adapting the consumption of the prototype of the SWRO desalination plant to widely varying WT-generated power. Despite using various time interval lengths in which it was assumed that the WT output power remained constant, a perfect fit was not obtained between the theoretical WT-generated power and the power consumed by the SWRO desalination plant, nor was it possible to maintain a constant permeate recovery rate at each instant.

© 2014 Elsevier Ltd. All rights reserved.

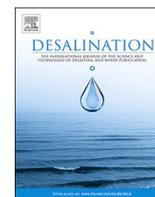
1. Introduction

1.1. Background

Potable water is obviously a liquid essential for human life and for this reason so much importance has been given to the lack of

* Corresponding author. Tel.: +34 928 45 14 83; fax: +34 928 45 14 84.

E-mail address: jcarta@dim.ulpgc.es (J.A. Carta).



Artificial neural networks applied to manage the variable operation of a simple seawater reverse osmosis plant



Pedro Cabrera^{a,*}, José A. Carta^a, Jaime González^b, Gustavo Melián^c

^a Department of Mechanical Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain

^b Department of Electronics and Automatics Engineering, Universidad de Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain

^c Water Department, Canary Islands Institute of Technology (ITC), Playa de Pozo Izquierdo s/n, 35119 Santa Lucía, Gran Canaria, Spain

ARTICLE INFO

Keywords:

Desalination
Artificial neural network
Fluctuating power input
Reverse osmosis

ABSTRACT

For the purpose of managing the operation of a small-scale prototype of a sea water reverse osmosis desalination plant installed on the island of Gran Canaria (Spain) and enabling it to function with fluctuating power input, artificial neural network (ANN) models were incorporated into its control system. The ANN models were developed to generate feed flow and operating pressure setpoints (with the restriction of having to maintain the permeate recovery rate within a certain range) after taking into account not only the available electrical power but also the temperature and conductivity of the feedwater.

It is concluded that the ANN models that were used after training and validation were able to successfully manage the random and widely varying available electrical power. The statistical hypothesis testing that was also performed showed no significant statistical differences (at 5% level) between the errors (both MAE and MAPE) committed when adapting power consumption of the plant to the available electrical power in the various operational tests using different feedwater characteristics.

1. Introduction

1.1. Renewable energy applications for freshwater production

Proposals to use wind energy in seawater desalination first began to appear in the scientific literature in the 1970s and '80s [1]. A few of the projects that were implemented demonstrated the feasibility of the operation of reverse osmosis plants driven by wind turbines with rated powers ranging between 4 and 11 kW [2–4]. Since then, many more research, development and innovative projects have been undertaken in this field [5–7]. Though several types of renewable energy sources and of desalination technologies have been proposed and different scales of use considered, most studies and projects have concentrated on the use of photovoltaic and wind energy systems for small-scale (maximum capacity of 50 m³/day) seawater desalination in arid-remote and coastal areas, using reverse osmosis technology [8,9].

The vast majority of small-scale desalination systems based on the exploitation of wind energy have used batteries as an energy storage system, with the reverse osmosis membranes generally operating under constant pressure and flow conditions [9]. Consequently, despite the variable nature of the renewable energy being generated, the reverse

osmosis plants have operated at constant power. As pointed out by Miranda and Infield [10], the drawback of using such energy storage systems is the increased capital and operating costs that they entail.

1.2. Strategies for the variable operation of a wind-powered reverse osmosis desalination plant

The literature survey undertaken revealed various alternatives to wind energy-driven desalination systems that use battery banks as a means of mass storage of energy. In their place, systems have been proposed and developed that employ energy management strategies aimed at maximising exploitation of the wind resource [10–22].

Systems on this basis have been considered and developed for the variable operation of the desalination plant; in other words, to enable the desalination plant to adapt its energy consumption to the variable nature of the renewable energy source.

