

2017

PREDICCIÓN DE POTENCIA A CORTO PLAZO PARA PLANTAS FOTOVOLTAICAS UTILIZANDO REDES NEURONALES ARTIFICIALES

CARRASCO CATALÁN, NICOLÁS ALEJANDRO

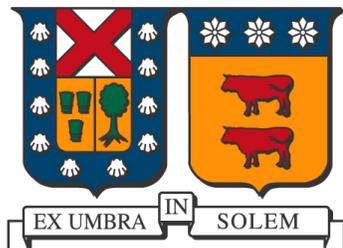
<http://hdl.handle.net/11673/22684>

Repositorio Digital USM, UNIVERSIDAD TECNICA FEDERICO SANTA MARIA

Universidad Técnica Federico Santa María

Departamento de Ingeniería Eléctrica

Valparaíso - Chile



"PREDICCIÓN DE POTENCIA A CORTO PLAZO PARA PLANTAS FOTOVOLTAICAS UTILIZANDO REDES NEURONALES ARTIFICIALES".

NICOLÁS ALEJANDRO CARRASCO CATALÁN

MEMORIA DE TITULACIÓN PARA OPTAR AL TÍTULO DE
INGENIERO ELECTRICISTA

Profesores Guías

Ignacio Antonio Calle

Alejandro Angulo Cárdenas

Correferente externo

Eduardo Soto Sepúlveda

26 de mayo de 2017

Material de referencia, su uso no involucra responsabilidad del autor o de la institución.

Resumen

La predicción de potencia fotovoltaica es importante para planear la operación del sistema eléctrico. En nuestro país hasta ahora no hay un método para predicción de variables fotovoltaicas. La empresa Phineal SpA, en sus continuos avances dentro de la energía solar, intenta estudiar el problema del pronóstico para ofrecer una herramienta de predicción solar.

En este estudio se ha predicho la potencia fotovoltaica de dos maneras: 1) utilizando aproximación de superficies mediante polinomios y 2) usando redes neuronales artificiales autoregresivas con variables exógenas (NARX). El objetivo es predecir valores horarios en un día entero. Para ambos métodos, de forma previa se requiere la predicción de la irradiancia solar, entre otras variables meteorológicas como la temperatura y la humedad relativa, todas predichas mediante redes neuronales artificiales (RNA). Los datos para alimentar las RNA se recogieron desde una planta fotovoltaica que posee una estación de medición meteorológica que capta: potencia fotovoltaica de salida de la planta (AC), temperatura ambiente y humedad relativa (desde 02/01/2015 hasta 31/12/2015). Para evaluar el poder de generalización de las RNA se prueban sucesivas redes, variando el tamaño de estas, probando con un conjunto de datos para validación. Las redes a escoger para predicción son las que tienen el menor error RMSE en el set de datos. Se prueba el poder de predicción de las RNA en dos condiciones distintas: días soleados y días nublados, pronosticando cinco días para cada situación. Para evaluar los pronósticos, se utilizan estadísticos recomendados por el Departamento de Energía y el Laboratorio de Energías Renovables de los Estados Unidos.

Los resultados indican que las Redes Neuronales pueden captar la tendencia de los datos y por consiguiente entregar una predicción adecuada en forma, pero a veces con errores considerables.

Abstract

Forecasting of solar power is important for the operation of the electrical system. In our country, until now, there isn't a method for prediction of solar variables. Phineal SpA, in their continuous advancements within the solar energy, tries to study the forecasting problem to offer a solar prediction tool.

In this study, the solar power has been predicted in two ways: 1) using polynomial surface fitting and 2) using NARX Neural Networks. The objective is to predict hourly values in an entire day. Both methods require the prediction of solar irradiance, among other meteorological variables such as temperature and relative humidity. All predictions have been made with Neural Networks. The data to feed the networks has been chosen from a photovoltaic plant that possess a meteorological station that measures: solar electric output power (AC), ambient temperature and relative humidity (data from 02/01/2015 to 31/12/2015). To evaluate the generalization of the Neural Networks, by varying the size of the networks, several configurations have been tested with a validation dataset. The final networks to choose are those who have a minimal RMSE error in the dataset. The predictions are made in two conditions: clear and cloudy days, forecasting five days for each situation. To evaluate the predictions, statistical tools recommended by the Department of Energy and the National Renewable Energy Laboratory from USA are used.

The results indicate that the Neural Networks are able to capture the trend in the data and therefore deliver an adequate prediction in form but sometimes with considerable errors.

Índice general

1. Introducción	14
2. Aspectos teóricos	18
2.1. Sistemas fotovoltaicos	18
2.1.1. Radiación solar	18
2.1.1.1. Componentes de la radiación	19
2.1.1.2. Medición de la radiación	19
2.1.1.3. Modelos para relacionar GHI con irradiancia POA	20
2.1.2. Tecnología fotovoltaica	21
2.1.3. Predicción fotovoltaica	22
2.1.3.1. Predicción de variables meteorológicas	23
2.1.3.2. Predicción de potencia fotovoltaica	24
2.2. Redes neuronales artificiales	26
2.2.1. Definición y propiedades	26
2.2.2. Tipos de redes neuronales	28
2.2.2.1. Redes estáticas	28
2.2.2.2. Redes dinámicas	29
2.2.3. Escogiendo la configuración de red a utilizar	32
2.2.3.1. Evitando overfitting	32
2.2.3.2. Número de neuronas en distintas capas de la red	33
2.2.4. Entrenamiento	34
2.2.4.1. Aprendizaje supervisado	34
2.2.4.2. Aprendizaje no supervisado	35
2.3. Desempeño de una predicción	35
2.3.1. Estadísticos para evaluar desempeño	35

3. Datos y método propuesto	38
3.1. Conjunto de datos	38
3.2. Método propuesto	39
3.2.1. Predicción de variables meteorológicas	39
3.2.2. Predicción de potencia fotovoltaica	41
4. Predicción de variables meteorológicas	46
4.1. Configuración de las redes neuronales	46
4.2. Días despejados	47
4.2.1. Radiación global horizontal con datos reales de entradas futuras	47
4.2.2. Temperatura	48
4.2.3. Humedad relativa	50
4.2.4. Radiación global horizontal en base a predicciones	51
4.2.5. Análisis de predicción de variables meteorológicas para días despejados	52
4.3. Días nublados	53
4.3.1. Radiación global horizontal con datos reales de entradas futuras	53
4.3.2. Temperatura	54
4.3.3. Humedad relativa	56
4.3.4. Radiación global horizontal en base a predicciones	57
4.3.5. Análisis de predicción de variables meteorológicas para días nublados	58
5. Predicción de potencia fotovoltaica	60
5.1. Días despejados	60
5.1.1. Mediante aproximación polinomial	61
5.1.2. Análisis de predicción de potencia para días despejados utilizando aproximación polinomial	64
5.1.3. Mediante redes neuronales artificiales	65
5.1.4. Análisis de predicción de potencia para días despejados utilizando redes neuronales artificiales	69
5.2. Días nublados	70
5.2.1. Utilizando aproximación polinomial	70
5.2.2. Análisis de predicción de potencia para días nublados utilizando aproximación polinomial	73
5.2.3. Mediante RNA	74

5.2.4. Análisis de predicción de potencia para días nublados utilizando redes neuronales artificiales	77
6. Conclusiones y trabajo a futuro	78
6.1. Utilización de redes neuronales artificiales para modelar variables meteorológicas .	78
6.2. Modelación fotovoltaica	79
6.3. Trabajo a futuro	79
A. Anexos	85

Índice de figuras

1.1. Potencial solar mundial	15
2.1. Espectro de la radiación solar	19
2.2. Elementos para medición de radiación solar	20
2.3. Característica I-V de un dispositivo fotovoltaico, determinada por su corriente de cortocircuito (I_{sc}) y su tensión en circuito abierto (V_{oc})	22
2.4. Dependencia de la potencia con respecto a la temperatura	22
2.5. Clasificación de los modelos basados en resolución espacial y temporal	24
2.6. Distintos métodos para generar pronósticos de potencia fotovoltaica	25
2.7. Circuitos equivalentes para modelación fotovoltaica	26
2.8. Representación simbólica de la neurona y perceptrón	27
2.9. Representación de perceptrón multicapa, considerando una sola capa oculta y posibles n entradas, m neuronas en capa oculta y o salidas	28
2.10. Línea de retardo	29
2.11. Red neuronal con retardo enfocado	30
2.12. Red neuronal con retardo distribuido	31
2.13. Esquema de una red NARX	31
2.14. Arquitecturas redes NARX	32
2.15. <i>Overfitting</i>	33
2.16. Esquema del entrenamiento de una red neuronal con aprendizaje supervisado	35
3.1. Estación de medición	39
3.2. Esquema de predicción de la radiación utilizando redes NARX	40
3.3. División de datos pasados para entrenar las RNA y ajustar su respuesta	40
3.4. Gráfico de potencia en función de la temperatura y radiación global en plano horizontal	42
3.5. Aproximación de la potencia mediante polinomios	42

3.6.	Aproximación de la potencia mediante polinomios en verano	43
3.7.	Aproximación de la potencia mediante polinomios en invierno	43
4.1.	Procedimiento a utilizar para predicción y análisis de variables meteorológicas . . .	46
4.2.	Predicción de radiación utilizando entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015	48
4.3.	Predicción de temperatura en días despejados. 23-04 hasta 27-04 del 2015	49
4.4.	Predicción de humedad relativa utilizando entradas reales futuras en días despejados. 17-07 hasta 21-07 del 2015	50
4.5.	Predicción de radiación utilizando entradas predichas en días despejados. 23-04 hasta 27-04 del 2015	51
4.6.	Predicción de radiación utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	54
4.7.	Predicción de temperatura utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	55
4.8.	Predicción de humedad relativa utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	56
4.9.	Predicción de radiación utilizando entradas predichas en días nublados. 17-07 hasta 21-07 del 2015	57
5.1.	Predicción de potencia utilizando aproximación polinomial con entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015	61
5.2.	Distribución de errores de predicción utilizando aproximación polinomial con entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015	62
5.3.	Predicción de potencia utilizando aproximación polinomial con entradas predichas en días despejados. 23-04 hasta 27-04 del 2015	63
5.4.	Distribución de errores de predicción utilizando aproximación polinomial con entradas predichas en días despejados. 23-04 hasta 27-04 del 2015	64
5.5.	Predicción de potencia utilizando RNA con entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015	66
5.6.	Distribución de errores de predicción utilizando RNA con entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015	67
5.7.	Predicción de potencia utilizando RNA con entradas predichas en días despejados. 23-04 hasta 27-04 del 2015	68
5.8.	Distribución de errores de predicción utilizando RNA con entradas predichas en días despejados. 23-04 hasta 27-04 del 2015	69

5.9. Predicción de potencia utilizando aproximación polinomial con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	70
5.10. Distribución de errores de predicción utilizando aproximación polinomial con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	71
5.11. Predicción de potencia utilizando aproximación polinomial con entradas predichas en días nublados. 17-07 hasta 21-07 del 2015	72
5.12. Distribución de errores de predicción utilizando aproximación polinomial con entradas predichas futuras en días nublados. 17-07 hasta 21-07 del 2015	73
5.13. Predicción de potencia utilizando RNA con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	74
5.14. Distribución de errores de predicción utilizando RNA con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	75
5.15. Predicción de potencia utilizando RNA con entradas predichas en días nublados. 17-07 hasta 21-07 del 2015	76
5.16. Distribución de errores de predicción utilizando RNA con entradas predichas en días nublados. 17-07 hasta 21-07 del 2015	77
A.1. Calibración de la mejor red neuronal escogida para predecir la radiación del 23 de abril del 2015	94
A.2. Calibración de la mejor red neuronal escogida para predecir la radiación del 24 de abril del 2015	95
A.3. Calibración de la mejor red neuronal escogida para predecir la radiación del 25 de abril del 2015	95
A.4. Calibración de la mejor red neuronal escogida para predecir la radiación del 26 de abril del 2015	96
A.5. Calibración de la mejor red neuronal escogida para predecir la radiación del 27 de abril del 2015	96
A.6. Calibración de la mejor red neuronal escogida para predecir la temperatura del 23 de abril del 2015	97
A.7. Calibración de la mejor red neuronal escogida para predecir la temperatura del 24 de abril del 2015	98
A.8. Calibración de la mejor red neuronal escogida para predecir la temperatura del 25 de abril del 2015	98
A.9. Calibración de la mejor red neuronal escogida para predecir la temperatura del 26 de abril del 2015	99
A.10. Calibración de la mejor red neuronal escogida para predecir la temperatura del 27 de abril del 2015	99

A.11. Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 23 de abril del 2015	100
A.12. Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 24 de abril del 2015	101
A.13. Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 25 de abril del 2015	101
A.14. Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 26 de abril del 2015	102
A.15. Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 27 de abril del 2015	102
A.16. Calibración de la mejor red neuronal escogida para predecir la radiación del 17 de julio del 2015	103
A.17. Calibración de la mejor red neuronal escogida para predecir la radiación del 18 de julio del 2015	104
A.18. Calibración de la mejor red neuronal escogida para predecir la radiación del 19 de julio del 2015	104
A.19. Calibración de la mejor red neuronal escogida para predecir la radiación del 20 de julio del 2015	105
A.20. Calibración de la mejor red neuronal escogida para predecir la radiación del 21 de julio del 2015	105
A.21. Calibración de la mejor red neuronal escogida para predecir la temperatura del 17 de julio del 2015	106
A.22. Calibración de la mejor red neuronal escogida para predecir la temperatura del 18 de julio del 2015	107
A.23. Calibración de la mejor red neuronal escogida para predecir la temperatura del 19 de julio del 2015	107
A.24. Calibración de la mejor red neuronal escogida para predecir la temperatura del 20 de julio del 2015	108
A.25. Calibración de la mejor red neuronal escogida para predecir la temperatura del 21 de julio del 2015	108
A.26. Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 17 de julio del 2015	109
A.27. Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 18 de julio del 2015	110
A.28. Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 19 de julio del 2015	110

A.29. Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 20 de julio del 2015	111
A.30. Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 21 de julio del 2015	111
A.31. Calibración de la mejor red neuronal escogida para predecir la potencia del 23 de abril del 2015	112
A.32. Calibración de la mejor red neuronal escogida para predecir la potencia del 24 de abril del 2015	113
A.33. Calibración de la mejor red neuronal escogida para predecir la potencia del 25 de abril del 2015	113
A.34. Calibración de la mejor red neuronal escogida para predecir la potencia del 26 de abril del 2015	114
A.35. Calibración de la mejor red neuronal escogida para predecir la potencia del 27 de abril del 2015	114
A.36. Calibración de la mejor red neuronal escogida para predecir la potencia del 17 de julio del 2015	115
A.37. Calibración de la mejor red neuronal escogida para predecir la potencia del 18 de julio del 2015	116
A.38. Calibración de la mejor red neuronal escogida para predecir la potencia del 19 de julio del 2015	116
A.39. Calibración de la mejor red neuronal escogida para predecir la potencia del 20 de julio del 2015	117
A.40. Calibración de la mejor red neuronal escogida para predecir la potencia del 21 de julio del 2015	117

Índice de tablas

2.1. Dispositivos para medir radiación	20
3.1. Datos técnicos estación de medición	38
3.2. Estadísticos para evaluar predicción de variables meteorológicas	41
3.3. Errores en predicción mediante aproximación polinomial	44
3.4. Estadísticos para evaluar predicción de potencia fotovoltaica	45
4.1. Valores máximos a considerar para la búsqueda de redes neuronales para predicción de variables meteorológicas	47
4.2. Configuración de redes para pronosticar la radiación en días despejados. 23-04 hasta 27-04 del 2015	47
4.3. Estadísticos para evaluar predicción de radiación utilizando entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015	48
4.4. Configuración de redes para pronosticar la temperatura en días despejados. 23-04 hasta 27-04 del 2015	49
4.5. Estadísticos para evaluar predicción de temperatura utilizando entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015	49
4.6. Configuración de redes para pronosticar la humedad relativa en días despejados. 23-04 hasta 27-04 del 2015	50
4.7. Estadísticos para evaluar predicción de humedad relativa utilizando entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015	51
4.8. Estadísticos para evaluar predicción de radiación utilizando entradas predichas en días despejados. 23-04 hasta 27-04 del 2015	52
4.9. Configuración de redes para pronosticar la radiación en días nublados. 17-07 hasta 21-07 del 2015	53
4.10. Estadísticos para evaluar predicción de radiación utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	54

4.11. Configuración de redes para pronosticar la temperatura en días nublados. 17-07 hasta 21-07 del 2015	55
4.12. Estadísticos para evaluar predicción de temperatura utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	55
4.13. Configuración de redes para pronosticar la humedad relativa en días nublados. 17-07 hasta 21-07 del 2015	56
4.14. Estadísticos para evaluar predicción de humedad relativa utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	57
4.15. Estadísticos para evaluar predicción de radiación utilizando entradas predichas en días nublados. 17-07 hasta 21-07 del 2015	58
5.1. Valores máximos a considerar para la búsqueda de redes neuronales para predicción de potencia	60
5.2. Estadísticos para evaluar predicción de potencia utilizando aproximación polinomial con entradas reales futuras en días despejados. 23-04 al 27-04 del 2015	62
5.3. Estadísticos para evaluar predicción de potencia utilizando aproximación polinomial con entradas predichas en días despejados. 23-04 al 27-04 del 2015	63
5.4. Configuración de redes para pronosticar la potencia en días despejados. 23-04 hasta 27-04 del 2015	65
5.5. Estadísticos para evaluar predicción de potencia utilizando RNA con entradas reales futuras en en días despejados. 23-04 al 27-04 del 2015	67
5.6. Estadísticos para evaluar predicción de potencia utilizando RNA con entradas predichas en días despejados. 23-04 al 27-04 del 2015	68
5.7. Estadísticos para evaluar predicción de potencia utilizando aproximación polinomial con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	71
5.8. Estadísticos para evaluar predicción de potencia utilizando aproximación polinomial con entradas predichas en días nublados. 17-07 al 21-07 del 2015	72
5.9. Configuración de redes para pronosticar la potencia en días nublados. 17-07 hasta 21-07 del 2015	74
5.10. Estadísticos para evaluar predicción de potencia utilizando RNA con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015	75
5.11. Estadísticos para evaluar predicción de potencia utilizando RNA con entradas predichas en días nublados. 17-07 hasta 21-07 del 2015	76

Capítulo 1

Introducción

Motivación

La sociedad contemporánea, dado su crecimiento demográfico e industrial, requiere cada vez de una cantidad mayor de energía eléctrica para satisfacer sus necesidades. La cantidad de contaminantes que afectan al medioambiente y la dependencia de los combustibles fósiles que poseen la mayoría de las grandes centrales actuales han llevado a enfrentar un nuevo reto: conseguir que las energías renovables sustituyan de manera paulatina a la generación convencional.

Para lograr el acometido de incrementar las ERNC, el Ministerio de Energía crea la Hoja de Ruta 2050 [1], que consiste en un plan energético que contempla la inclusión de al menos un 70 % de Energías Renovables al 2050.

Entre las fuentes de energías renovables se encuentra la solar, que ha gozado de un crecimiento importante en el mundo. Entre los años 2001 a 2015 se ha visto que la potencia instalada es duplicada aproximadamente cada dos años. La potencia en 2008 fue de 16 GW, 40 GW en 2010, 100 GW en 2012, 140 GW en 2013, 180 GW en 2014 y 233 GW en 2015.