In this context, different operational strategies have been proposed in the theoretical studies which have been published [10–13] for the variable operation of a simple wind power driven reverse osmosis unit. In these studies, an acceptable operational window is defined for the reverse osmosis plant. The limits of this window are defined by the

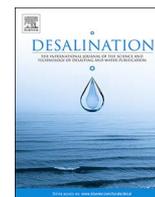
* Corresponding author.

E-mail address: pedro.cabrerasantana@ulpgc.es (P. Cabrera).



Contents lists available at ScienceDirect

Desalination

journal homepage: www.elsevier.com/locate/desal

Wind-driven SWRO desalination prototype with and without batteries: A performance simulation using machine learning models

Pedro Cabrera^a, José Antonio Carta^{a,*}, Jaime González^b, Gustavo Melián^c

^a Department of Mechanical Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain

^b Department of Electronics and Automatics Engineering, Universidad de Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain

^c Water Department, Canary Islands Institute of Technology (ITC), Playa de Pozo Izquierdo s/n, 35119 Santa Lucía, Gran Canaria, Spain

ARTICLE INFO

Keywords:

Desalination
Wind energy
Microgrid
Sea water reverse osmosis
Machine learning

ABSTRACT

In this paper, two studies are carried out related to the performance simulation and analysis of a wind-powered seawater reverse osmosis (SWRO) desalination plant prototype installed on the island of Gran Canaria (Spain). Three machine learning techniques (artificial neural networks, support vector machines and random forests) were implemented to predict the performance (pressure, feed flow rate and permeate flow rate, and permeate conductivity) of the SWRO desalination plant. Subsequently, plant operation was analysed in two different operating modes: a) constant pressure and flow rate through connection with a wind-battery microgrid, b) variable pressure and flow rate as a function of the power supplied by a stand-alone wind microgrid without energy storage. The paper supports two main outcomes. First, support vector machines and random forests are significantly (5% significance level) better predictors of the plant's performances than neural networks. Second, over one year, the operating mode that considers variable pressure and flow rate operates more continuously (higher operating frequencies and lower stop/start frequencies) than the constant pressure and flow rate alternative; however 1.2 times less permeate with 1.08 higher conductivity is produced on an annual basis.

1. Introduction

Though technological advances have gradually succeeded in reducing the specific energy consumptions of water desalination technologies [1–2], the relatively high energy consumption which they still require has a strong impact on production costs [3].

Traditionally, the energy sources used in desalination processes have been fundamentally fossil fuel based. As a result of the trend of rising costs of fossil fuels [4], the establishment of policies that pursue reductions in energy dependency (when conventional resources are absent) and that aim to contribute to the protection and preservation of the environment (reducing the atmospheric contamination generated by fossil fuels), as well as the difficulties faced in certain remote areas of the planet where no conventional energy resources are available, various projects have been proposed in recent times based on the use of alternative energy sources [5–6]. Most of these proposals advocate the use of renewable energy sources, either exclusively or when forming part of renewable-conventional hybrid systems [6–11].

It should be noted that many of the proposals that have been made focus on small-scale desalination (maximum capacity of 50 m³/day) using stand-alone microgrids. To date, photovoltaic solar energy and

wind energy have been the most commonly proposed sources for small-scale desalination using reverse osmosis (RO) technologies [12–15].

Various microgrid configurations and operating strategies have been proposed for the operation of small, sea water reverse osmosis (SWRO) desalination plants (DPs) powered exclusively by wind energy. However, if only considering systems that use electrical energy to power the SWRO-DPs, these can be conceptually classified into two groups: a) microgrids comprising a wind turbine (WT), a massive energy storage system and an SWRO-DP operating with constant pressure and flow [13–16], and b) microgrids that discard the use of massive energy storage and that have the SWRO-DP operating with variable pressure and/or flow with the aim of adapting its energy consumption to the variability of the wind energy [17–21].

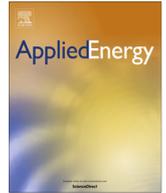
When it comes to simulating and/or predicting the operation of the two aforementioned microgrid groups, the difficulties faced by the operating strategies of the systems classified in group b) are much greater given the need to adequately model the variable operation of the SWRO-DP in terms of pressure and/or flow. However, in the a) group systems, as the SWRO-DP operates under constant pressure and flow conditions, the permeate flow rates and their conductivities are approximately constant. In this latter case, the SWRO-DP will be

* Corresponding author.

E-mail address: jose.carta@ulpgc.es (J.A. Carta).

<https://doi.org/10.1016/j.desal.2017.11.044>

Received 24 August 2017; Received in revised form 27 October 2017; Accepted 27 November 2017
0011-9164/ © 2017 Elsevier B.V. All rights reserved.



Comparison of feature selection methods using ANNs in MCP-wind speed methods. A case study



José A. Carta^{a,*}, Pedro Cabrera^a, José M. Matías^b, Fernando Castellano^c

^a Department of Mechanical Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands, Spain

^b Department of Statistics, University of Vigo, Lagoas Marcosende, 36200 Vigo, Spain

^c Renewable Energies Department, Canary Islands Institute of Technology (ITC), Playa de Pozo Izquierdo s/n, 35119 Santa Lucía – Las Palmas, Spain

HIGHLIGHTS

- An analysis is carried out of the benefits of feature selection in MCP methods which use ANNs.
- The wrapper approach (WA) generated lower mean errors than the filter approach (FA).
- No significant statistical difference was observed between the WA and the FA in certain cases.
- The FA generated models somewhat simpler and more interpretable than the WA.
- The WA displayed better predictive capacity than the FA, but is more computationally intensive.

ARTICLE INFO

Article history:

Received 8 May 2015

Received in revised form 27 July 2015

Accepted 21 August 2015

Keywords:

Measure–correlate–predict method

Artificial neural networks

Wind speed

Wind direction

Feature selection

Cross-validation technique

ABSTRACT

Recent studies in the field of renewable energies, and specifically in wind resource prediction, have shown growing interest in proposals for Measure–Correlate–Predict (MCP) methods which simultaneously use data recorded at various reference weather stations. In this context, the use of a high number of reference stations may result in overspecification with its associated negative effects. These include, amongst others, an increase in the estimation error and/or overfitting which could be detrimental to the generalisation capacity of the model when handling new data (prediction).

This paper analyses the benefits of feature selection for use with Artificial Neural Network (ANN) techniques with a multilayer perceptron (MLP) structure when the ANNs are used as MCP methods to predict mean hourly wind speeds at a target site. The features considered in this study were the mean hourly wind speeds and directions recorded in 2003 and 2004 at five weather stations in the Canary Archipelago (Spain).

The two feature selection techniques considered in the analysis were the Correlation Feature Selection (CFS), which is a correlation-based filter approach (FA), and an MLP-based wrapper approach (WA). The metrics used to compare the results were the mean absolute error (MAE), the mean absolute percentage error (MAPE) and the index of agreement (IoA).

Evaluation of the mean errors obtained in the 10-fold cross-validation tests for the year used to represent the short-term wind data period resulted in several conclusions. These included, notably, that the WA gave lower mean errors than the FA in 100% of the cases analysed independently of the metric employed. However, the FA resulted in a significant reduction in computational load and considerable enhancement of model interpretability. When very good correlation coefficients were obtained between the target and reference stations, no significant statistical difference was observed at 5% level between the three models (FA, WA and the models constructed with all the variables) in most of the cases analysed.

© 2015 Elsevier Ltd. All rights reserved.

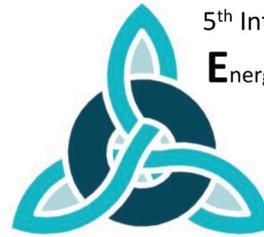
* Corresponding author. Tel.: +34 928 45 14 83; fax: +34 928 45 14 84.