VAISALA

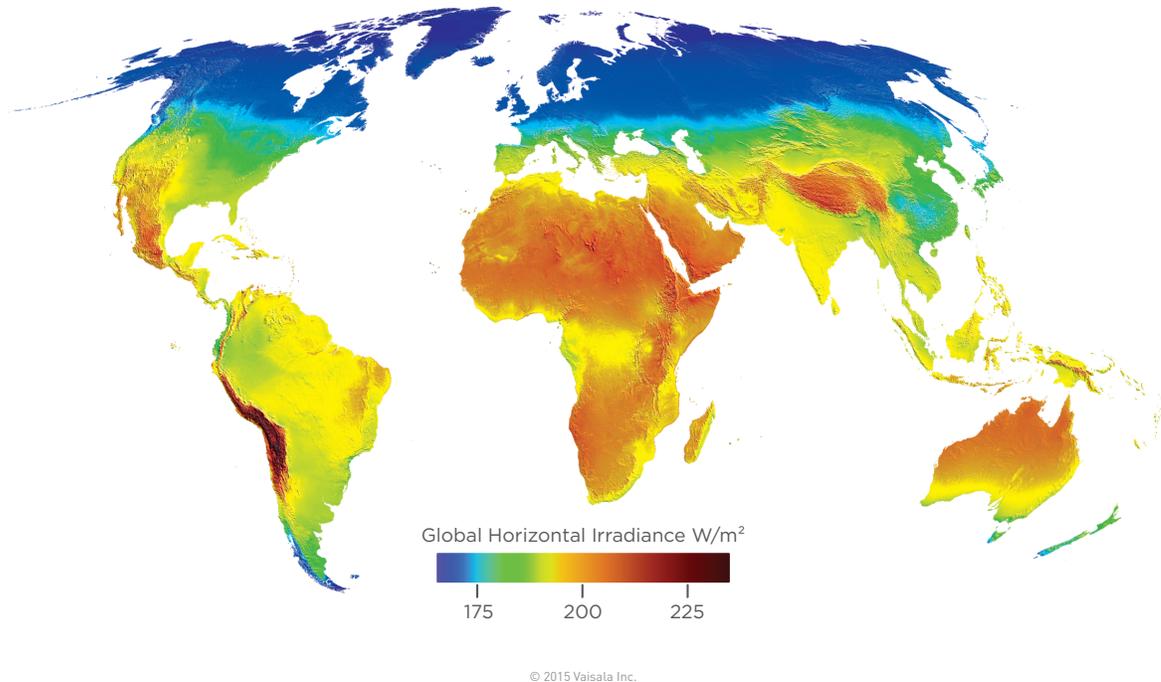


Figura 1.1: Potencial solar mundial [2]

Chile tiene un potencial solar considerable, como lo muestra la figura 1.1. La radiación solar en Calama alcanza los 2500 kWh/m² al año. Para dimensionar la gran diferencia que se tiene, el potencial del sur de Alemania, país líder en potencia instalada solar, con 40 GW instalados al final del 2015 [3] equivale al de Puerto Montt, con aproximadamente 1400 kWh/m² anuales. El potencial del sur de España, uno de los países de Europa con mayor irradiancia anual [4], equivale al de Santiago, con 1800 kWh/m² anuales. Comparativamente hablando, en Chile la potencia solar fotovoltaica instalada a septiembre del 2015 es relativamente baja con respecto a países que no tienen tanto recurso solar, alcanzando los 597 MW [5].

Uno de los problemas asociados con la energía fotovoltaica es la característica intrínseca de producción de potencia intermitente dependiente de las condiciones atmosféricas, especialmente de la radiación solar y la temperatura ambiente [6]. Aquella generación no controlada puede causar problemas de control y operación en las redes eléctricas, dado que estas tienen que lidiar frecuentemente con rápidos excesos o caídas en cuanto a la producción generada. El pronóstico de la potencia a producir por una planta fotovoltaica es importante en general por una serie de razones. Para dueños o administradores de sistemas fotovoltaicos una buena predicción sirve para: monitorear el rendimiento de las plantas, detectar fallas y ayudar a escoger el mejor momento para desconectar la planta en caso de ser necesario mantenimiento [6]. En [7] analizan el efecto que el error de

pronóstico de potencia fotovoltaica ejerce en redes de media y baja tensión, concluyendo que uno de los grandes desafíos en cuanto a generación fotovoltaica está en el efecto de sobretensiones durante el día, lo que se puede mejorar con un buen pronóstico de generación. Para los operadores del sistema, una herramienta de predicción puede ayudar tanto al predespacho (horizonte 24 h) como a la estabilidad del sistema (predicciones intradiarias, generalmente 6 h).

La empresa Phineal SpA se enfoca en proyectos y desarrollos de herramientas dedicadas a la tecnología solar. Dentro de sus proyectos, está el crear una herramienta para ofrecer predicciones a corto plazo para plantas fotovoltaicas. Para lograr el objetivo la empresa cuenta con estaciones de medición solar *phiNet* concentradas entre Santiago, Valparaíso y Rancagua. Las estaciones capturan datos meteorológicos como: radiación solar, temperatura, humedad relativa entre otras. Dadas las mediciones se intentará analizar la serie de tiempo de las variables que más afecten a las plantas fotovoltaicas utilizando Redes Neuronales Artificiales (RNA) por su gran flexibilidad, relativa sencillez en la implementación y potencial en las predicciones.

Objetivos

Objetivo general

Plantear un método para predicción de potencia fotovoltaica a corto plazo mediante Redes Neuronales Artificiales.

Objetivos específicos

- Estudiar modelos para cálculo de potencia fotovoltaica a partir de la irradiancia y temperatura.
- Recolección de datos para alimentar RNA a partir de mediciones hechas por estaciones de medición *phiNet* y externos.
- Diseñar diferentes arquitecturas de RNA a partir de los datos obtenidos con objeto de predecir irradiancia y temperatura ambiente.
- Determinar las redes que mejor se comporten, mediante herramientas estándar para analizar errores en predicciones fotovoltaicas.
- Utilizar datos predichos como entrada hacia modelo de simulación de sistemas fotovoltaicos para comparar predicciones hechas con potencia de salida de planta fotovoltaica a definir.

Estructura del documento

El cuerpo principal de la memoria se divide en 6 capítulos, los cuales contienen la información más relevante del trabajo realizado. En los anexos, por su parte, se encuentra la información que es

complementaria al trabajo. Los capítulos se estructuran de la siguiente manera:

- En el capítulo 2 se encuentran los aspectos teóricos en los cuales se basa el trabajo. La primera parte presenta a los sistemas fotovoltaicos y las variables que afectan a la producción de potencia. La segunda parte expone las redes neuronales artificiales tanto en su teoría como en su aplicación para predicción de series de tiempo. La tercera parte exhibe cómo se analiza el desempeño de una predicción, presentando los estadísticos a usar en el trabajo.
- El capítulo 3 presenta tanto los datos recopilados como el método propuesto, tanto para hacer predicciones de variables meteorológicas como para predecir la potencia fotovoltaica.
- El capítulo 4 muestra los resultados de predecir variables meteorológicas durante cinco días seguidos mediante RNA, tanto para días despejados como para días nublados.
- El capítulo 5 utiliza los resultados obtenidos en el capítulo 4 para calcular la potencia fotovoltaica durante esos mismos días. La potencia se obtendrá de dos formas: 1) mediante aproximar de forma polinomial la superficie generada a partir de la potencia, radiación y temperatura con los datos de últimos días y 2) utilizando RNA con la radiación, temperatura, humedad relativa y hora del día como entradas exógenas.
- Finalmente, en el capítulo 6 se encuentran las principales conclusiones y recomendaciones de este trabajo.

Capítulo 2

Aspectos teóricos

2.1. Sistemas fotovoltaicos

2.1.1. Radiación solar

El sol es el centro de gravedad de nuestro sistema solar y es la fuente de energía para nuestro planeta. La energía emitida por el sol permite, directa o indirectamente, la existencia de la vida en la tierra. El sol consiste en 71 % de Hidrógeno, 27 % de Helio y 2 % de materia sólida. Alrededor del centro la temperatura ronda los 16 millones de grados y el área de reacción nuclear en el núcleo toma hasta un cuarto de su diámetro total, que es aproximadamente 1.392.000 km. La masa del sol es aproximadamente 332.000 veces la masa de la tierra.

La energía emitida por el sol equivale a una radiación de 63 MW por m² de la superficie. La distancia entre el sol y la tierra alcanza una media de 150 millones de kilómetros (1 Unidad Astronómica, UA). El espectro de radiación solar se distribuye desde el infrarrojo hasta el ultravioleta, como muestra la figura 2.1. La irradiancia que alcanza el exterior de la atmósfera de la tierra es conocida como la Constante Solar (E_0). El valor calculado en 1982, utilizado por la Organización Meteorológica Mundial es 1.367 W/m², no obstante, el valor obtenido por la NASA a base de mediciones extra-terrestres en 2008 es de 1.360,8±0,5 W/m².

De la radiación que llega al exterior de la atmósfera, no toda alcanza la superficie de la Tierra, porque las ondas ultravioletas más cortas son absorbidas por los gases presentes en la atmósfera.

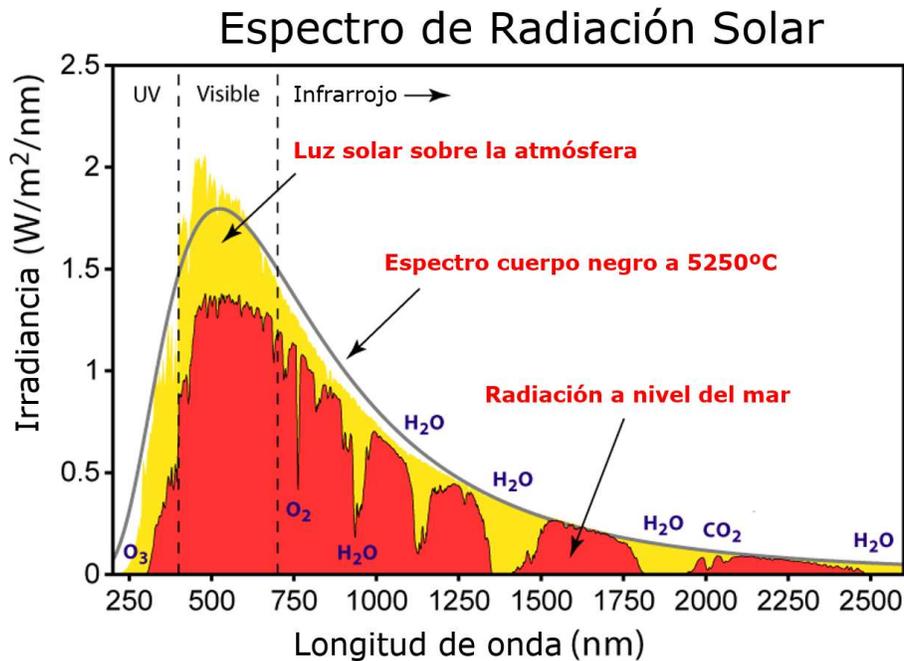


Figura 2.1: Espectro de la radiación solar [8]

2.1.1.1. Componentes de la radiación

La irradiancia que llega al plano horizontal terrestre se puede analizar separando sus componentes: la que llega directamente desde el sol se denomina radiación directa normal, o DNI (Direct Normal Irradiance) y la radiación que es desviada por las nubes y otras partículas atmosféricas se denomina radiación horizontal difusa, o DHI (Diffuse Horizontal Irradiance). La radiación total que llega en un plano horizontal está compuesta por la suma entre el DHI y DNI y se denomina radiación global horizontal, o GHI (Global Horizontal Irradiance).

Cuando el plano a analizar no es el horizontal, se puede hablar de la radiación en plano inclinado, o irradiancia POA (Plane of Array). Esta se compone de la radiación directa en el plano, POA_{dir} , y de dos radiaciones difusas en ese mismo plano: una correspondiente a la difusa que viene desde el cielo, $\text{POA}_{diff,sky}$, y la otra siendo la difusa proveniente del reflejo de la radiación directa en la superficie, $\text{POA}_{diff,ref}$.

2.1.1.2. Medición de la radiación

Las radiaciones mencionados anteriormente se pueden medir utilizando un piranómetro (Fig. 2.2a) y un pirheliómetro (Fig. 2.2a)). El primero tiene un sensor capaz de captar la radiación en un campo

de visión de 180 grados, mientras el segundo capta la radiación directa, al tener un campo de visión menor a 5 grados. La tabla 2.1 resume los instrumentos necesarios para medir las distintas componentes de la radiación.



(a) Piranómetro referencial. [9] (b) Pirheliómetro referencial. [10]

Figura 2.2: Elementos para medición de radiación solar

Radiación	Global	Difusa	Reflejada	Directa
Sensor	Piranómetro	Piranómetro	Piranómetro	Pirheliómetro
Campo de vista	180°	180°	180°	<5°
Accesorio adicional	Ninguno	Dispositivo para crear sombra	Escudo reflectante	Seguidor solar

Tabla 2.1: Dispositivos para medir radiación

Históricamente, en las estaciones meteorológicas se suele medir la radiación global en plano horizontal [11]. Tener registrado el GHI ayuda a tener un plano general de cómo es el potencial solar de un lugar específico. No es muy común medir la radiación directa, producto de que el conjunto entre el pirheliómetro y el seguidor solar suelen generar un importante costo económico.

2.1.1.3. Modelos para relacionar GHI con irradiancia POA

Los modelos para relacionar la irradiancia incidente en un plano inclinado a partir de la radiación global horizontal son críticos para el desempeño de análisis fotovoltaicos, porque lo usual es medir solamente el GHI y los paneles fotovoltaicos son dispuestos en un plano tal que se pueda maximizar la producción anual de energía. El modelar la irradiancia POI involucra dos pasos [12]: 1) la descomposición del GHI entre sus componentes directa y difusa; y 2) la transposición de estas componentes al POA de los módulos. Por el momento, no hay combinación de descomposición y transposición de componentes que sea considerada un estándar.

Hay numerosos estudios previos que evalúan la descomposición [13, 14], transposición [15–17] o una combinación entre ellas [18]. Aún con lo anterior, una dificultad que se debe enfrentar es que estos estudios son muy locales debido a los distintos tipos de climas. La mayoría de los estudios

son hechos en Canadá, Estados Unidos y algunos países de Europa. No se encuentra un método en Chile para descomponer o transponer las componentes de la irradiancia.

2.1.2. Tecnología fotovoltaica

El material básico para la tecnología fotovoltaica es la celda fotovoltaica. Esta aprovecha el efecto fotovoltaico para la creación de tensión o corriente cuando está expuesta a la luz. En 1954 se crea la primera celda solar, capaz de convertir el 6 % de la irradiancia incidente en electricidad. Recientemente, científicos en la universidad NSW de Australia han logrado un peak de eficiencia solar obteniendo un 34.5 % de aprovechamiento en la conversión. De todas formas, los módulos solares comúnmente comercializados tienen una eficiencia que ronda el 20 %.

Para utilizar las celdas fotovoltaicas, estas se interconectan formando un panel. Estos a su vez se pueden interconectar para obtener las tensiones y corrientes requeridas. La naturaleza modular de los sistemas fotovoltaicos es muy adecuada para los techos de construcciones como casas o edificios, donde las cargas eléctricas están cerca de la generación. No obstante, también se pueden encontrar grandes parques fotovoltaicos, aunque estos requieren de líneas de transmisión para transportar la energía producida.

La potencia eléctrica es producto de la tensión (V) y la corriente (I). En el caso de un dispositivo fotovoltaico, la potencia a entregar está determinada por la característica de la curva $V - I$ (Fig. 2.3), que depende en mayor parte de la irradiancia, la temperatura y la impedancia de la carga a conectar. La característica de cortocircuito varía en forma directamente proporcional con la radiación incidente (Fig. 2.3), y la potencia que puede entregar el dispositivo disminuye cuando aumenta la temperatura (Fig. 2.4).

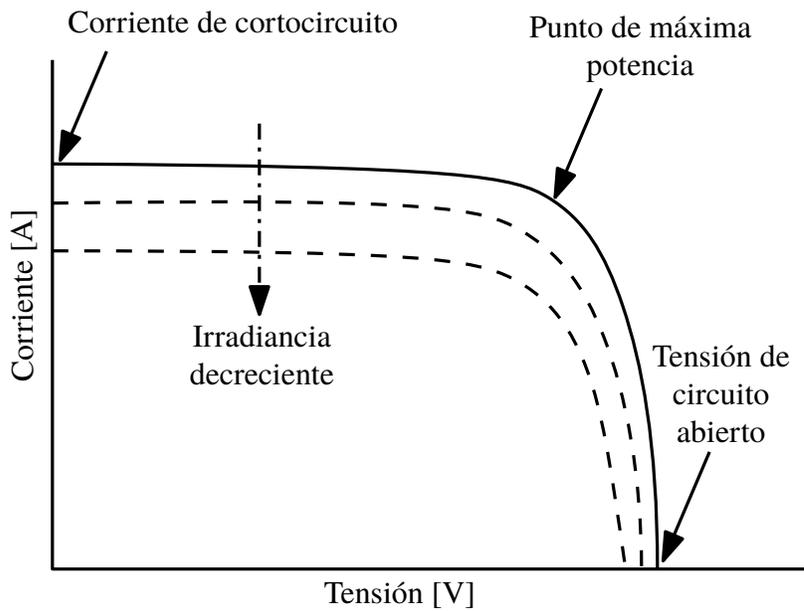


Figura 2.3: Característica I-V de un dispositivo fotovoltaico, determinada por su corriente de cortocircuito (I_{sc}) y su tensión en circuito abierto (V_{oc})

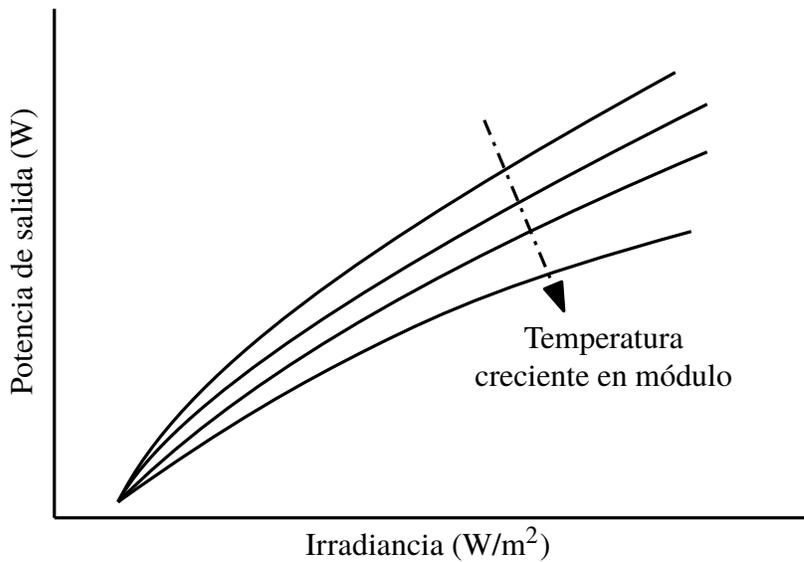


Figura 2.4: Dependencia de la potencia con respecto a la temperatura

2.1.3. Predicción fotovoltaica

Las predicciones fotovoltaicas se pueden separar entre físicas y estadísticas. Las físicas utilizan modelos de potencia fotovoltaica, que normalmente dependen de la radiación solar y temperatura,

mientras que las estadísticas se encargan de pronosticar la serie de tiempo de la potencia fotovoltaica, dejando de lado los modelos fotovoltaicos. Si bien ha habido mucha investigación en los últimos años, aún no hay un estándar para la predicción [19].

2.1.3.1. Predicción de variables meteorológicas

Dado que el parámetro clave para determinar potencia fotovoltaica es la irradiancia, es que los métodos de predicción físicos se enfocan principalmente en esta variable. Entre los métodos para predecir la radiación solar se encuentran [20]:

- Modelos estadísticos. Enfocados principalmente en predicción a corto plazo. Ejemplos de modelos son el autoregresivo (AR) y autoregresivo con medias móviles (ARMA). El uso de aprendizaje automático (*Machine Learning*) para predecir los valores futuros de una serie de tiempo es una alternativa a los modelos lineales clásicos. Las redes neuronales artificiales (RNA) recaen en esta categoría.
- Para predicción de irradiancia a corto plazo, la información sobre el desarrollo temporal de las nubes que determina en alto grado la irradiancia en un cierto lugar, puede usarse como base:
 - Predicciones basadas en vectores de movimiento de nubes a partir de imágenes satelitales [21] muestran buenos pronósticos para el rango temporal de 30 minutos hasta 6 horas.
 - Para rangos menores a una hora, la información de las nubes a partir de imágenes tomadas y procesadas desde la superficie se puede utilizar para generar predicciones.
- Para horizontes mayores de predicción, a partir de aproximadamente 6 horas, los pronósticos basados en Predicción Meteorológica Numérica o NWP (Numerical Weather Prediction) típicamente son los más confiables, y superan a los pronósticos satelitales [22]. Las predicciones NWP utilizan modelos matemáticos de la atmósfera y océanos para predecir el clima basado en condiciones actuales de este.

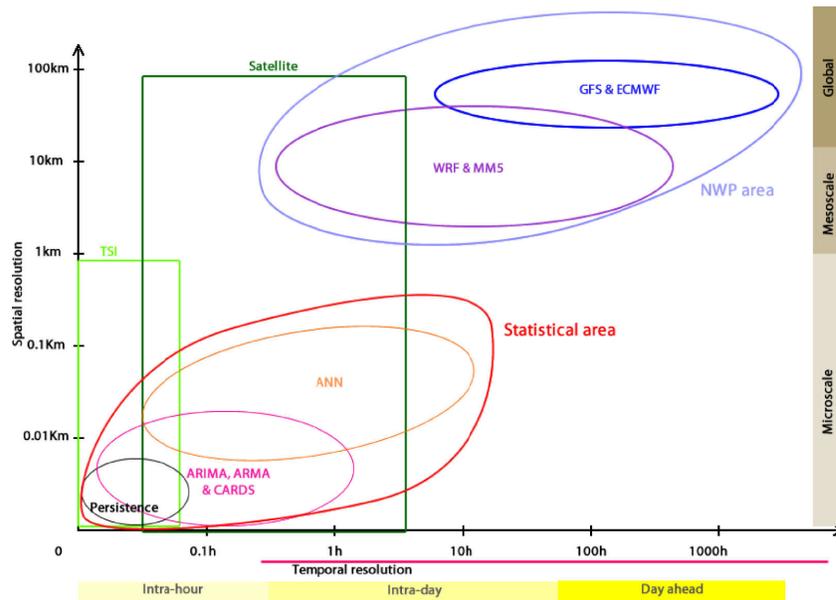


Figura 2.5: Clasificación de los modelos basados en resolución espacial y temporal [20]

La figura 2.5 muestra una clasificación de los modelos de predicción con respecto a resoluciones espaciales y temporales [20].

2.1.3.2. Predicción de potencia fotovoltaica

Las salidas obtenidas desde las predicciones meteorológicas deben convertirse en potencia fotovoltaica. La figura 2.6 muestra los distintos métodos para generar predicciones de potencia fotovoltaica.

Los **modelos físicos** dependen de las especificaciones técnicas de los elementos que conforman el sistema fotovoltaico: módulos, inversores, cables, entre otros. El nivel de complejidad depende de la exactitud con la que se quiera modelar el sistema y la gran ventaja de estos métodos es que no se requieren datos históricos para la modelación. Lo anterior hace que sean ideales para la evaluación de proyectos solares.

El método más sencillo es considerar solamente la irradiancia que recibe el panel (G), junto a la eficiencia total (μ) y área total (A):

$$P = \mu GA$$

Paatero [23] utiliza un método similar pero incorpora la temperatura ambiente. La salida del arreglo fotovoltaico sigue siendo calculada como $P = \mu GA$, pero ahora μ está compuesta principalmente de tres factores: μ_0 siendo la eficiencia de los paneles, μ_{inv} la del inversor y una expresión que representa la dependencia de la temperatura:

$$\mu = \mu_0 \left(1 - 0.0042 \left(\frac{I}{18} + T_a - 20 \right) \right) \mu_{inv}$$

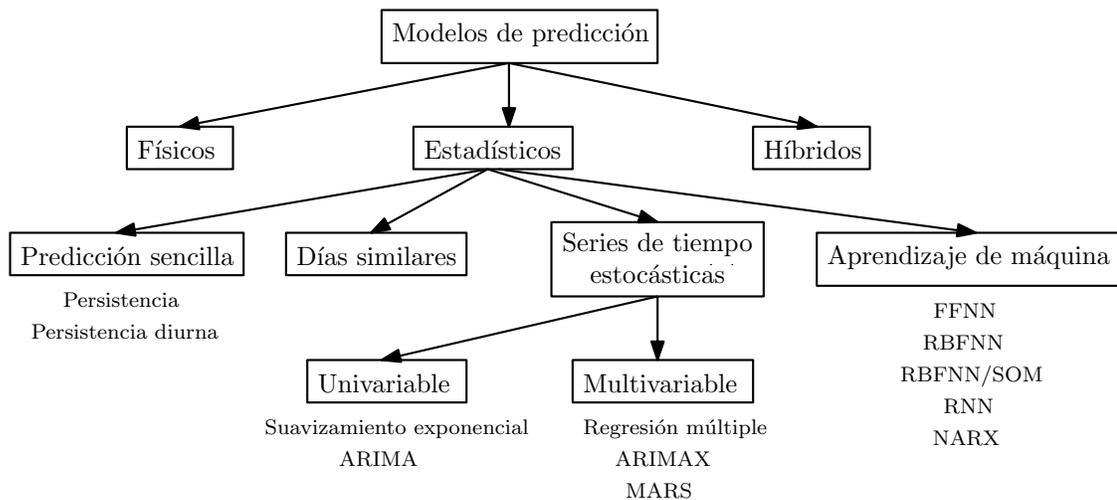


Figura 2.6: Distintos métodos para generar pronósticos de potencia fotovoltaica [19]

Otra manera de modelar sistemas fotovoltaicos se enfoca en las celdas, y se realiza utilizando circuitos equivalentes simplificados. El modelo matemático está basado en asumir que la celda fotovoltaica, que es un dispositivo semiconductor, opera como un diodo. Los modelos simplificados más utilizados son: ideal y diodo simple.

El propósito del modelamiento matemático de las celdas fotovoltaicas es obtener curvas V-I con alta precisión, teniendo como entradas la radiación (G) y la temperatura (T). El modelo más simple está caracterizado por tres parámetros y se muestra en la figura 2.7a. El circuito incluye una fuente de corriente en paralelo a un diodo, representando la corriente generada por la luz y el comportamiento eléctrico de la unión P-N. Su característica V-I está definida por 2.1,

$$I = I_{PV} - I_D = I_{PV} - I_0 \left(\exp^{\frac{V}{n \cdot V_t}} - 1 \right) \quad (2.1)$$

Los tres parámetros que caracterizan a este modelo son I_{PV} , I_0 y n que representan la corriente generada por luz, la corriente de saturación inversa de la unión PN y el coeficiente de idealidad del diodo, respectivamente.

El modelo más complejo depende de cinco parámetros y está representado en la figura 2.7c. Los parámetros que se añaden representan las pérdidas y son: resistencia serie $R_{S,c}$ y resistencia paralelo $R_{SH,c}$. La ecuación general del modelo de 5 parámetros está dada por 2.2,

$$I = I_{PV} - I_0 \left(\exp^{\frac{V + IR_{S,c}}{n \cdot V_t}} - 1 \right) - \frac{V + IR_{S,c}}{R_{SH,c}} \quad (2.2)$$

El impacto de la resistencia serie es cuando la celda presenta altas tensiones, y se comporta como una fuente ideal de tensión. Cuando la celda presenta tensiones muy bajas, la resistencia paralelo afecta mayormente y el circuito se comporta como una fuente de corriente ideal.

Dado que la resistencia paralelo generalmente asume valores altos [24], su impacto final en la

curva V-I es bajo. Por lo anterior, un circuito equivalente simplificado de 4 parámetros puede ser desarrollado, despreciando a $R_{SH,c}$. El circuito se muestra en la figura 2.7b y tiene como ecuación general a 2.3:

$$I = I_{PV} - I_0 \left(\exp \frac{V+IR_{S,c}}{n \cdot V_r} - 1 \right) \quad (2.3)$$

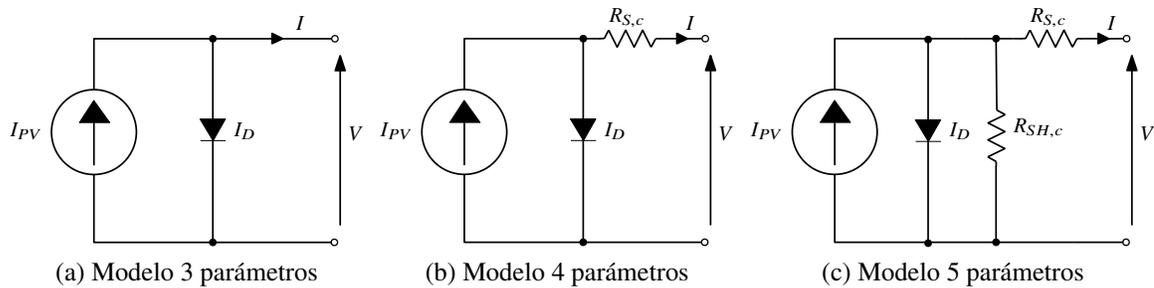


Figura 2.7: Circuitos equivalentes para modelación fotovoltaica

Para estimar los parámetros de los circuitos equivalentes existen diversos métodos numéricos. Mayor información se puede encontrar en [25–28].

Entre los **métodos estadísticos**, el más sencillo es el de persistencia, el cual asume que lo que acontecerá en el futuro es lo mismo que acontece en este momento. El ciclo solar dura 24 horas, y este método asume que el día siguiente será de la misma manera que el que acaba de pasar. Si bien este método es muy limitado, sigue siendo ampliamente utilizado como modelo base de comparación para evaluar el comportamiento de otro modelo más avanzado [19].

Al igual que en la predicción de variables meteorológicas, pueden usarse modelos ARIMA [29, 30] o modelos multivariados (SARIMAX, ARMAX) [31] para predecir potencia fotovoltaica utilizando datos pasados. Asimismo, métodos de inteligencia artificial han sido ampliamente utilizados para predecir potencia fotovoltaica. Entre los métodos más utilizados para predicción a corto plazo, se encuentran las redes neuronales artificiales [6].

Los **modelos híbridos** apuntan a tomar lo mejor de dos o más métodos y combinarlos para formar una buena predicción [32, 33].

2.2. Redes neuronales artificiales

2.2.1. Definición y propiedades

Las redes neuronales artificiales emulan a las biológicas, que tienen la capacidad de procesar información en paralelo, dada la gran cantidad de neuronas que participan en el proceso. También presentan una alta adaptabilidad al entorno, es decir, pueden aprender de la experiencia y generalizar a partir de situaciones particulares.

El elemento básico del sistema neuronal es la neurona, tipo de célula del sistema nervioso cuya principal función es la excitabilidad eléctrica de su membrana plasmática. Esta se compone a partir del cuerpo de la célula con un núcleo, dendritas que alimentan de señales externas al cuerpo y axones que transmiten la señal producida desde la neurona hacia otras.

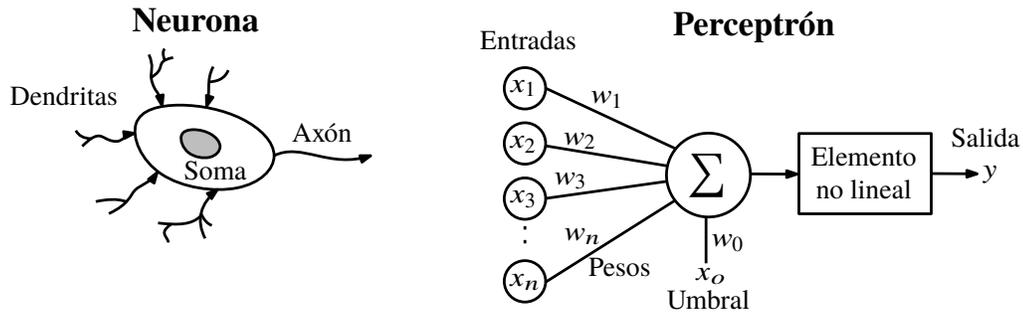


Figura 2.8: Representación simbólica de la neurona y perceptrón

Widrow y Hoff (1960) tomaron la idea básica de la neurona y crearon el perceptrón, que simula la neurona (Fig. 2.8). La configuración anteriormente mencionada se puede simular mediante: (1) el núcleo del elemento, llamado perceptrón, que contiene un sumador y un elemento posiblemente no lineal para procesar la señal; (2) las señales de entrada x_i , que están conectadas al núcleo mediante pesos ajustables w_i , y (3) señales de salida.

Rumelhart y McClelland (1986) refinaron la idea de Widrow y Hoff describiendo la i -ésima neurona artificial estándar, que consiste en:

- Un **conjunto de entradas** x_j y unos pesos sinápticos w_{ij} , con $j = 1, \dots, n$.
- Una **regla de propagación** h_i definida a partir del conjunto de entradas y los pesos sinápticos, es decir:

$$h_i(x_1, \dots, x_n, w_{i1}, \dots, w_{in})$$

La regla de propagación más comúnmente utilizada consiste en combinar linealmente entradas y pesos sinápticos, obteniendo:

$$h_i(x_1, \dots, x_n, w_{i1}, \dots, w_{in}) = \sum_{j=1}^n w_{ij} x_j$$

Suele ser habitual añadir al conjunto de pesos de la neurona un parámetro adicional θ_i denominado umbral, el cual se acostumbra a restar al potencial post-sináptico:

$$h_i(x_1, \dots, x_n, w_{i1}, \dots, w_{in}) = \sum_{j=1}^n w_{ij} x_j - \theta_i$$

- Una **función de activación**, que representa simultáneamente la salida de la neurona y su estado de activación. Si denotamos por y_i dicha función de activación, se tiene $y_i = f_i(h_i) = f_i(\sum_{j=1}^n w_{ij} x_j - \theta_i)$.

El perceptrón básicamente aprende mediante un proceso de entrenamiento, basado en un set de datos. Durante el entrenamiento, el perceptrón ajusta sus pesos de interconexión de acuerdo a los datos presentados como entrada. Para ajustar los pesos, Widrow y Hoff (1960) propusieron la regla delta que añade al valor actual del peso $w(k)$ un término compensacional $\eta\epsilon(k)x(k)$, para obtener el siguiente peso:

$$w(k + 1) = w(k) + \eta\epsilon(k)x(k)$$

Donde η es el término de proporcionalidad, $\epsilon(k)$ es el error en el paso de ajuste k , y $x(k)$ es el valor de la señal de entrada en el paso actual k .

Si bien la regla delta se puede considerar como simple, se ha demostrado una gran eficiencia y rapidez de convergencia en el entrenamiento. De todas formas, un solo perceptrón no puede aprender a solucionar problemas más complejos que los de separación lineal. Para solucionar lo anterior se crearon los perceptrones multicapa (Fig. 2.9) que, en adición a la capa de entrada y la de salida tiene las llamadas capas ocultas. Estas capas se incluyen entre las capas de entrada y salida, formando una red en cascada. En la práctica, una sola capa oculta es suficiente para construir una red con las capacidades computacionales para resolver la mayoría de los problemas prácticos [34].

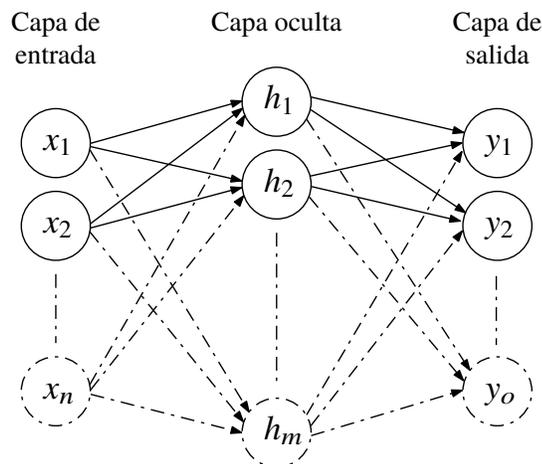


Figura 2.9: Representación de perceptrón multicapa, considerando una sola capa oculta y posibles n entradas, m neuronas en capa oculta y o salidas

2.2.2. Tipos de redes neuronales

2.2.2.1. Redes estáticas

La primera clase de redes se conoce como redes neuronales estáticas. En esta categoría recaen por ejemplo: la red multicapa de perceptrones, la red de funciones de base radial, la red neuronal probabilística, entre otras. La característica de estas redes es que no poseen memoria, es decir, simplemente transforman un conjunto de entradas en un conjunto de salidas, las cuales solamente

dependen de las entradas utilizadas. Este tipo de redes se ha empleado con éxito por ejemplo en problemas de clasificación, funciones lógicas y aproximación funcional.

2.2.2.2. Redes dinámicas

En las redes dinámicas, la salida depende no solamente de las entradas actuales de la red, sino que también puede depender de las entradas y salidas previas. Esto añade cierta memoria a estas redes.

Las redes dinámicas son generalmente más poderosas que las estáticas. Dado que estas series tienen memoria, estas pueden ser entrenadas para aprender patrones secuenciales o que dependan del tiempo. Las aplicaciones son amplias, y van desde predicción en mercados financieros, [35], identificación adaptativa para control y protecciones de sistemas de potencia, [36] y reconocimiento de voz [37] entre otros.

Para utilizar redes dinámicas, se requiere de un nuevo elemento: la línea de retardo (TDL: *tapped delay line*). La TDL se muestra en la figura 2.10. En este elemento, la señal pasa desde la izquierda, y se recoge la información hasta el *delay N*. Se obtiene un vector N-dimensional, compuesto de la señal en el tiempo actual y su información hasta un retardo de *N* pasos.

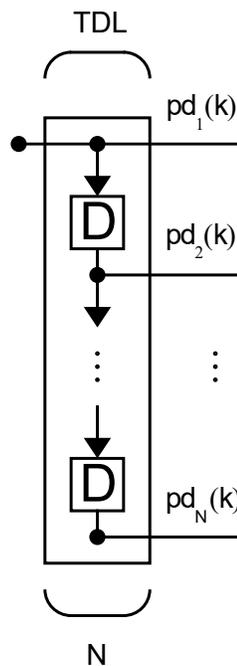


Figura 2.10: Línea de retardo [38]

Diferentes tipos de redes dinámicas han sido utilizadas con objeto de modelar sistemas dinámicos y predicción de series de tiempo. Las redes utilizadas se diferencian con respecto a la ubicación del TDL. En primera instancia se menciona la red dinámica más sencilla, la red con retardo enfocado (FTDNN), que consiste en en una red *feedforward* con una línea de retardo en la capa de entrada. Se

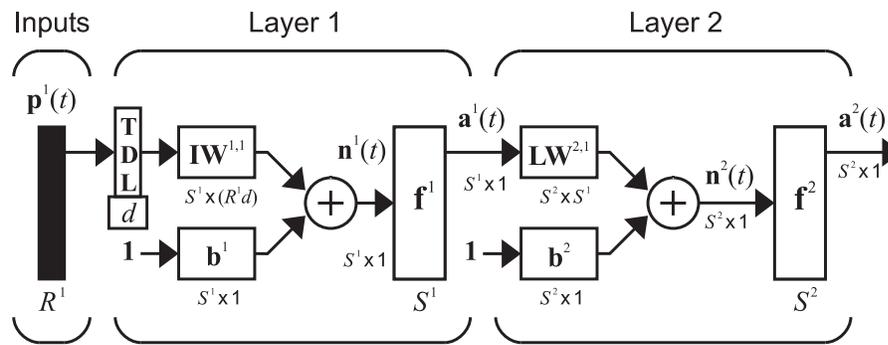


Figura 2.11: Red neuronal con retardo enfocado [38]

puede apreciar en la figura 2.11 un esquema de una red con dos capas, en la cual el TDL solamente afecta a las entradas.

En segundo caso, se puede aplicar el TDL a las distintas capas de la red neuronal, obteniendo una red con retardo distribuido (TDNN). La figura 2.12 muestra esta configuración, que fue en principio creada para identificación de fonemas [39].

Otra opción es aplicar el TDL tanto a la entrada como a la salida, creando la red no lineal auto regresiva con valores exógenos (NARX). Esta red dinámica y recurrente es de gran interés para modelación de sistemas dinámicos y predicción de series de tiempo, [40–45].

La ecuación que define una red NARX es:

$$\bar{y}(t + 1) = f(y(t), y(t - 1), \dots, y(t - n_s), u(t), \dots, u(t - n_i)) \quad (2.4)$$

Siendo el siguiente valor de la salida $\bar{y}(t)$ dependiente tanto del valor actual y previos de la misma como del valor actual y previos de una entrada exógena independiente $u(t)$. Se puede apreciar un esquema de una red NARX con dos capas en la figura 2.13.