E-mail address: jcarta@dim.ulpgc.es (J.A. Carta).

APÉNDICE

B

Conferences contributions



Application of Artificial Intelligence techniques to harmonize the consumption of an SWRO desalination plant with the variability of a renewable energy source

Pedro Cabrera^{*1}, José A. Carta¹, Jaime Gonzalez² and Baltasar Peñate³

¹*Department of Mechanical Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017, Las Palmas de Gran Canaria, Canary Islands, Spain*

²*Department of Electronics and Automatics Engineering, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017, Las Palmas de Gran Canaria, Canary Islands, Spain*

³*Department of Water, Canary Islands Institute of Technology (ITC), Playa de Pozo Izquierdo s/n, 35119 Santa Lucía- Gran Canaria, Spain*

Various desalination systems powered by renewable energy sources and using reverse osmosis technologies have been proposed to provide fresh water in remote, arid coastal locations. One approach used in some designs has been to maximize exploitation of the renewable energy source and minimize the need to use energy storage systems. With this in mind, several strategies have been considered which aim to optimize the non-steady state operation of seawater reverse osmosis (SWRO) desalination plants. One such strategy aims to adapt the energy consumed by the SWRO desalination plant by regulating the feed flow rate and operating pressure (within the acceptable operating limits of the membrane system) and maintaining a constant permeate recovery rate. The variable output of the renewable energy source/s, as well as the specific characteristics of the SWRO desalination plant and the feed water (including conductivity and temperature), need to be considered when determining the flow rate and pressure setpoints of a control system for such a plant. The present study proposes the implementation of Artificial Intelligence techniques and, more specifically, of Artificial Neural Networks (ANNs), in the determination of such setpoints. By using ANN models, the aim is to allow the control system of an SWRO desalination plant to self-adjust by enabling it to react to possible changes in the process and generate appropriate setpoints for any foreseeable circumstances. An analysis is presented of the results obtained after implementation of such ANN models in a small-scale prototype SWRO desalination plant installed on the island of Gran Canaria (Spain).

The copyright of the Abstract belongs to the authors. The North Sea Conference & Journal Ltd has a right to publish the Abstract on the conference website.

Keywords: Renewable energy, Reverse osmosis, Artificial Neural Network, Automatic control.

Comparison of MACHINE LEARNING TECHNIQUES used TO MANAGE the variable operation of an SWRO DESALINATION PLANT



Pedro Cabrera^{1*}, José A. Carta¹, Jaime González¹, Baltasar Peñate²
¹University of Las Palmas de Gran Canaria, ²Water Department - Canary Islands Institute of Technology (ITC)

[P1.43]

introduction

In SEAWATER REVERSE OSMOSIS (SWRO) desalination plants driven by RENEWABLE ENERGY SOURCES, THE POWER CONSUMED depends on:

- the feed pressure and
- the feed flow rate

which will vary according to the characteristics of the feed water.

It can therefore be of interest TO IMPLEMENT INTELLIGENT SYSTEMS which generate the appropriate operating pressure and feed flow setpoints which enable an operational energy balance of the SWRO desalination plant.

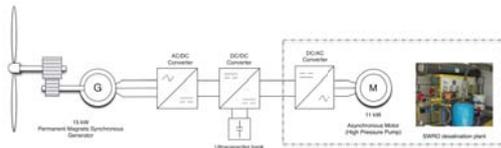


Fig. 1. General configuration of the wind energy based microgrid designed to desalinate seawater.

materials

The SWRO desalination plant will, in the near future, form part of the microgrid whose general configuration can be seen in Fig.1. Under exceptional circumstances, the SWRO desalination plant was disconnected from the microgrid and connected through a frequency converter to the conventional grid.