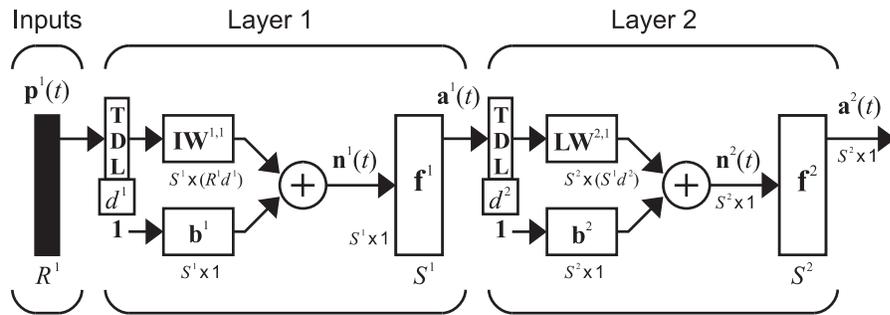


Figura 2.12: Red neuronal con retardo distribuido [38]

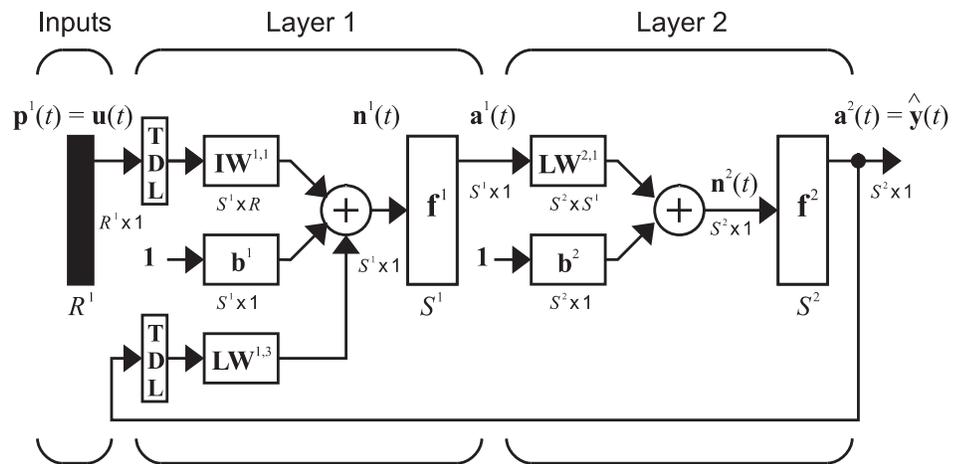


Figura 2.13: Esquema de una red NARX [38]

Para predecir con una red NARX se requiere previamente conocer las dos arquitecturas básicas que puede poseer: configuración Paralelo (Fig. 2.14a) y Serie Paralelo (Fig. 2.14b)

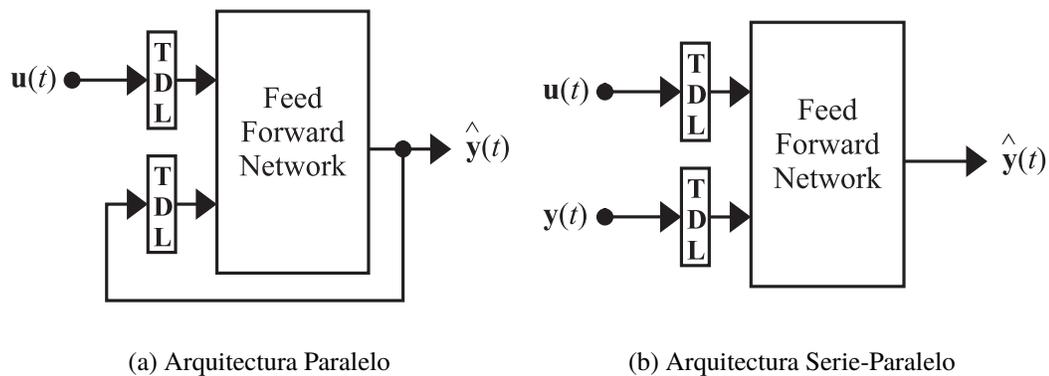


Figura 2.14: Arquitecturas redes NARX [38]

La arquitectura Serie-Paralelo se implementa para entrenar la red en ciclo abierto. Se utilizan como entradas la serie a predecir y las componentes exógenas que se deseen utilizar. Como *target* se utiliza la misma serie a predecir. Cuando el entrenamiento está completo se cierra el ciclo, pasando a la arquitectura Paralelo. Esta permite implementar la red creada utilizando nuevas entradas.

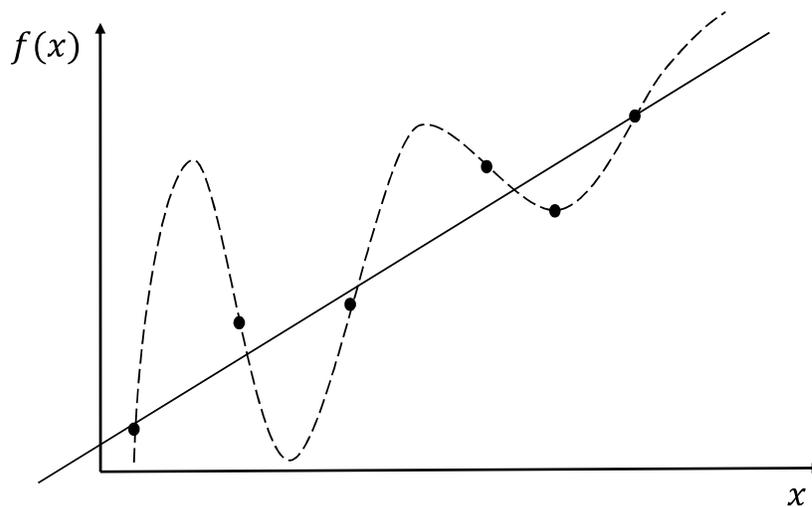
2.2.3. Escogiendo la configuración de red a utilizar

Para escoger una red, junto a sus parámetros, es importante en primera instancia tener una idea de lo que es el *overfitting*, y cómo evitarlo.

2.2.3.1. Evitando overfitting

El término *overfitting* es muy utilizado en inteligencia artificial, y consiste básicamente en utilizar un modelo tan complejo para ajustar los datos, que este no permite generalizar a un conjunto nuevo de datos.

Un ejemplo se muestra en la figura 2.15, donde se puede apreciar que dado un conjunto de datos, se tienen dos casos de ajuste de curvas. El primero, representado por la línea sólida corresponde a una regresión lineal, que si bien no captura todos los datos en el modelo, entiende cómo es el comportamiento general de la información. El segundo, representado por la línea punteada, representa un ajuste más complejo, que si bien puede captar todos los datos, podría ser que presente una generalización insuficiente cuando se introduzcan nuevos sets de entradas.

Figura 2.15: *Overfitting*

Para evitar el *overfitting* se intenta hacer una red que pueda generalizar los datos de la forma más simple posible. Una forma de simplificar la red es reduciendo el número total de neuronas, lo que variará la cantidad de pesos que las interconecten y, por ende, la complejidad de la red. Hasta ahora, no hay un método estándar para determinar la configuración óptima de una red neuronal. Se utiliza el método de "prueba y error" para determinar la red que pueda dar buenos resultados.

2.2.3.2. Número de neuronas en distintas capas de la red

Cada red neuronal tiene tres tipos de capas: entrada, oculta y de salida. Con respecto al número de neuronas en la capa de entrada, este se determina conociendo las variables que se relacionan de alguna u otra manera con la salida a escoger. No obstante, como se vio anteriormente, en caso de utilizar una red recurrente que ocupe líneas de retardo, el número de entradas aumenta conforme aumentan los *delays*, tanto en la entrada como en la salida retroalimentada. Lo anterior implica que hay que ser cuidadoso con escoger el retardo máximo a evaluar, porque introducirá más neuronas a la capa de entrada y, por ende, complejidad a la red en forma de pesos de interconexión a determinar.

Con respecto al número de neuronas en la capa oculta, para mejorar la generalización, este debiese ser uno mínimo tal que la red funcione de forma adecuada. Jeff Heaton, [46] menciona un método para escoger el tamaño óptimo de la capa oculta llamado "poda". Aquel método tiene dos variantes: 1) poda incremental, que iterativamente incrementa el número de neuronas en la capa oculta hasta que se obtiene un error menor al límite impuesto. 2) Poda selectiva: toma una red neuronal ya hecha y va quitando uno a uno neuronas en la capa oculta, cuidando que no se supere un cierto error límite impuesto.

El número de neuronas en la capa de salida es fijo y estará determinado principalmente por las variables que se quieren modelar.

2.2.4. Entrenamiento

Uno de los principales objetivos de las redes neuronales artificiales es emular la capacidad de aprendizaje que posee el ser humano, es decir, intenta ser una estructura flexible con capacidad de adaptación. Una vez que se escoge la topología de la red, el siguiente paso es entrenarla para que aprenda el comportamiento deseado, es decir, debiese ser capaz de dar una respuesta correcta a las entradas que se le presenten. El proceso de entrenar la red modifica los pesos de esta hasta llegar a la respuesta deseada.

Dependiendo del set de datos disponibles, hay mayormente dos tipos de creencias con respecto al entrenamiento de redes neuronales enfocadas a predicción. En primera instancia, se cree que si se tiene un set de datos grande, usualmente varios años, entonces las predicciones se harán de forma **determinista**. Lo anterior asume que cada factor necesario para determinar el estado siguiente de la variable a pronosticar está presente en los datos. Por otra parte, se piensa que al tener set de datos pequeños, se puede aprender el comportamiento local de la variable a predecir y se hace una predicción de forma **estocástica** [47].

El entrenamiento puede ser categorizado en dos tipos: aprendizaje supervisado y no supervisado.

2.2.4.1. Aprendizaje supervisado

En el aprendizaje supervisado se le presenta a la red una serie de vectores de entrada y salida. La red procesa el vector de entrada y la salida obtenida se compara con la salida deseada. Luego se modifican los pesos para hacer que las salidas sean lo más parecidas posible. Hay dos maneras de entrenar una red bajo aprendizaje supervisado [38]:

Incremental: En cada patrón mostrado a la red, se evalúa la salida que esta entrega y se compara con la salida deseada. Luego, se ajustan los pesos de las conexiones para minimizar el error entre la salida de la red y el valor deseado. Una vez hecho el ajuste, se pasa al siguiente patrón y así sucesivamente hasta que todos los pesos sinápticos se estabilicen en torno a valores óptimos.

Por lote: En este modo de entrenamiento, se le presenta al sistema un conjunto con todos los pares de entrada y salida a modelar. De este modo, todos los pesos de la red cambian en cada iteración hasta llegar a una red óptima.

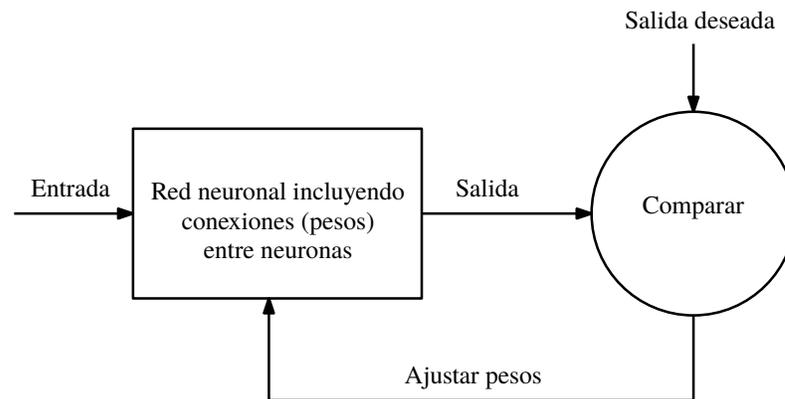


Figura 2.16: Esquema del entrenamiento de una red neuronal con aprendizaje supervisado

Para el entrenamiento de redes multicapa, usualmente se utiliza como función de rendimiento el error cuadrático medio entre la salida de la red y el conjunto de datos. Se puede utilizar cualquier método de optimización numérica [38] para optimizar la función de rendimiento. Dentro de los algoritmos utilizados comúnmente se encuentra el de Levenberg-Marquardt ((A.1) en anexos), que es una de las herramientas más populares para problemas de mínimos cuadrados no lineales. Debido a sus propiedades de rápida convergencia y estabilidad, este algoritmo se ha utilizado ampliamente en problemas de modelación.

2.2.4.2. Aprendizaje no supervisado

El aprendizaje no supervisado se caracteriza por no tener salidas deseadas a los datos de entrada. El objetivo de este aprendizaje es descubrir relaciones y estructuras entre los datos que se le presentan a la red, sin presentar algún criterio o ayuda externa que pueda ayudar a la clasificación.

Ejemplos de uso para redes con aprendizaje no supervisado incluyen entre otros la detección de anomalías en datos y aplicación de *clustering*, es decir, particionar datos en grupos cuando no hay categorías o clases disponibles.

2.3. Desempeño de una predicción

2.3.1. Estadísticos para evaluar desempeño

Según Jan Kleissl [48], las métricas convencionales para análisis de errores en predicciones solares se pueden categorizar según tres tipos: (1) sesgo, (2) varianza y (3) correlación. El sesgo caracteriza el balance entre sobre y subpredicción, y la medida de sesgo más utilizada es el *mean bias error* (MBE), definido como

$$MBE = \frac{1}{N} \sum_{t=1}^N (\hat{I}(t) - I(t)) \quad (2.5)$$

Donde $I(t)$ es la irradiancia medida en tiempo t , $\hat{I}(t)$ es la irradiancia pronosticada para el tiempo t y N es el número de datos en el set. Esta métrica otorga un valor de 0 en caso de tener un pronóstico perfecto y en caso de que los errores positivos y negativos se cancelen. Un valor grande de MBE implica un mayor sesgo en el pronóstico. Un valor positivo implicaría un sobrepronóstico general, mientras que uno negativo indica que se subpronostica. El entender el valor de MBE en general que entrega una herramienta de pronóstico puede ayudar a los operadores del sistema a utilizar mejor los recursos para compensar los errores de pronóstico en el proceso de despacho económico. De todas formas, solamente el MBE no da una buena indicación del rango total de errores de pronóstico.

Comúnmente, hay dos medidas para calcular la varianza de los errores de los pronósticos: el error cuadrático medio (RMSE) y el error medio absoluto (MAE). El valor RMSE está relacionado con la desviación estándar de los errores. Los dos valores calculan la esparción en los errores, y en el caso del error cuadrático medio, los castigos por diferencia entre datos son mayores. La expresión para el RMSE es

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (\hat{I}(t) - I(t))^2} \quad (2.6)$$

El MAE se calcula como

$$MAE = \frac{1}{N} \sum_{t=1}^N |\hat{I}(t) - I(t)| \quad (2.7)$$

Para evaluar la correlación entre la predicción y los valores reales, usualmente se calcula el coeficiente de determinación R^2 dado por

$$R^2 = 1 - \frac{\sigma^2(\hat{I} - I)}{\sigma^2(I)} \quad (2.8)$$

Donde σ es la varianza.

En [49] se propone un set de métricas para intentar estandarizar los pronósticos fotovoltaicos. Los desarrolladores de herramientas de predicción usualmente utilizan solo los estadísticos clásicos mencionados anteriormente. Los autores mencionan que estos no captan ni explican en su totalidad los errores y sus formas. También, se menciona que los estadísticos habituales no muestran los grandes errores que se producen y que afectan de mayor forma a los sistemas de potencia, por ende hay que agregar más estadísticos para entender mejor los errores generados.

Para penalizar los grandes errores y al mismo tiempo evaluar el error general, se agrega el error cuártico medio (RMQE), dado por:

$$RMQE = \left(\frac{1}{N} \sum_{t=1}^N (\hat{I}(t) - I(t))^4 \right)^{1/4} \quad (2.9)$$

Se pueden normalizar los errores RMSE y RMQE, dividiendo los valores obtenidos por la capacidad de la planta a analizar, obteniendo los errores RMSEn y RMQEn.

Otra herramienta es el error máximo absoluto, que sirve para evaluar el error más grande de pronóstico y se expresa como:

$$\text{MaxAE} = \max_{i=1,2,\dots,N} |\hat{I}_i - I_i| \quad (2.10)$$

El MaxAE es útil para evaluar el evento más extremo en la predicción. Un valor pequeño de MaxAE indica un mejor pronóstico. No obstante, esta métrica da mucho peso a un valor extremo, por lo que es más útil en predicciones en corto plazo.

Con respecto a los errores y su forma, para proveer de una visualización del rango total de estos y su variabilidad a largo plazo se puede esquematizar la distribución de errores, que entrega una representación gráfica que da cuenta de forma condensada el comportamiento de la herramienta de predicción. En conjunto con la distribución de los errores de pronóstico, el análisis de asimetría y curtosis provee información adicional para evaluar los pronósticos. Distintos tipos de distribuciones han sido analizadas en la literatura para cuantificar los errores de predicción de potencia solar (o eólica) incluyendo la distribución hiperbólica, la estimación por densidad de kernel (KDE: Kernel Density Estimation), la distribución normal, la Weibull y la beta [49].

Capítulo 3

Datos y método propuesto

3.1. Conjunto de datos

Una estación meteorológica fue utilizada para obtener los datos de: radiación global en plano horizontal (GHI), temperatura ambiente (T_a), humedad relativa (HR) y la hora (hr). La estación está localizada en Cerro Navia, Santiago. Las figuras 3.1a y 3.1b muestran los dispositivos CS300 (Radiación global en plano horizontal) y HMP60 (temperatura ambiente y humedad relativa). Los datos técnicos de la estación se muestran en la tabla 3.1.

Junto a la estación, se tiene un sistema fotovoltaico residencial de 1.4kW instalados. Se mide la potencia de salida en AC (W) del conjunto.

El conjunto de datos original consiste en mediciones para cada minuto de las variables mencionadas durante el año 2015. Para este trabajo se filtraron los datos¹ con objeto de obtener los valores instantáneos para cada hora del año.

Variable	Dispositivo	Rango de medida	Error	Rango Operacional
Radiación Global	CS300	0 a 1,75 kW/m ²	5 %	-40 a 70°C
Humedad Relativa	HMP60	0 a 100	3 %	-40 a 60°C
Temperatura del aire	HMP60	-40 a 60	3 %	-40 a 60°C

Tabla 3.1: Datos técnicos estación de medición

¹El código de filtrado de datos se encuentra en el apéndice.

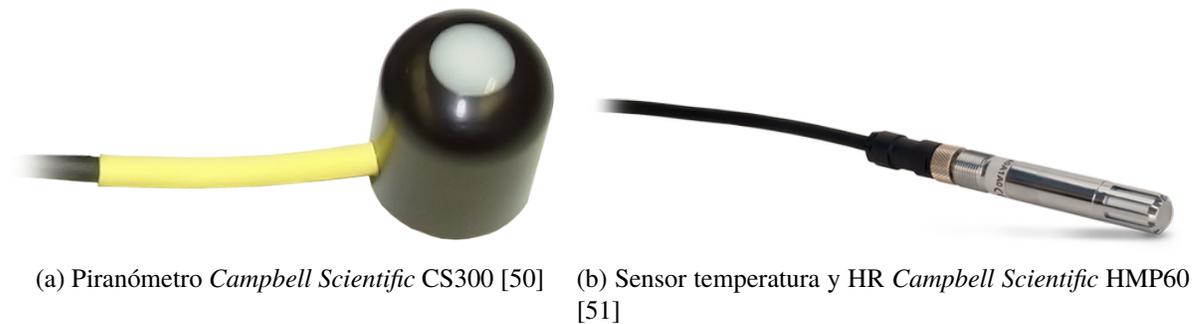


Figura 3.1: Estación de medición

3.2. Método propuesto

Para predecir la potencia fotovoltaica, se separará el problema en dos partes: primero se pronosticarán las variables meteorológicas y luego estas se utilizarán para predecir la potencia fotovoltaica de salida.

Con objeto de probar la herramienta de predicción en distintas condiciones, esta se utilizará en dos temporadas: verano e invierno. Esto para pronosticar las variables tanto en días con cielo despejado como en días donde, debido a la nubosidad, hayan cambios bruscos en la irradiancia y por ende, en la potencia de salida. Para cada condición, se pronosticarán cinco días seguidos y se calcularán estadísticos con objeto de evaluar el error tanto para cada día como durante todo el período a predecir.

3.2.1. Predicción de variables meteorológicas

El objetivo es tener una herramienta de predicción del día siguiente sencilla de implementar y utilizar, por ende se utilizarán redes neuronales artificiales. La gran ventaja de estas es que solamente requiere de introducir los datos, dado que el entrenamiento y evaluación de la mejor configuración puede ser automatizado. Producto de su gran capacidad de predicción, en específico se utilizarán redes NARX. El software a utilizar será MATLAB, dado su paquete de redes neuronales artificiales incorporado.