The devices operated by the control system are shown in Fig. 2, as well as the sensors installed in the plant (the signals of which are recorded by the control system). Also shown is the additional equipment (within the dash-dot line of the detailed view of Mixing-water tank) which was temporarily included in the system for the purpose of selectively modifying the characteristics of the feedwater (conductivity and temperature).

The SWRO is comprised of two pressure vessels, PV1 and PV2, each fitted with three membranes (Toray membranes. Model TM810) in series, which the control system can independently connect/disconnect to/from the system by operating the SV-3 valve. The power demand of the system can be modified when the control system adjusts the operating pressure (by operating the PSV valve) and feed flow of the membranes (by operating the frequency converter which drives the high pressure pump).

methods

The mission of the Machine Learning (ML) Techniques in the control system is to generate the setpoints of pressure, P_{in} and flow, Q_{in} , which are required to enable adaptation of the power consumed to the simulated generated power of a wind turbine. They are taking as input values:

- the power consumption, P_{wtr} of the SWRO desalination plant,
- the feedwater conductivity, C_f (conductivity sensor CT2 in Fig.2),
- and temperature, T_f (temperature sensor TT2 in Fig. 2),

The steps taken to carry out the tests on the prototype SWRO desalination plant are the following:

one Data collection for the SWRO desalination plant*.

1. The SWRO desalination plant was operated using one pressure vessel:
 - the feed flow rate was varied between 1 m³/h and 3 m³/h,
 - the conductivity between 48000µS/cm and 56000µS/cm,
 - and membrane input temperature between 20°C and 25°C.
2. The SWRO desalination plant was operated using two pressure vessels:
 - the feed flow rate was varied between 3 m³/h and 6 m³/h,
 - the conductivity between 48000µS/cm and 56000µS/cm,
 - and membrane input temperature between 20°C and 25°C.

*[This was done by following a sequence of nested loops such that for each set of three values of these variables the operating pressure was regulated until a steady state permeate recovery rate was obtained within the narrow range of between 13.5% and 13.6%].

two Selection, configuration and evaluation of three Machine Learning Techniques**:

- Artificial Neural Networks (ANN)
- Support Vector Regression (SVR)
- Random Forests (RF)

**4 models for each ML technique were built: one for each configuration (one or two pressure vessels) and output (pressure setpoint or flow setpoint).

three Testing for statistical significance between errors of the three techniques.

1. two-by-two ANOVA comparisons between errors of three models
2. adjusted p-values calculation using the procedure proposed by Benjamini and Hochberg for multiple comparisons.

conclusions

The analysis undertaken has demonstrated the ability of these three Machine Learning techniques to generate accuracy operating setpoints of an SWRO desalination plant. With them it is possible to adapt the energy consumption of the plant to the wide and random variation of the available electrical power.

Support Vector Regression and Random Forest have better performance than Artificial Neural Networks. There is not statistical difference significance between Support Vector Regression and Random Forest.

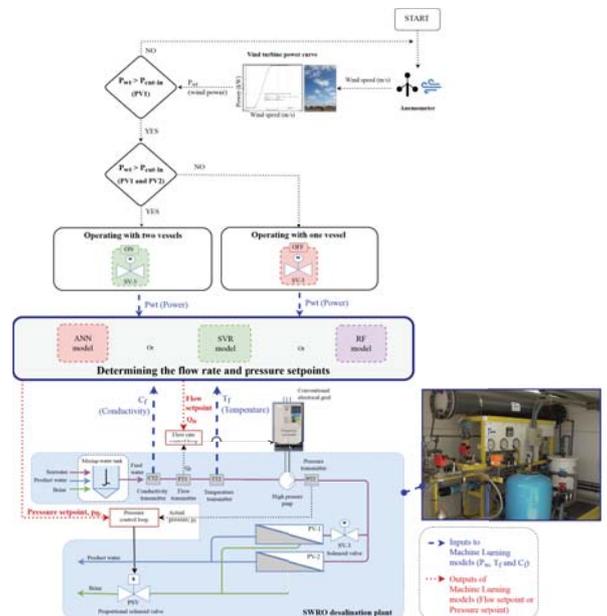


Fig. 2. Layout of the SWRO desalination plant prototype and control system.