El objetivo final es pronosticar la temperatura ambiente y la irradiancia, dado que son las dos variables meteorológicas que afectan mayormente la potencia de una planta fotovoltaica. Como entradas exógenas para la RNA de la irradiancia se utilizarán: la humedad relativa, la temperatura ambiente y la hora del día. Para evaluar la capacidad de las RNA se utilizarán dos tipos de pronósticos:

- **Predicción con componentes exógenas conocidas:** se pronosticará la irradiancia utilizando valores de temperatura y humedad relativa del día siguiente conocidos, emulando una predicción perfecta de estas variables exógenas.

- Predicción total:** las componentes exógenas de temperatura y humedad relativa serán pronosticadas mediante RNA, utilizando la hora del día como entrada a estas.

La figura 3.2 muestra el esquema a utilizar para la predicción total.

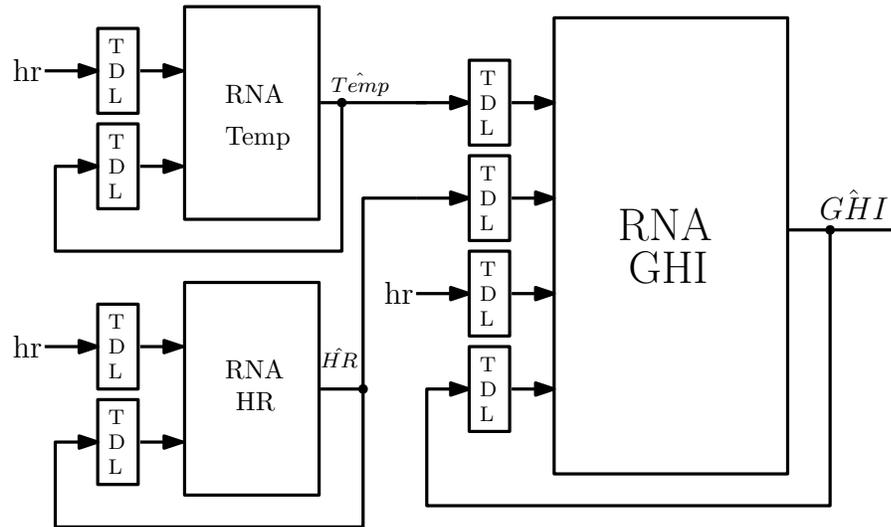


Figura 3.2: Esquema de predicción de la radiación utilizando redes NARX

Producto de poseer solamente un año de datos es que no se pueden hacer predicciones del tipo deterministas. El enfoque entonces será el de hacer predicciones estocásticas, y para eso se requiere un conjunto menor de datos que tengan comportamientos similares. Dado que las distintas variables meteorológicas difieren en cuanto al comportamiento diario, es que se tienen distintas opciones para escoger los datos. Al no existir un método para escoger la cantidad de datos, se hará mediante prueba y error. Se configurarán redes con distintos números de días anteriores (X_d) y finalmente se evaluará la cantidad de días que mejor pueda generalizar los datos.

Para escoger la red que generalice de mejor forma los datos se dividirán los días anteriores escogidos entre un conjunto de entrenamiento y otro de ajuste. Se entrenarán distintas configuraciones de RNA utilizando la información de los primeros ($X_d - 3$) días y se probarán con los datos de los últimos 3 días, escogiendo finalmente la red que presente un menor error cuadrático medio en la prueba. El esquema de entrenamiento, ajuste y predicción de las redes se muestra en la figura 3.3.

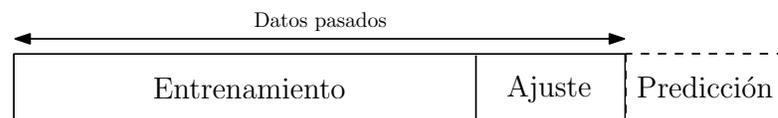


Figura 3.3: División de datos pasados para entrenar las RNA y ajustar su respuesta

Las distintas configuraciones de RNA serán creadas variando parámetros que estén directamente relacionados con el número de neuronas de las distintas capas del sistema. Al ser redes NARX

serán variados los *delays* de las entradas y salidas, así como el número de neuronas en capa oculta. El proceso será variar desde uno hasta un valor máximo esas tres variables, obteniendo un arreglo tridimensional de redes neuronales a elegir. La cantidad de neuronas máxima en la capa oculta, al igual que los *delays* máximos para la entrada y la salida, serán determinados mediante prueba y error para cada variable, prediciendo distintos días con distintos valores y finalmente escogiendo el valor que mejor se adecue a los valores reales.

Dado que se requiere rapidez en la convergencia producto de analizar un gran conjunto de redes neuronales, se escogerá el algoritmo de Levenberg-Marquardt para minimizar el error cuadrático medio como función de rendimiento de las redes a crear.

Para analizar el error de predicción de variables meteorológicas se utilizará el error cuadrático medio, el error cuártico medio, el coeficiente de determinación, el MAE, el MBE y el error máximo (MaxAE). Las métricas serán mostradas como en la tabla 3.2.

Estadístico	día 1	día 2	día 3	día 4	día 5
RMSE					
RMQE					
R^2					
MAE					
MBE					
MaxAE					

Tabla 3.2: Estadísticos para evaluar predicción de variables meteorológicas

3.2.2. Predicción de potencia fotovoltaica

Para hacer pronósticos fotovoltaicos lo usual es disponer de la radiación en el plano del panel o calcularla mediante otras variables. En este caso se posee solamente de la radiación global en plano horizontal, y no se encuentra algún estudio en Chile en el cual se relacione de alguna manera esta radiación con una en un cierto plano inclinado.

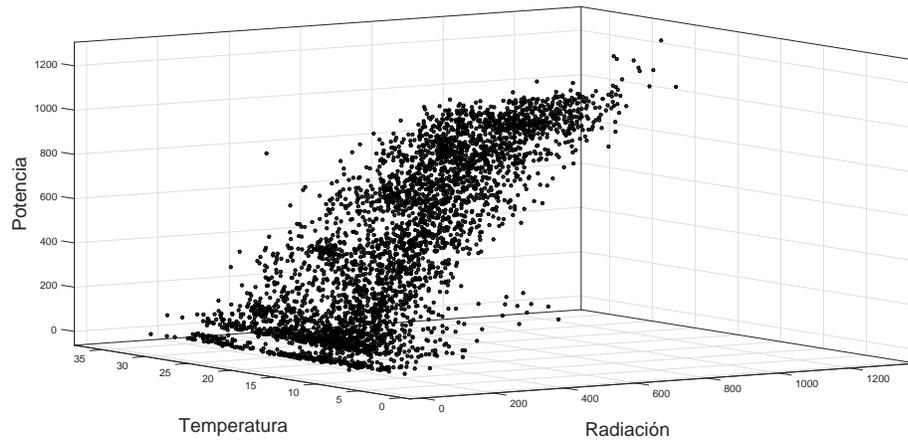


Figura 3.4: Gráfico de potencia en función de la temperatura y radiación global en plano horizontal

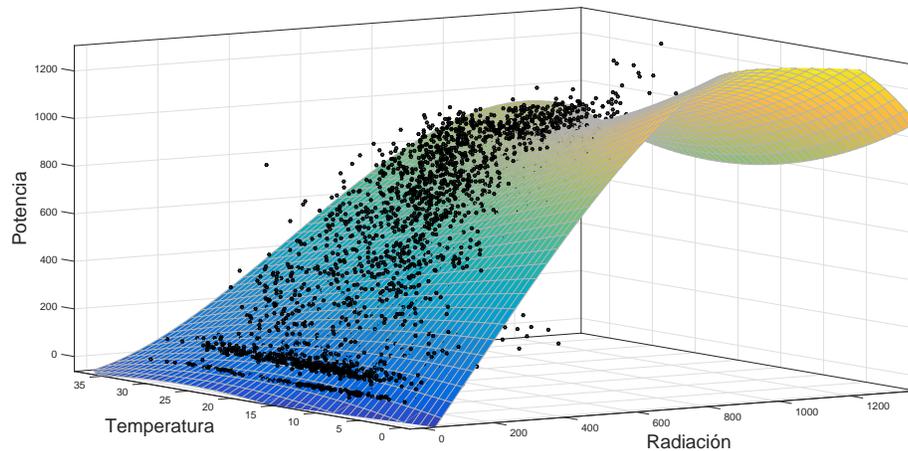


Figura 3.5: Aproximación de la potencia mediante polinomios

De todas maneras, al saber que la irradiancia y temperatura ambiente son los factores que más afectan a la potencia fotovoltaica, se grafican los datos de todo el año (Fig. 3.4). El gráfico a simple vista se asemeja a una superficie, por lo que se modelará la potencia mediante aproximación polinomial. Probando con distintos grados en las variables de radiación y temperatura, se obtiene una mejor modelación en términos de error y correlación utilizando un orden de 2 y 3 respectivamente (Fig. 3.5).

Para evaluar la capacidad del modelamiento de la potencia mediante aproximación polinomial, se prueba en dos condiciones: días despejados y nublados. Para ajustar el polinomio aproximador, en cada día a aproximar se utilizan datos de los últimos 60 días, con objeto de captar las variaciones

y condiciones locales. Se prueba la aproximación de forma previa utilizando 3 días para cada condición. Los días escogidos para probar la aproximación en días despejados son desde el 02-01-2015 hasta el 27-02-2015 para el primer día, obteniendo un R^2 de 0,9705 y un error RMSE de 55,6 W. Para la prueba en días nublados se aproxima la superficie correspondiente a los datos desde el 01-07-2015 hasta el 26-08-2015 para el primer día, obteniendo un R^2 de 0,9455 y un error RMSE de 64,36 W. Las figuras 3.6 y 3.7 muestran el resultado de las pruebas de forma gráfica, pronosticando tanto los días 28, 29 y 30 de febrero como 27, 28 y 29 de agosto. La tabla 3.3 muestra estadísticos para evaluar la capacidad de modelamiento del método escogido.

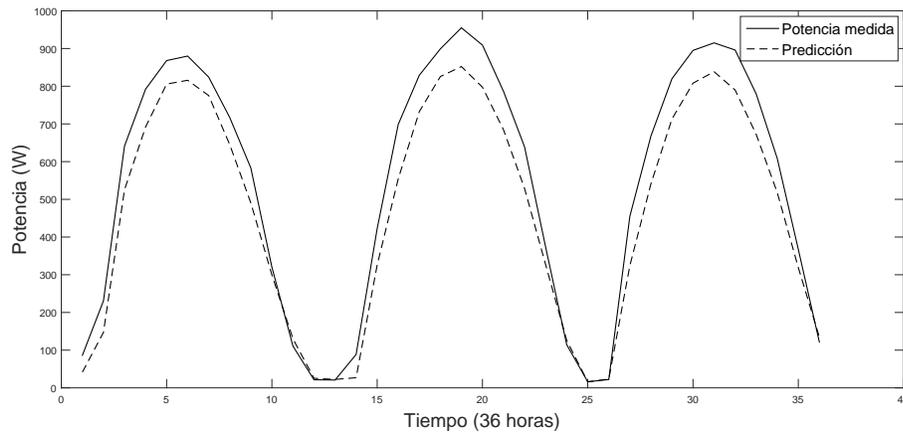


Figura 3.6: Aproximación de la potencia mediante polinomios en verano

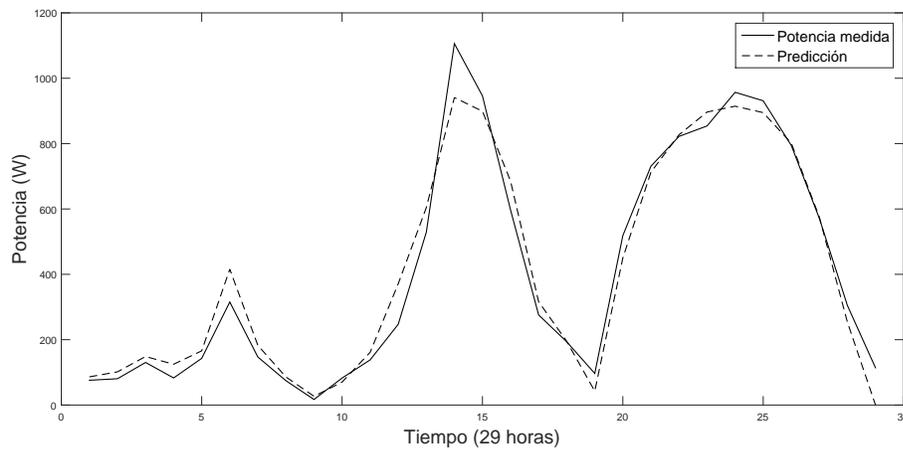


Figura 3.7: Aproximación de la potencia mediante polinomios en invierno

Estadístico	Verano	Invierno
RMSE (W)	82,596	59,874
RMQE (W)	93,57	83,386
RMSEn	0,058997	0,042767
RMQEn	0,066836	0,059561
R ²	0,98892	0,96948
MAE (W)	71,733	44,553
MBE (W)	-68,903	2,544
MaxAE (W)	144,46	165,14

Tabla 3.3: Errores en predicción mediante aproximación polinomial

La forma que adopta la predicción es prometedora, lo cual se corrobora con los valores del coeficiente de determinación (R^2), mostrando una buena correlación entre los datos, superior a 0,96 en ambos casos. Los errores RMSE y RMQE son ligeramente mayores en el caso de verano, lo cual se esperaba según los gráficos, pero de todas formas corresponden a aproximadamente un 6 % de la planta en ambos casos, según los valores normalizados. Se nota una subpredicción en general del modelo, afectando mayormente a los valores del verano, obteniendo un MBE de -68,903 W. Para el caso de invierno se alcanza un valor de 2,544 W, lo cual es bastante aceptable. Si bien el error máximo en ambos casos ronda los 150 W, y considerando que la radiación es la global horizontal, el comportamiento en general del modelamiento utilizando polinomios interpolantes es aceptable, por lo que será utilizado en este trabajo.

Para probar el poder de modelación de las redes neuronales artificiales, estas también serán utilizadas para pronosticar la potencia fotovoltaica. Las características serán similares a las utilizadas para predecir las variables meteorológicas. Las entradas hacia la red de potencia serán: la radiación global en plano horizontal, temperatura ambiente, humedad relativa y hora del día.

Con respecto a los errores, al igual que las variables meteorológicas se calcularán el error cuadrático medio, el error cuártico medio, el coeficiente de correlación lineal, el MAE, el MBE y el error máximo (MaxAE). También, y según las métricas propuestas por el departamento de energía de los Estados Unidos, se agregará el análisis de la distribución de errores y se utilizarán medidas de forma como el coeficiente de asimetría y curtosis. Dado que Matlab lo incluye como función, la distribución de errores de potencia fotovoltaica será estimada utilizando el método KDE. Con objeto de tener una visión general del desempeño de las herramientas de predicción, se utilizarán los datos de todos los días pronosticados dentro de cada estadístico para obtener estadísticos totales acumulados. Para resumir los estadísticos se utilizará la tabla 3.4.

Estadístico	día 1	día 2	día 3	día 4	día 5	Total acumulado
RMSE (W)						
RMQE (W)						
RMSEn						
RMQEn						
R^2						
MAE (W)						
MBE (W)						
MaxAE (W)						
Asimetría	-	-	-	-	-	
Curtosis	-	-	-	-	-	

Tabla 3.4: Estadísticos para evaluar predicción de potencia fotovoltaica

Capítulo 4

Predicción de variables meteorológicas

Para la predicción de variables meteorológicas, y con objeto de probar el poder predictivo de las RNA, en primera instancia se crearán redes para pronosticar la radiación utilizando datos reales futuros de las entradas: hora, temperatura y humedad relativa. Luego, se crearán redes que pronostiquen estas variables exógenas, para luego ser utilizadas como entradas hacia las redes que pronostiquen la radiación, obteniendo una predicción puramente a base de redes neuronales. La figura 4.1 resume el procedimiento a utilizar.

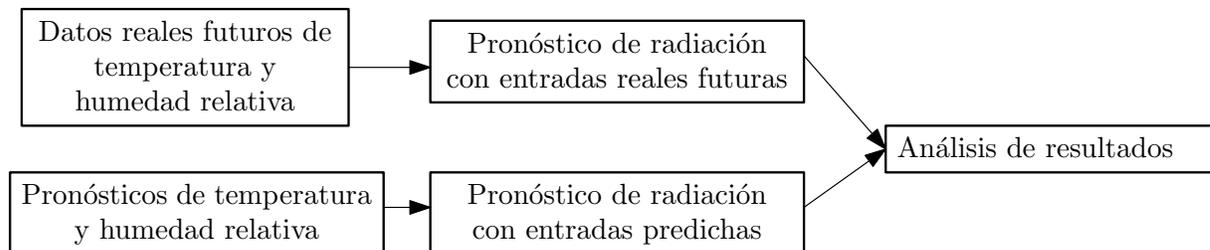


Figura 4.1: Procedimiento a utilizar para predicción y análisis de variables meteorológicas

4.1. Configuración de las redes neuronales

Previamente, se escogen la cantidad de días utilizados para entrenar las redes, el número máximo de *delays* de entrada y salida, como así también el número máximo de neuronas en capa oculta a considerar. Pruebas previas pronosticando distintos días del año entregan que se obtiene una buena generalización con los valores que resume la tabla 4.1. La experiencia muestra que el utilizar límites más grandes hace que las redes tiendan a sobreajustar los valores en la fase de calibración, lo que impide una buena generalización en las predicciones.

	Días pasados	$d_{entrada}$	d_{salida}	H
Radiación	100	8	8	15
Temperatura	50	8	8	10
Humedad Relativa	50	8	8	10

Tabla 4.1: Valores máximos a considerar para la búsqueda de redes neuronales para predicción de variables meteorológicas

4.2. Días despejados

Para probar la capacidad de predicción en días despejados se pronosticará desde el 23 al 27 de abril del 2015.

4.2.1. Radiación global horizontal con datos reales de entradas futuras

Al pronosticar cinco días seguidos, el algoritmo debe escoger cada día distintas redes neuronales. El resultado de la búsqueda arroja las configuraciones que se muestran en la tabla 4.2. La figura 4.2 muestra la predicción para los 5 días¹ de forma gráfica, junto al valor real de la radiación y los errores que se cometen. La tabla 4.3 muestra los estadísticos para evaluar las predicciones de cada día.

	día 1	día 2	día 3	día 4	día 5
d_{input}	4	1	1	3	1
d_{output}	4	4	2	7	8
H	15	3	4	9	11

Tabla 4.2: Configuración de redes para pronosticar la radiación en días despejados. 23-04 hasta 27-04 del 2015

¹La calibración de estas y todas las redes neuronales escogidas por el algoritmo durante el trabajo se pueden ver en el apéndice, junto a los códigos utilizados.