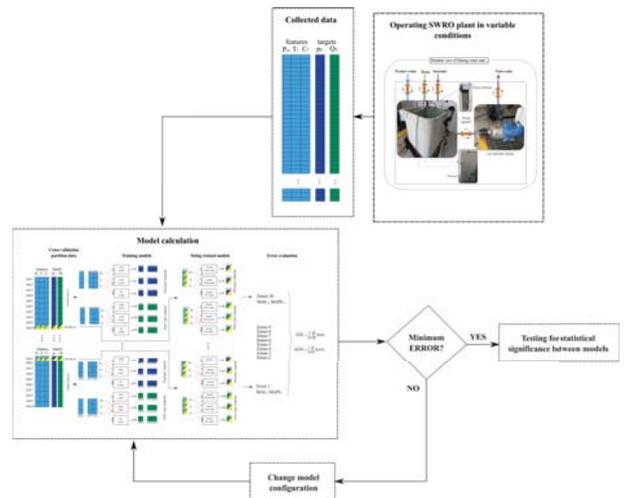


Fig. 3. Block diagram with a schematic representation of the methodology employed in the design and evaluation of the Machine Learning techniques used.

results

Table 1. P-values obtained from comparison of MAE errors of the three ML techniques evaluated.

	PRESSURE				FLOW RATE								
	ANN	SVR	RF	ANN	SVR	RF	ANN	SVR	RF				
1. vessel	(MAE)	(0.278)	(0.174)	(0.188)	(MAE)	(0.036)	(0.023)	(0.017)	(MAE)	(0.036)	(0.023)	(0.017)	
	ANN	0.0001	0.0015	-	ANN	0.0002	0.0010	0.0002	ANN	0.0002	0.0010	0.0001	
	SVR	0.0001	0.8457	-	SVR	0.023	0.0010	-	SVR	0.023	0.0010	-	
2. vessels	(MAE)	(0.253)	(0.122)	(0.129)	(MAE)	(0.047)	(0.031)	(0.023)	(MAE)	(0.047)	(0.031)	(0.023)	
	ANN	0.0000	0.0000	-	ANN	0.0000	0.0000	0.0015	ANN	0.0000	0.0000	0.0015	
	SVR	0.0000	0.8525	-	SVR	0.031	0.0000	-	SVR	0.031	0.0000	-	
RF	0.129	0.0000	0.8525	-	RF	0.023	0.0015	0.1553	-	RF	0.023	0.0015	0.1553

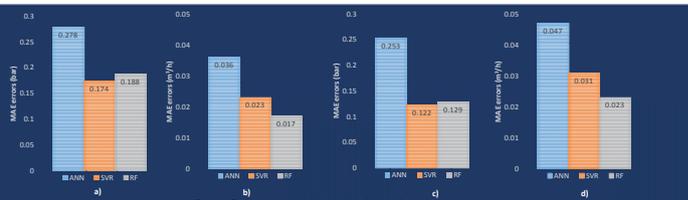


Fig. 4. MAE errors obtained for ML techniques in the estimation of setpoints: a) Pressure and b) Flow rate, for SWRO desalination plant operating with one pressure vessel; c) Pressure and d) Flow rate, for SWRO desalination plant operating with two pressure vessels.



APÉNDICE

C

Book chapter



Series: Sustainable Water Developments **4**

Renewable Energy Technologies for Water Desalination

Editors: Hacene Mahmoudi, Nouredine Ghaffour,
Matthaeus Goosen & Jochen Bundschuh

CHAPTER 5

Wind technology design and reverse osmosis systems for off-grid and grid-connected applications

Eftihia Tzen, Kyriakos Rossis, Jaime González, Pedro Cabrera,
Baltasar Peñate & Vicente Subiela

5.1 INTRODUCTION

Wind turbines can be used to supply electricity or mechanical power to desalination plants for the desalination of brackish water or seawater. Within the last century, with the installation of wind farms, wind energy has been mainly used for grid-connected applications with the purpose of selling electricity to the grid. However, in developing countries, and in some areas of developed countries, the use of wind turbines seems to have been more valuable to human life than just an investment for economic benefits. In rural and remote areas, the use of small wind turbines in mini-grids or stand-alone (off-grid) applications is essential for the improvement of inhabitants' lives and their socioeconomic development. Furthermore, the provision of electricity through renewable energy sources can replace the use of diesel generators, kerosene lamps, etc. and reduce environmental impacts, while also providing an affordable and sustainable solution.

The supply of drinking water has always been an important issue in the economic and social development plans of a country. Continuous efforts brought improvements in the conditions of drinking water supplies, in terms of quality and quantity, both in urban and rural areas.

Desalination of water by thermal or membrane processes is a sustainable and reliable solution for the provision of potable or freshwater in areas where there is a requirement. Several applications have been implemented using wind energy to drive reverse osmosis units and a few to drive mechanical vapor compression and electrodialysis units.

Desalination units driven by renewable energy sources (RES), such as those driven by wind energy, guarantee environment-friendly, cost-effective and sustainable production of desalinated water in those regions with severe potable water shortages that, nevertheless, are fortunate to have renewable energy resources. The combination of these technologies is uniquely suited to providing water and electricity in remote areas where the associated infrastructure is currently lacking. This chapter reviews wind technology, its development, and its utilization for the production of fresh or potable water via desalination systems.

5.2 WIND ENERGY TECHNOLOGY OVERVIEW

5.2.1 *Wind technology history*

From earliest recorded history, people have harnessed the energy of the wind. An example of this is the use of windmills in countries such as Persia, China and Egypt for grinding grain and draining land. In brief, the history of wind energy can be separated into four overlapping time periods (Schaffarczyk, 2014) as follows:

- *600 to 1890 (the Classical period)*. Within this period the exploitation of wind energy was implemented with the use of classic windmills. These were used as mechanical drives and, in most cases, for pumping water and grinding grain. More than 100,000 such windmills were

Financiación

La realización de esta tesis ha sido posible gracias al disfrute de una de las ayudas del **Programa de Ayudas a la Investigación de la ULPGC**, para financiar contratos predoctorales durante el periodo comprendido entre julio de 2014 y julio de 2018. Dicha ayuda fue financiada por la **Agencia Canaria de Investigación, Innovación y Sociedad de la Información** (ACIISI) del Gobierno de Canarias, y co-financiada en un 85 % por el Fondo Social Europeo.

Varios equipos del prototipo analizado se instalaron gracias al soporte económico de un proyecto de Investigación Fundamental no orientada del **Ministerio de Economía y Competitividad** del Gobierno de España (Ref. ENE2012-37847). También, gracias al proyecto financiado por la **ACIISI**, cuyo título es «*Sistema de desalación de agua del mar accionado por energía eólica - SODAMEE*» (Ref. SOL-SUBC200801000346).

Asimismo, durante la realización de esta tesis se ha realizado una estancia breve de investigación de 3 meses de duración (abril 2017 - junio 2017) en el *Departamento de Energy Planning* de la Universidad de Aalborg (Dinamarca), gracias a la co-financiación obtenida por una parte del proyecto **DESAL+**, del programa **INTERREG MAC 2014-2020** cofinanciado con **fondos FEDER**, y por otra parte del **Plan de Formación del Personal Investigador de la ULPGC**.

Pedro Cabrera

Las Palmas de Gran Canaria, diciembre 2017

Este trabajo se terminó de escribir en Las Palmas de Gran Canaria el 11 de
diciembre de 2017

This page is intentionally left blank