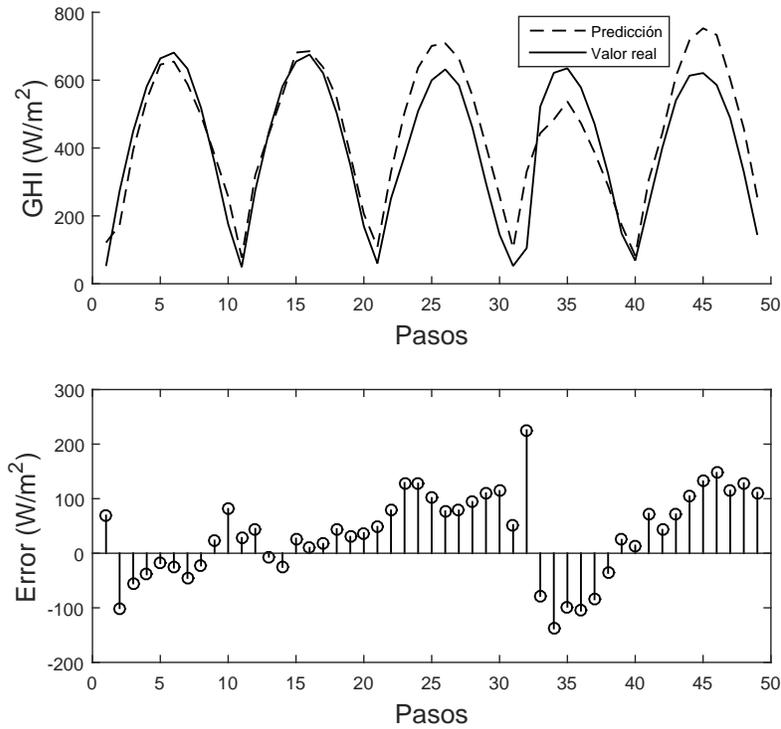


Figura 4.2: Predicción de radiación utilizando entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5
RMSE (W/m^2)	54,92	29,67	98,80	109,7	102,0
RMQE (W/m^2)	65,64	33,21	103,7	137,9	111,4
R^2	0,9407	0,9905	0,9851	0,8437	0,9757
MAE (W/m^2)	48,03	26,96	95,77	93,48	93,73
MBE (W/m^2)	-13,31	20,68	95,77	-26,41	93,73
MaxAE (W/m^2)	100,6	44,76	128,8	225,4	147,3

Tabla 4.3: Estadísticos para evaluar predicción de radiación utilizando entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015

4.2.2. Temperatura

Para la predicción de temperatura, entrada exógena de la radiación, se crean redes con las características mostradas en la tabla 4.4. La figura 4.3 muestra la predicción junto a los valores reales de los días predichos. La tabla 4.5 muestra los estadísticos para evaluar las predicciones.

	día 1	día 2	día 3	día 4	día 5
d_{input}	2	1	1	5	4
d_{output}	5	4	2	7	3
H	10	10	5	7	7

Tabla 4.4: Configuración de redes para pronosticar la temperatura en días despejados. 23-04 hasta 27-04 del 2015

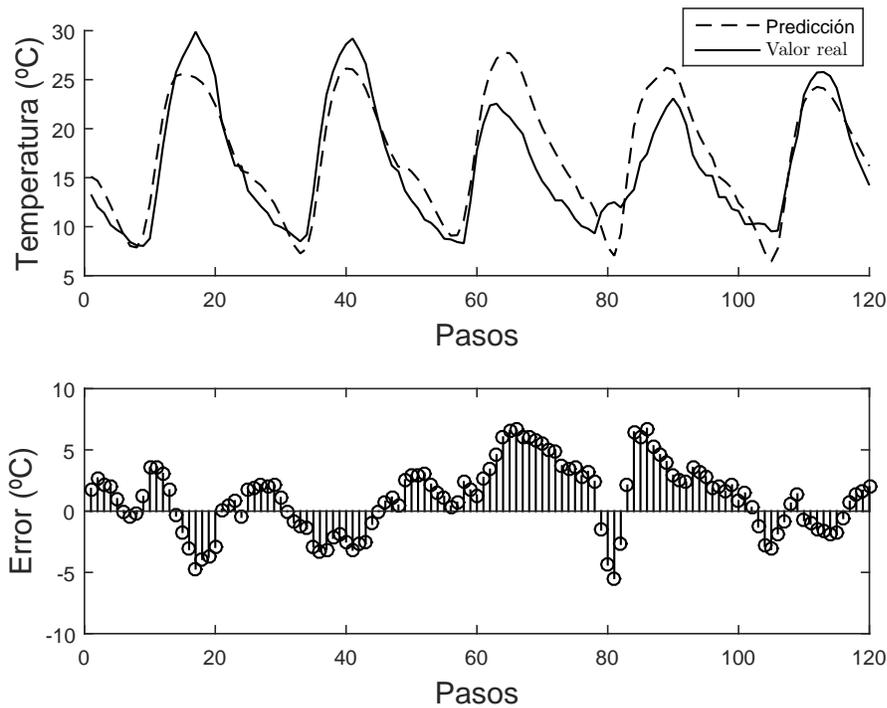


Figura 4.3: Predicción de temperatura en días despejados. 23-04 hasta 27-04 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5
RMSE (°C)	2,350	1,995	4,087	3,914	1,610
RMQE (°C)	2,858	2,272	4,726	4,408	1,860
R^2	0,9308	0,9431	0,9451	0,7752	0,9237
MAE (°C)	1,904	1,759	3,579	3,648	1,459
MBE (°C)	0,1029	-0,6494	3,579	2,480	-0,1187
MaxAE (°C)	4,684	3,280	6,661	6,726	3,091

Tabla 4.5: Estadísticos para evaluar predicción de temperatura utilizando entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015

4.2.3. Humedad relativa

Con respecto a la humedad relativa, también entrada exógena para la red neuronal de la radiación, se crean redes con las características mostradas en la tabla 4.6. La figura 4.4 muestra de forma gráfica la predicción junto a los valores reales de los días predichos. La tabla 4.7 resume los estadísticos para evaluación del pronóstico.

	día 1	día 2	día 3	día 4	día 5
d_{input}	2	5	7	2	8
d_{output}	3	3	3	2	2
H	10	10	9	7	5

Tabla 4.6: Configuración de redes para pronosticar la humedad relativa en días despejados. 23-04 hasta 27-04 del 2015

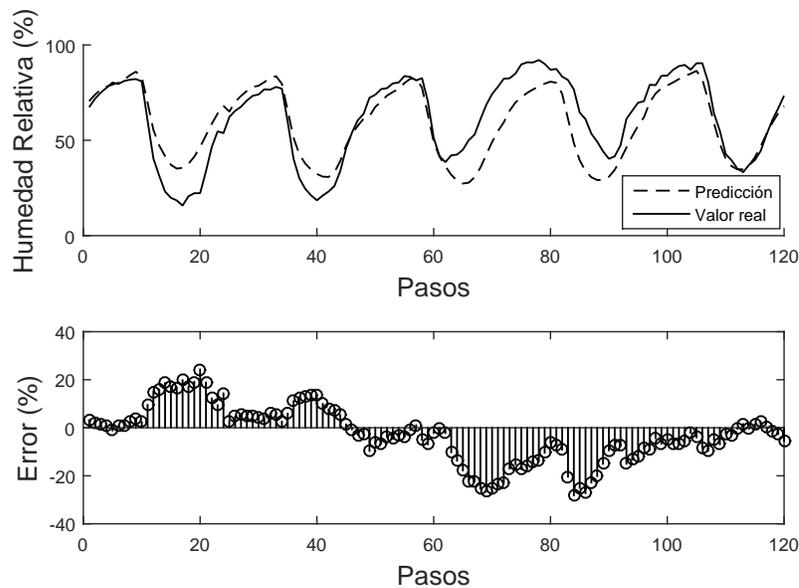


Figura 4.4: Predicción de humedad relativa utilizando entradas reales futuras en días despejados. 17-07 hasta 21-07 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5
RMSE (%)	12,86	7,468	14,36	16,18	5,072
RMQE (%)	15,33	9,103	17,98	18,37	6,097
R^2	0,9828	0,9644	0,7713	0,8867	0,9842
MAE (%)	10,27	6,379	11,07	14,91	4,241
MBE (%)	10,18	5,871	-10,98	-14,91	-3,767
MaxAE (%)	24,28	13,83	26,17	28,12	9,597

Tabla 4.7: Estadísticos para evaluar predicción de humedad relativa utilizando entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015

4.2.4. Radiación global horizontal en base a predicciones

Una vez que se tienen pronosticadas las componentes exógenas de temperatura y humedad relativa, se utilizan como entradas hacia las redes neuronales de radiación global horizontal descritas en la tabla 4.2, con objeto de hacer una predicción con datos predichos. Los resultados obtenidos se pueden apreciar en la figura 4.5, mientras que los estadísticos se muestran en la tabla 4.8.

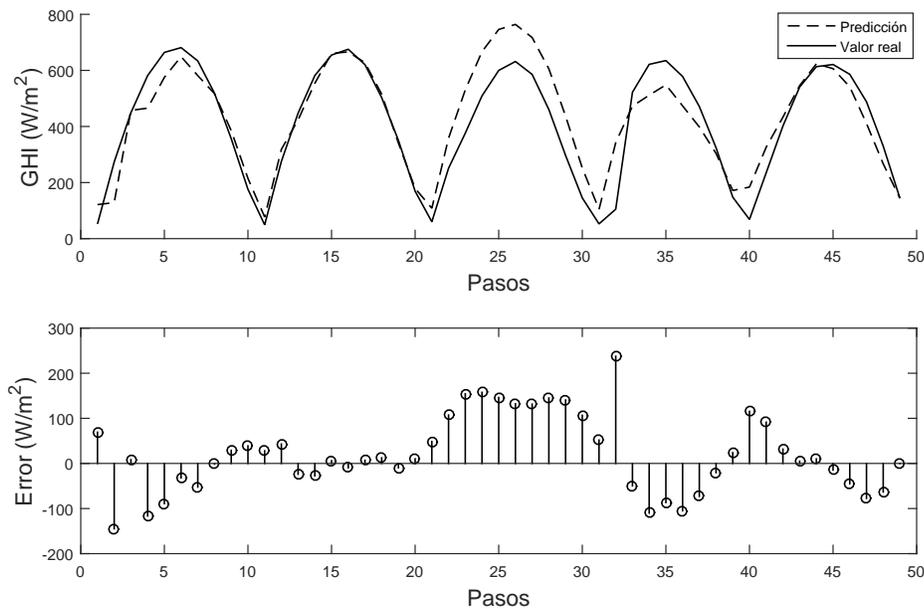


Figura 4.5: Predicción de radiación utilizando entradas predichas en días despejados. 23-04 hasta 27-04 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5
RMSE (W/m ²)	73,09	21,2	130,7	104,6	59,19
RMQE (W/m ²)	92,14	26,58	135,3	140,9	74,27
R ²	0,8992	0,9917	0,9903	0,8409	0,9137
MAE (W/m ²)	58,16	17,72	127,0	84,18	45,37
MBE (W/m ²)	-29,11	3,589	127,0	-14,61	5,306
MaxAE (W/m ²)	144,8	42,99	157,6	237,5	115,4

Tabla 4.8: Estadísticos para evaluar predicción de radiación utilizando entradas predichas en días despejados. 23-04 hasta 27-04 del 2015

4.2.5. Análisis de predicción de variables meteorológicas para días despejados

Las configuraciones de las redes utilizadas para pronosticar la radiación, temperatura y humedad relativa mostradas en las tablas 4.2, 4.4 y 4.6 respectivamente muestran que en general se tienen valores de neuronas en capa oculta relativamente altos para la calibración de días más complicados en cuanto a variaciones en los datos. Lo anterior se puede apreciar, por ejemplo, en la predicción del 23 de abril para la radiación, donde el número de neuronas en la capa oculta alcanza su máximo de 15 debido a la complejidad de los tres días anteriores utilizados para calibrar, mostrados en la figura A.1 de los anexos.

Para probar el poder predictivo de las redes neuronales artificiales se pronostica la radiación solar desde el 23 al 27 de abril utilizando entradas exógenas conocidas, es decir, los valores reales de la temperatura y humedad relativas de aquellos días. Los resultados de la predicción, mostrados gráficamente en la figura 4.2 junto a los estadísticos de la tabla 4.3, evidencian que las predicciones son similares en comparación a los datos reales. Se obtienen valores relativamente altos de R², variables entre 0,8437 para el cuarto día y 0,9905 para el segundo. Se muestra también que los errores, considerando los valores de MAE, RMSE y RMQE corresponden con lo mostrado en la gráfica, es decir, se tiene un menor error general en el segundo día, mientras que el cuarto día es el que presenta mayores errores. Lo anterior se repite para el caso del error máximo, que en el día 2 alcanza un valor de 44,76 W/m², mientras que en el cuarto día llega a un valor de 225,4 W/m². Los valores de MBE varían entre -26,41 W/m² para el cuarto día, evidenciando una subpredicción general, y 95,77 W/m² para el tercer día, representando una sobrepredicción.

En el caso de la temperatura y humedad relativa, al tener solamente la hora como entrada exógena, se podría esperar una respuesta que se ajuste más que todo a la tendencia de la serie de tiempo, siendo incapaz de predecir cambios bruscos. Tomando en cuenta los gráficos de las calibraciones mostradas en el anexo (figuras A.6 a A.15), se da cuenta de la tendencia pronosticada.

Considerando las predicciones de temperatura, se obtienen buenos valores de R², variando entre 0,775 y 0,945. No obstante, los errores son en su mayoría grandes. Si bien las temperaturas varían en torno a los 10°C y 30°C, se obtienen errores máximos variando entre 4,684°C y 6,726°C. Observando

los valores de MAE, RMSE y RMQE, se ve que los errores que mayormente predominan son los grandes, debido a que el castigo que se aplica conforme se aumenta el exponente hace que los errores aumenten considerablemente. El día con la mejor predicción es el segundo, en términos del error RMSE y RMQE, pero también es el día que más se acomoda a la tendencia de los valores.

Con respecto a la humedad relativa, esta presenta un comportamiento similar en cuanto a la temperatura. Si bien también se obtienen valores relativamente altos de R^2 , las predicciones poseen grandes errores. En términos de los errores MAE, RMSE y RMQE, también se nota que los errores que predominan son los grandes, dado el castigo que se tiene mientras sube el exponente del error. El mayor MaxAE corresponde al cuarto día, con un valor de 28,12 %. Considerando la humedad relativa variable entre 18,54 % y 90,4 %, un error de ese calibre se puede considerar como importante. Del valor de MBE no se puede extraer alguna tendencia hacia una sub o sobrepredicción del modelo.

Utilizando los valores de temperatura y humedad relativa predichos como entradas a las redes neuronales creadas para la predicción de radiación se obtienen las predicciones mostradas en la figura 4.5. Si bien los pronósticos de las variables exógenas poseen errores relativos importantes, la gráfica muestra en general una buena predicción. Los valores de R^2 son altos, variando desde 0,8409 para el cuarto día hasta 0,9917 para el segundo. Si bien el segundo día corresponde al de la mejor predicción, alcanzando el mínimo en todos los estadísticos, exceptuando R^2 , en contraparte se tiene el tercer día, que si bien alcanza a tener un valor de 0,99 en cuanto al coeficiente de determinación, posee los mayores errores en términos de MAE, RMSE y RMQE. El mayor error lo posee el día 4, alcanzando 237,5 W/m².

4.3. Días nublados

4.3.1. Radiación global horizontal con datos reales de entradas futuras

Nuevamente, se entrenan redes neuronales para predicción de radiación durante cinco días seguidos. La tabla 4.9 resume las configuraciones elegidas, mientras que los resultados de las predicciones se muestran en la figura 4.6. La tabla 4.10 resume los estadísticos que caracterizan la predicción.

	día 1	día 2	día 3	día 4	día 5
d_{input}	7	3	2	7	1
d_{output}	7	6	6	3	4
H	13	14	12	10	12

Tabla 4.9: Configuración de redes para pronosticar la radiación en días nublados. 17-07 hasta 21-07 del 2015

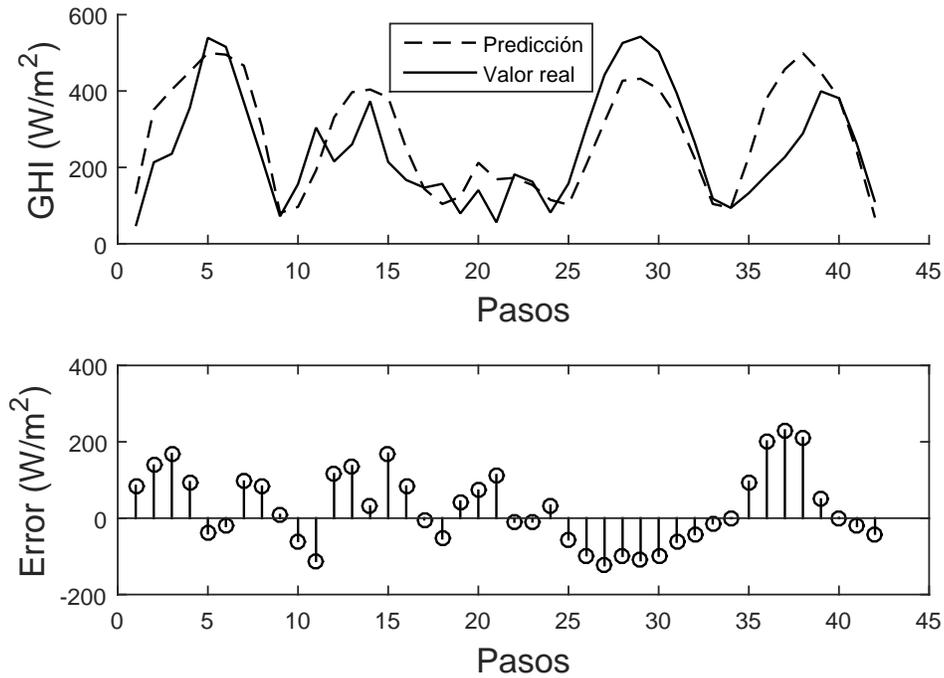


Figura 4.6: Predicción de radiación utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5
RMSE (W/m ²)	95,14	98,43	59,28	84,94	129,5
RMQE (W/m ²)	112,2	114,8	75,42	93,29	163,8
R ²	0,8377	0,4046	0,2094	0,9753	0,5464
MAE (W/m ²)	81,38	84,69	46,54	77,76	94,15
MBE (W/m ²)	68,02	34,13	40,66	-77,76	80,57
MaxAE (W/m ²)	168,0	169,1	112,9	123,3	229,9

Tabla 4.10: Estadísticos para evaluar predicción de radiación utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

4.3.2. Temperatura

La predicción de la temperatura se hace mediante las configuraciones de las RNA mostradas en la tabla 4.11. Los resultados de la predicción se muestran en la tabla 4.7 mientras que los estadísticos asociados se resumen en la tabla 4.12.

	día 1	día 2	día 3	día 4	día 5
d_{input}	6	7	5	4	3
d_{output}	7	5	2	1	1
H	10	5	10	4	6

Tabla 4.11: Configuración de redes para pronosticar la temperatura en días nublados. 17-07 hasta 21-07 del 2015

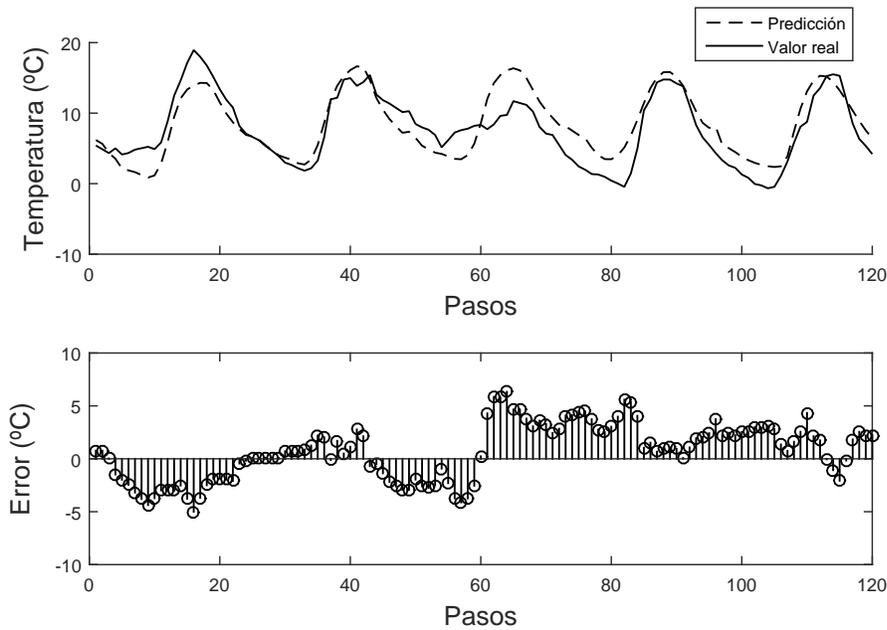


Figura 4.7: Predicción de temperatura utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5
RMSE (°C)	2,727	1,477	3,661	3,159	2,300
RMQE (°C)	3,134	1,850	4,108	3,672	2,563
R^2	0,9083	0,9078	0,5021	0,9624	0,9468
MAE (°C)	2,392	1,146	3,373	2,742	2,103
MBE (°C)	-2,261	0,280	0,8630	2,742	1,823
MaxAE (°C)	5,006	2,928	6,329	5,585	4,331

Tabla 4.12: Estadísticos para evaluar predicción de temperatura utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

4.3.3. Humedad relativa

La humedad relativa en días nublados se predice mediante las configuraciones de RNA caracterizadas en la tabla 4.13. La predicción durante los cinco días se muestra en la figura 4.8 mientras que los estadísticos para evaluarla se presentan en la tabla 4.14.

	día 1	día 2	día 3	día 4	día 5
d_{input}	6	2	7	2	1
d_{output}	3	3	3	4	5
H	8	10	10	4	5

Tabla 4.13: Configuración de redes para pronosticar la humedad relativa en días nublados. 17-07 hasta 21-07 del 2015

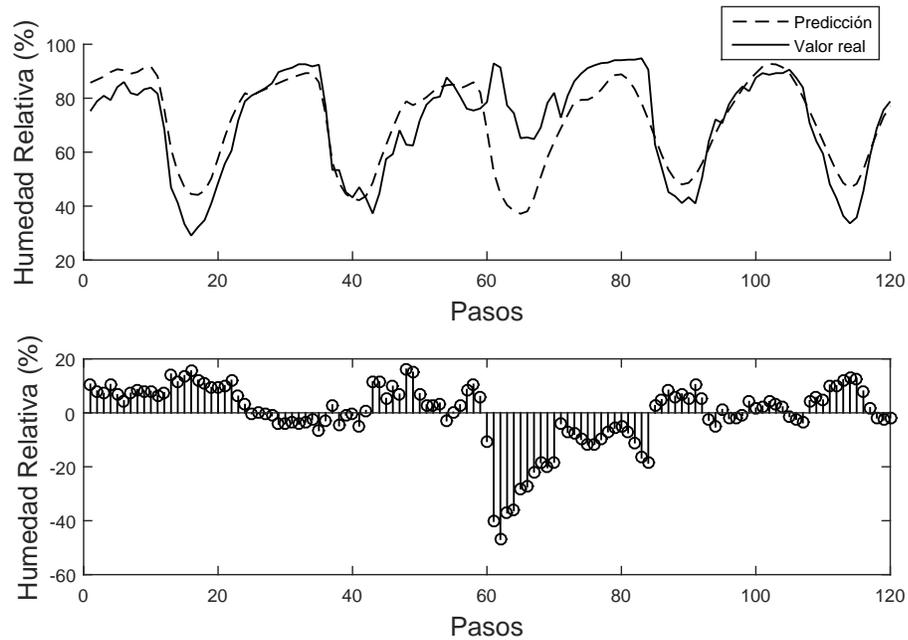


Figura 4.8: Predicción de humedad relativa utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5
RMSE (%)	9,618	6,025	20,69	8,680	6,168
RMQE (%)	10,43	8,347	27,06	10,55	8,103
R^2	0,9884	0,9125	0,0644	0,9428	0,9657
MAE (%)	9,144	4,476	15,72	7,596	4,836
MBE (%)	9,144	0,8797	-10,82	-3,366	3,496
MaxAE (%)	15,41	16,09	46,82	18,53	13,08

Tabla 4.14: Estadísticos para evaluar predicción de humedad relativa utilizando entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

4.3.4. Radiación global horizontal en base a predicciones

Al utilizar las predicciones de temperatura y humedad relativas en el modelo de RNA con las características descritas en la tabla 4.9, se obtienen las predicciones mostradas en la figura 4.9. Los estadísticos para evaluar los pronósticos se resumen en la tabla 4.15.

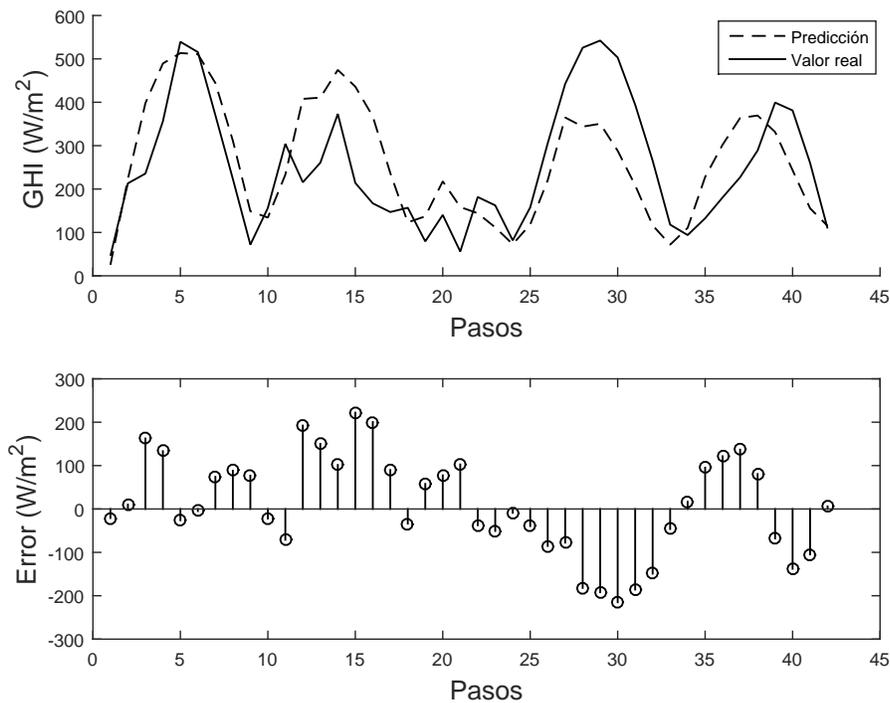


Figura 4.9: Predicción de radiación utilizando entradas predichas en días nublados. 17-07 hasta 21-07 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5
RMSE (W/m ²)	84,70	139,0	63,14	145,2	96,55
RMQE (W/m ²)	106,0	161,4	72,59	163,1	107,3
R ²	0,8528	0,3177	0,0298	0,8647	0,315
MAE (W/m ²)	66,28	120,3	55,82	130,2	85,21
MBE (W/m ²)	54,83	92,13	23,47	-130,2	16,24
MaxAE (W/m ²)	162,5	222,1	102,6	215,0	137,9

Tabla 4.15: Estadísticos para evaluar predicción de radiación utilizando entradas predichas en días nublados. 17-07 hasta 21-07 del 2015

4.3.5. Análisis de predicción de variables meteorológicas para días nublados

Debido a que en días nublados se tienen a veces cambios bruscos en los niveles de radiación, temperatura y humedad relativa, es que se estima en primera instancia que los valores del número de neuronas en la capa oculta sean mayores para poder aproximar de mejor manera los datos presentados. Viendo las tablas 4.9, 4.11 y 4.13, correspondientes a las configuraciones de las redes, se nota un valor de H más elevado que, en el caso de la irradiancia varía desde 10 hasta 13. Para la temperatura y humedad relativa, los valores de H son similares a los casos de días despejados, producto de que en este caso también se captó en mayor manera la tendencia del comportamiento debido a la única variable exógena de la hora en ambos casos.

Con respecto a los valores predichos de la radiación utilizando los valores reales de las entradas exógenas a futuro (Fig. 4.6), si bien no corresponden a una predicción perfecta capaz de captar los cambios bruscos que la irradiancia posee, pueden ser capaces de capturar la tendencia general. Si bien los valores de R² son bajos en comparación al caso de los días despejados, los errores MAE, RMSE y RMQE son relativamente bajos, evidenciando una predicción en general buena. Los errores máximos son significativos, variando desde 112,9 W/m² hasta 229,9 W/m². La tendencia general es de sobrepronóstico, y esto se evidencia en los valores positivos de MBE en casi todos los días exceptuando el cuarto, que es el que tiene mayor cantidad de irradiancia a lo largo del día.

Para poder pronosticar la irradiancia de forma real, se deben pronosticar también las variables de temperatura y humedad relativa. Nuevamente, en las figuras 4.7 y 4.8 se observa que debido a tener solamente la hora como variable exógena, se tienen valores predichos correspondientes a la tendencia general de los datos, incapaces de captar la dinámica de las variables a pronosticar.

La temperatura tiene buenos valores en términos de R², alcanzando casi todos alrededor de 0,9, con excepción del tercer día, que llega a un valor de 0,5021. No obstante, y en forma similar a la predicción en días despejados, se obtienen errores relativamente altos cuando la temperatura no sigue la tendencia esperada. Lo anterior se evidencia entre el tercer y cuarto día, donde se presentan los valores de errores MAE, RMSE y RMQE más altos, junto al mayor error máximo, de 6,329°C en el tercer día.

La humedad relativa presenta un comportamiento similar a la temperatura, en el cual no se pueden

captar las dinámicas de esta. Lo anterior se evidencia en el tercer día, que es el que presenta un mayor error en todas las variables y se alcanza un valor de R^2 igual a 0,0644.

Si bien los valores de temperatura y humedad relativas nuevamente no son pronosticados de forma óptima, aún así se tiene como resultado final una predicción de radiación que capta la tendencia de esta en cuanto a su forma, como muestra la figura 4.9. No obstante, los errores de predicción son relativamente grandes. Se tienen valores de R^2 bordeando el 0,85 en los días primero y cuarto, pero el segundo y quinto día alcanzan valores de 0,3. El tercer día llega a un valor de 0,029 lo que muestra una mala predicción. Con respecto a los valores máximos, estos son grandes y varían entre $102,6 \text{ W/m}^2$ y $222,1 \text{ W/m}^2$, lo que podría afectar en gran manera a la predicción futura de potencia.

Capítulo 5

Predicción de potencia fotovoltaica

Se utilizarán dos procedimientos para la predicción de potencia fotovoltaica: 1) mediante aproximación polinomial utilizando datos pasados para ajustar la superficie de la potencia, dependiente de la radiación y temperatura ambiente; 2) utilizando RNA con un método similar al correspondiente a la predicción de variables meteorológicas para calibrar y escoger la red que mejor generalice los últimos días. Para ambos, se utilizarán primero entradas futuras con objeto de evaluar el poder predictor de cada método. Luego, la radiación y temperatura predichas mediante las redes creadas anteriormente se usarán como entradas para obtener una predicción final real.

Previamente, para la predicción utilizando RNA, se crean varias redes variando tanto los días para entrenamiento, como límites para *delays* de entrada y salida, así como el número de neuronas en la capa oculta. La tabla 5.1 muestra los valores máximos a considerar para las predicciones de potencia mediante RNA.

	Días pasados	$d_{entrada}$	d_{salida}	H
Potencia	100	8	8	10

Tabla 5.1: Valores máximos a considerar para la búsqueda de redes neuronales para predicción de potencia

5.1. Días despejados

Para probar la capacidad de predicción en días despejados se pronosticará nuevamente desde el 23 al 27 de abril del 2015.

5.1.1. Mediante aproximación polinomial

Utilizando entradas reales futuras

Al utilizar una aproximación polinomial para el pronóstico de potencia mediante entradas reales futuras se obtiene la predicción mostrada en la figura 5.1. La tabla 5.2 exhibe los estadísticos para cada día, junto al total acumulado, que utiliza los datos de los cinco días seguidos para calcular cada estadístico. La distribución de errores de predicción se encuentra en la figura 5.2.

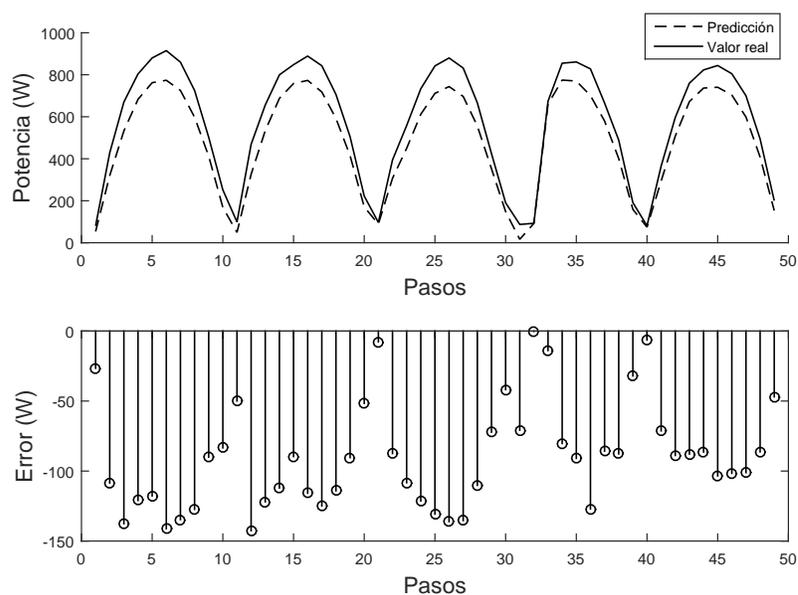


Figura 5.1: Predicción de potencia utilizando aproximación polinomial con entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5	Total acumulado
RMSE (W)	113,7	105,5	103,5	76,12	83,13	97,82
RMQE (W)	119,02	111,2	111,8	86,77	87,62	106,1
RMSEn	0,0812	0,0753	0,0741	0,0543	0,0593	0,0699
RMQEn	0,0850	0,0794	0,0798	0,0620	0,0626	0,0757
R^2	0,9960	0,9920	0,9980	0,9880	0,9970	0,99
MAE (W)	108,8	101,3	95,12	65,42	78,02	90,23
MBE (W)	-108,8	-101,3	-95,12	-65,42	-78,02	-90,23
MaxAE (W)	141,2	142,6	136,1	127,1	103,5	142,6
Asimetría	-	-	-	-	-	0,7850
Curtosis	-	-	-	-	-	2,824

Tabla 5.2: Estadísticos para evaluar predicción de potencia utilizando aproximación polinomial con entradas reales futuras en días despejados. 23-04 al 27-04 del 2015

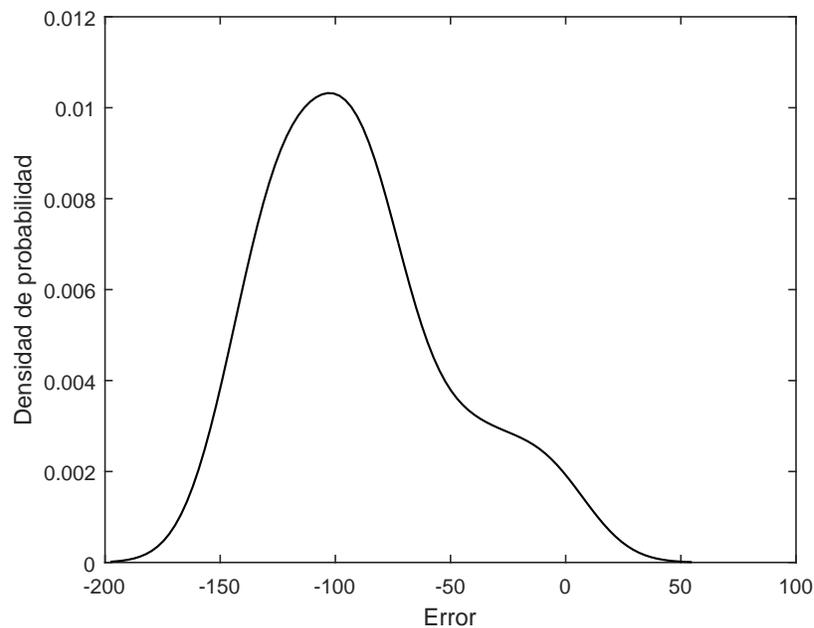


Figura 5.2: Distribución de errores de predicción utilizando aproximación polinomial con entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015

Utilizando entradas predichas

Al utilizar entradas predichas dentro del modelo polinomial se obtiene la predicción mostrada en la figura 5.3. La tabla 5.3 resume los estadísticos de la predicción. La distribución de errores se muestra en 5.4.

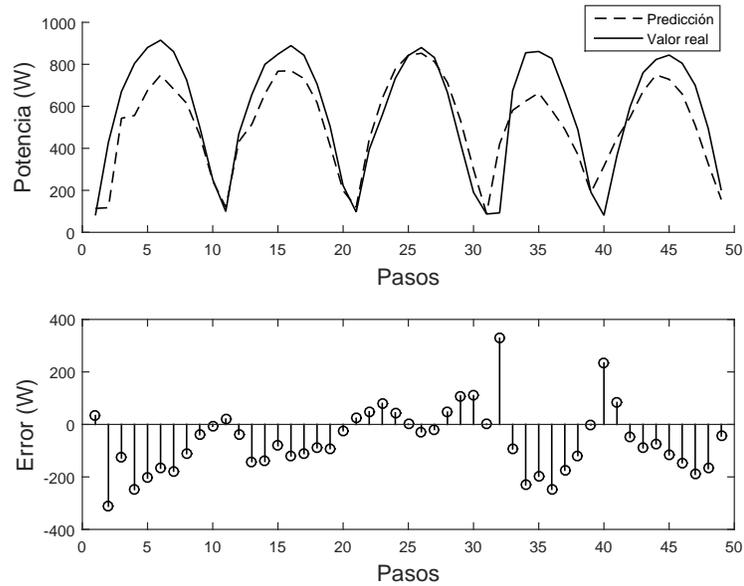


Figura 5.3: Predicción de potencia utilizando aproximación polinomial con entradas predichas en días despejados. 23-04 hasta 27-04 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5	Total acumulado
RMSE (W)	170,6	95,68	61,96	186,6	133,6	136,5
RMQE (W)	203,4	107,3	76,43	219,2	155,7	174,5
RMSEn	0,1221	0,0683	0,0442	0,1333	0,0954	0,0975
RMQEn	0,1453	0,0766	0,0546	0,1566	0,1112	0,12465
R^2	0,8674	0,9857	0,9772	0,7707	0,8108	0,8134
MAE (W)	142,6	85,49	50,81	154,5	119,3	109,7
MBE (W)	-135,9	-81,43	41,5	-81,43	-55,83	-62,24
MaxAE (W)	311,5	141,4	109,5	327,9	234,0	327,9
Asimetría	-	-	-	-	-	0,6574
Curtosis	-	-	-	-	-	4,0620

Tabla 5.3: Estadísticos para evaluar predicción de potencia utilizando aproximación polinomial con entradas predichas en días despejados. 23-04 al 27-04 del 2015

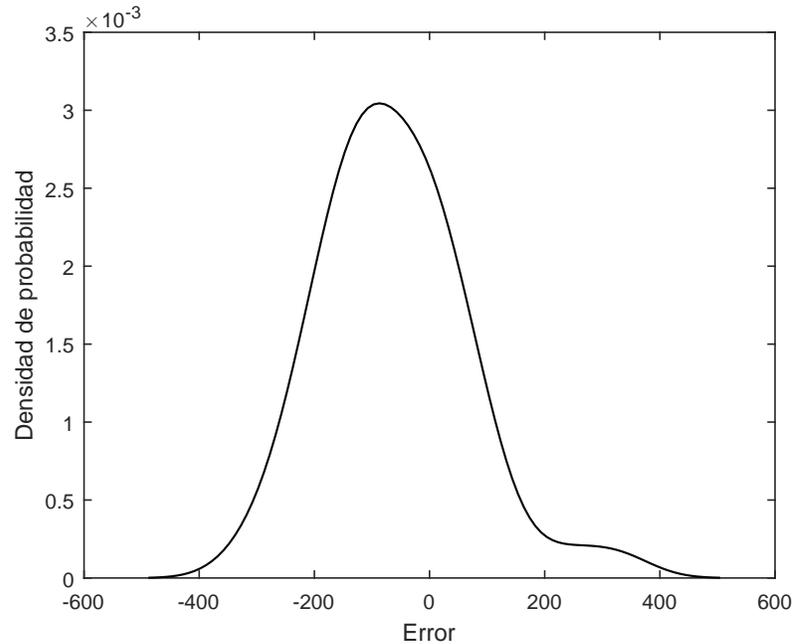


Figura 5.4: Distribución de errores de predicción utilizando aproximación polinomial con entradas predichas en días despejados. 23-04 hasta 27-04 del 2015

5.1.2. Análisis de predicción de potencia para días despejados utilizando aproximación polinomial

De la predicción de potencia fotovoltaica para días despejados utilizando entradas reales futuras dentro de un modelo polinomial, se observa en el gráfico de la figura 5.1 que se tiene una subpredicción general. Lo anterior es comprobable observando los valores de MBE en la tabla 5.2, que equivalen en todos los días al MAE en cuanto a magnitud pero con distinto signo: siempre se predice por debajo del valor real. No obstante, se tienen valores altos de R^2 , alcanzando como mínimo 0,988. Respecto a los errores máximos, estos generalmente se alcanzan a mitad del día, cuando la radiación solar es máxima. Las diferencias van desde 103,49 W hasta 142,61 W. Los errores en general son uniformes, y no muy grandes, lo que implica que el castigo por subir el exponente en los errores MAE, RMSE y RMQE no es tan significativo. Analizando la distribución de errores para los cinco días en la figura 5.2, se observa que estos se concentran en el lado izquierdo, es decir, se tiene una subpredicción. Lo anterior se resume en el valor de la asimetría general, que alcanza a ser 0,784. Con respecto a la curtosis, esta toma un valor de 2,824 lo que implica una curva no muy achatada ni aguzada, por lo que los errores de predicción no se concentran especialmente en una región.

Utilizando las entradas predichas de radiación y temperatura obtenidas mediante redes neuronales dentro del modelo polinomial para potencia fotovoltaica, se obtienen las predicciones mostradas en la figura 5.3. A primera vista, la predicción tiene ciertos problemas, lo que se puede observar en el primer y cuarto día. Si bien los valores de R^2 no son especialmente bajos, alcanzando 0,867 y

0,771 respectivamente, se alcanzan los mayores errores MaxAE, MAE, RMSE y RMQE. El resto de los días presentan mejores predicciones, con valores de R^2 variando desde 0,81 hasta 0,986, junto a errores MAE, RMSE y RMQE no muy grandes comparativamente hablando. Observando la distribución de errores en la figura 5.4 se puede dar cuenta de la subpredicción en general que posee el pronóstico total, aunque esta no es muy grande, dado que el valor de MBE alcanza a ser -62,236 W y la asimetría toma un valor de 0,657. La curva tampoco es levemente aguzada, lo que se comprueba con una curtosis de 4,0626.

5.1.3. Mediante redes neuronales artificiales

Utilizando entradas reales futuras

Se pronostica la potencia fotovoltaica utilizando RNA con las entradas reales futuras de radiación solar, temperatura, humedad relativa y hora del día. Las configuraciones de las redes para cada día se pueden apreciar en la tabla 5.4. El gráfico con los resultados obtenidos se muestran en la figura 5.5 mientras que la tabla 5.5 resume los estadísticos obtenidos para todos los días. El gráfico de la figura 5.6 muestra la distribución de errores.

	día 1	día 2	día 3	día 4	día 5
d_{input}	3	3	1	1	3
d_{output}	6	1	2	2	2
H	9	4	2	2	4

Tabla 5.4: Configuración de redes para pronosticar la potencia en días despejados. 23-04 hasta 27-04 del 2015

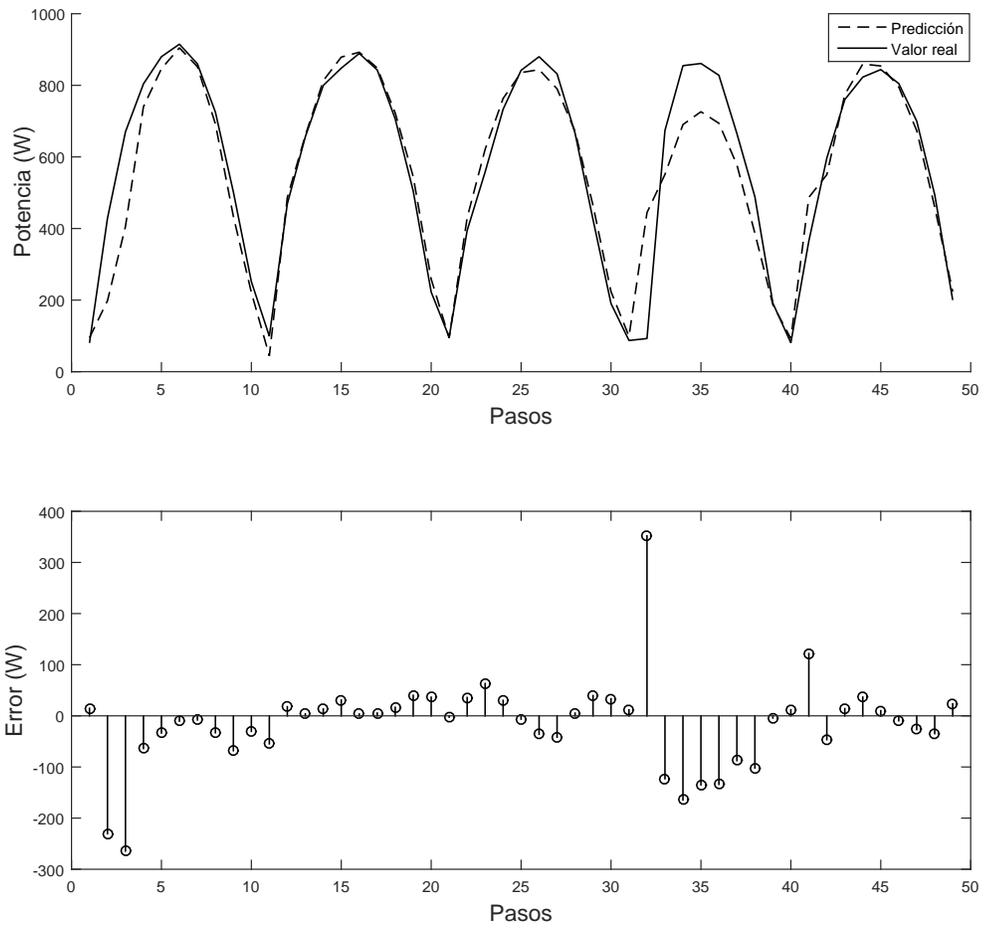


Figura 5.5: Predicción de potencia utilizando RNA con entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5	Total acumulado
RMSE (W)	116,3	27,76	34,63	156,5	46,21	89,96
RMQE (W)	166,8	34,65	40,48	208,8	69,18	150,5
RMSEn	0,0831	0,0198	0,0247	0,1120	0,0330	0,0643
RMQEn	0,1190	0,0248	0,0289	0,1490	0,0490	0,1070
R^2	0,9010	0,9920	0,9870	0,8000	0,9700	0,8950
MAE (W)	75,65	22,28	29,44	123,7	33,57	55,56
MBE (W)	-72,71	11,33	12,1	-42,93	10,07	-15,89
MaxAE (W)	264,4	54,73	63,16	351,9	121,8	351,8
Asimetría	-	-	-	-	-	0,5830
Curtosis	-	-	-	-	-	8,566

Tabla 5.5: Estadísticos para evaluar predicción de potencia utilizando RNA con entradas reales futuras en en días despejados. 23-04 al 27-04 del 2015

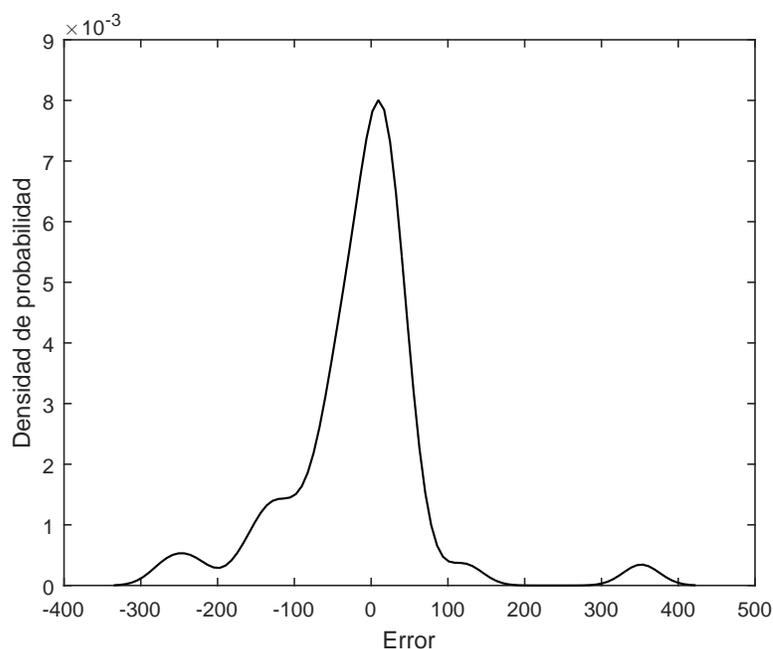


Figura 5.6: Distribución de errores de predicción utilizando RNA con entradas reales futuras en días despejados. 23-04 hasta 27-04 del 2015

Utilizando entradas predichas

Al utilizar las entradas anteriormente pronosticadas se obtiene la predicción mostrada en la figura 5.7. La tabla 5.8 resume los estadísticos obtenidos y la figura 5.8 muestra la distribución de errores para el conjunto de los cinco días.

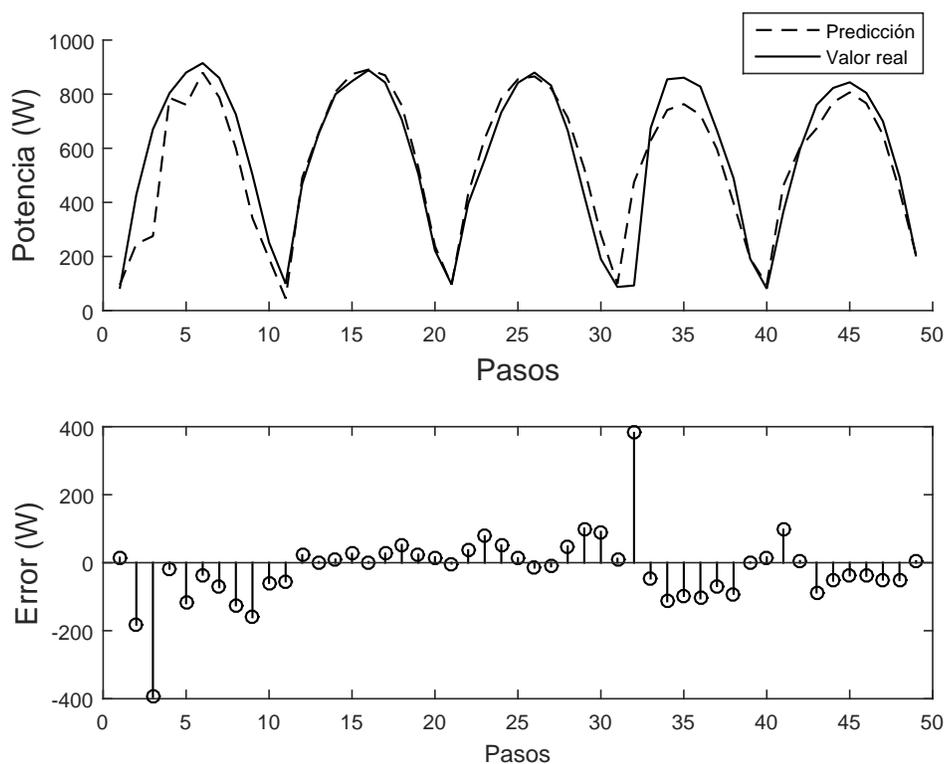


Figura 5.7: Predicción de potencia utilizando RNA con entradas predichas en días despejados. 23-04 hasta 27-04 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5	Total acumulado
RMSE (W)	159,8	29,24	55,76	147	53	102,77
RMQE (W)	227,1	36,67	68,54	221,6	64,39	177,6
RMSEn	0,1141	0,0209	0,0398	0,1050	0,0378	0,0734
RMQEn	0,1622	0,0262	0,0490	0,1580	0,0460	0,1270
R^2	0,8460	0,9930	0,9790	0,7940	0,9730	0,8640
MAE (W)	118,1	23,58	44,49	101,9	43,89	65,65
MBE (W)	-115,1	12,63	38,97	-14,22	-19,46	-19,54
MaxAE (W)	395,0	54,73	100,5	381,7	97,06	395,0
Asimetría	-	-	-	-	-	0,1336
Curtosis	-	-	-	-	-	9,476

Tabla 5.6: Estadísticos para evaluar predicción de potencia utilizando RNA con entradas predichas en días despejados. 23-04 al 27-04 del 2015

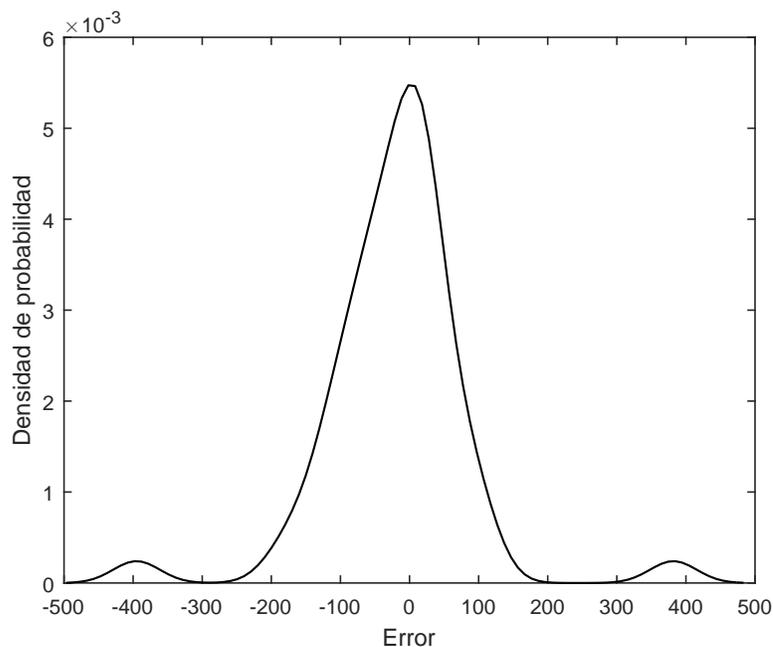


Figura 5.8: Distribución de errores de predicción utilizando RNA con entradas predichas en días despejados. 23-04 hasta 27-04 del 2015

5.1.4. Análisis de predicción de potencia para días despejados utilizando redes neuronales artificiales

La figura 5.5 muestra la predicción fotovoltaica utilizando entradas reales para los cinco días, junto a sus errores de predicción. A primera vista se ve que es una predicción bastante acertada, con excepción del cuarto día, que presenta los mayores errores, siendo el mayor cercano a los 400 W. Lo anterior se puede examinar de mejor manera en la tabla 5.5. El mejor día es el segundo, que tiene un R^2 de 0,992, junto a errores muy bajos en cuanto a RMSE, RMQE y sus correspondientes normalizadas. El valor MBE que presenta hace ver una pequeña sobrepredicción, pero sigue siendo el valor más bajo entre todo el conjunto de datos. Con respecto al cuarto día, este presenta un R^2 de 0,8 y el error más grande dentro de la predicción al principio de día como sobrepredicción, pasando luego a una subpredicción durante el resto del día, captado por el MBE con un valor de -42,93 W. También, es el día que presenta mayores errores en términos de RMSE, RMQE y sus normalizados. El error máximo que presenta es de 351,88 W, correspondiente a un 25,13 % de la capacidad total de la planta. Los días restantes se mantienen en una predicción buena, con coeficientes de determinación variables entre 0,9 y 0,98. Con respecto a la distribución de errores de predicción (Fig. 5.6), se puede apreciar una concentración de errores nulos bastante alta, indicando una buena predicción en general. Lo anterior se puede verificar mediante una curtosis de 8,56, que indica una curva aguzada. En conjunto con la curtosis, se tiene un valor de asimetría de 0,583, correspondiente a una leve subpredicción, lo que se aprecia de igual manera en el gráfico.

Al utilizar entradas futuras predichas en las redes para predecir la irradiancia, se obtienen valores bastante acertados como lo muestra la figura 5.3, teniendo errores en general bajos, con la excepción de los días primero y cuarto, que presentan valores de R^2 de 0,846 y 0,794 respectivamente. También poseen los mayores errores de predicción en cuanto al MaxAE, alcanzando 395,09 W para el primer día y 381,79 W para el cuarto. Considerando la distribución de errores, estos al ser pequeños hacen que esta sea bastante simétrica y aguzada, con una asimetría de 0,133 y una gran curtosis de 9,476.

5.2. Días nublados

Para probar la capacidad de predicción en días nublados se utilizarán tanto las entradas reales como las pronosticadas anteriormente para predecir la potencia desde el 17 al 21 de julio del 2015.

5.2.1. Utilizando aproximación polinomial

Utilizando entradas reales futuras

Al utilizar valores reales de radiación y temperatura futuros dentro de una aproximación polinomial, se obtiene la predicción que muestra la figura 5.9. Los estadísticos asociados a esta se presentan en la tabla 5.7. La figura 5.10 representa la distribución de errores para los cinco días predichos.

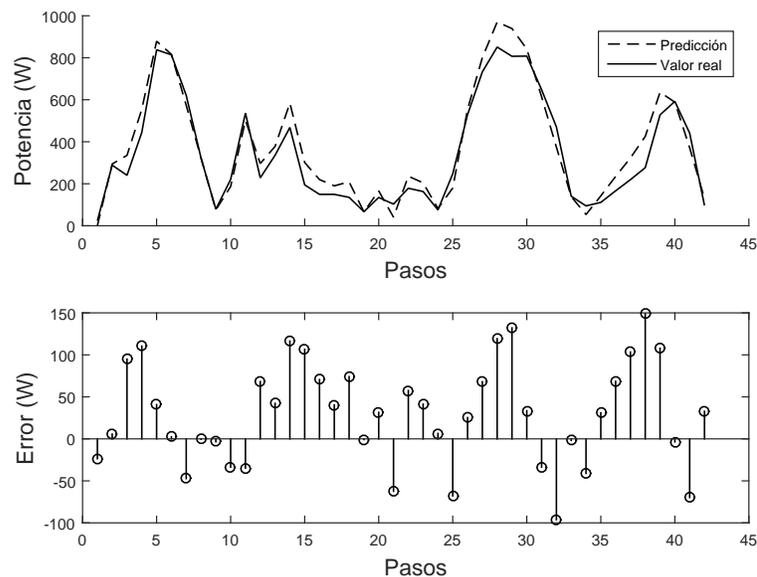


Figura 5.9: Predicción de potencia utilizando aproximación polinomial con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5	Total acumulado
RMSE (W)	53,42	71,30	40,68	76,76	80,09	67,63
RMQE (W)	71,70	81,52	47,27	91,75	96,79	84,01
RMSEn	0,0381	0,0509	0,0290	0,0548	0,0572	0,0483
RMQEn	0,0512	0,0582	0,0338	0,0655	0,0691	0,0600
R^2	0,9700	0,8666	0,8405	0,9669	0,8739	0,9485
MAE (W)	36,51	65,19	33,30	64,17	67,41	54,74
MBE (W)	19,92	49,99	12,26	19,85	41,98	29,98
MaxAE (W)	110,4	116,4	62,36	132,1	148,8	148,8
Asimetría	-	-	-	-	-	-0,0151
Curtosis	-	-	-	-	-	2,190

Tabla 5.7: Estadísticos para evaluar predicción de potencia utilizando aproximación polinomial con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

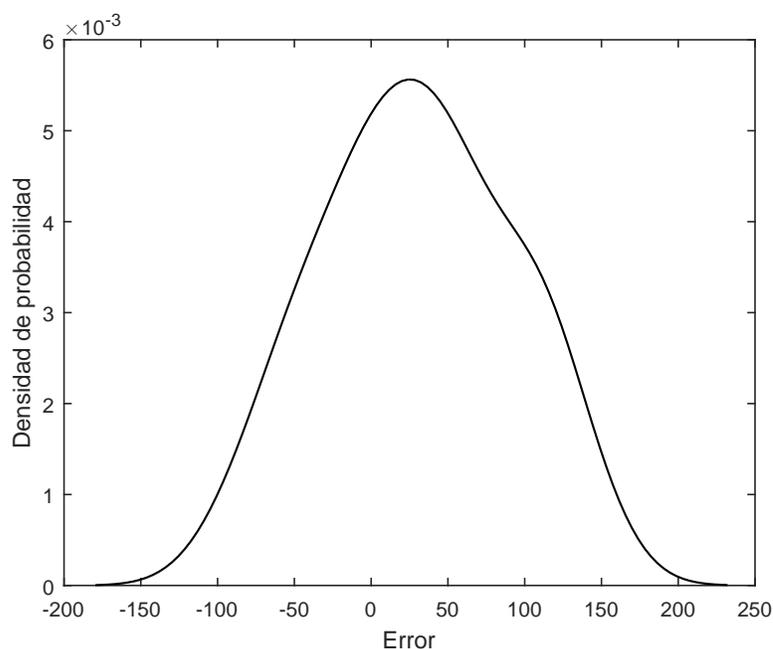


Figura 5.10: Distribución de errores de predicción utilizando aproximación polinomial con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

Utilizando entradas predichas

Al utilizar la radiación y temperatura predichas mediante RNA como entradas hacia los modelos polinomiales diarios creados, se obtienen las predicciones mostrada en la figura 5.11. Los estadísticos utilizados para evaluar las predicciones se muestran en la tabla 5.8 y la distribución de errores

se aprecia en la figura 5.12.

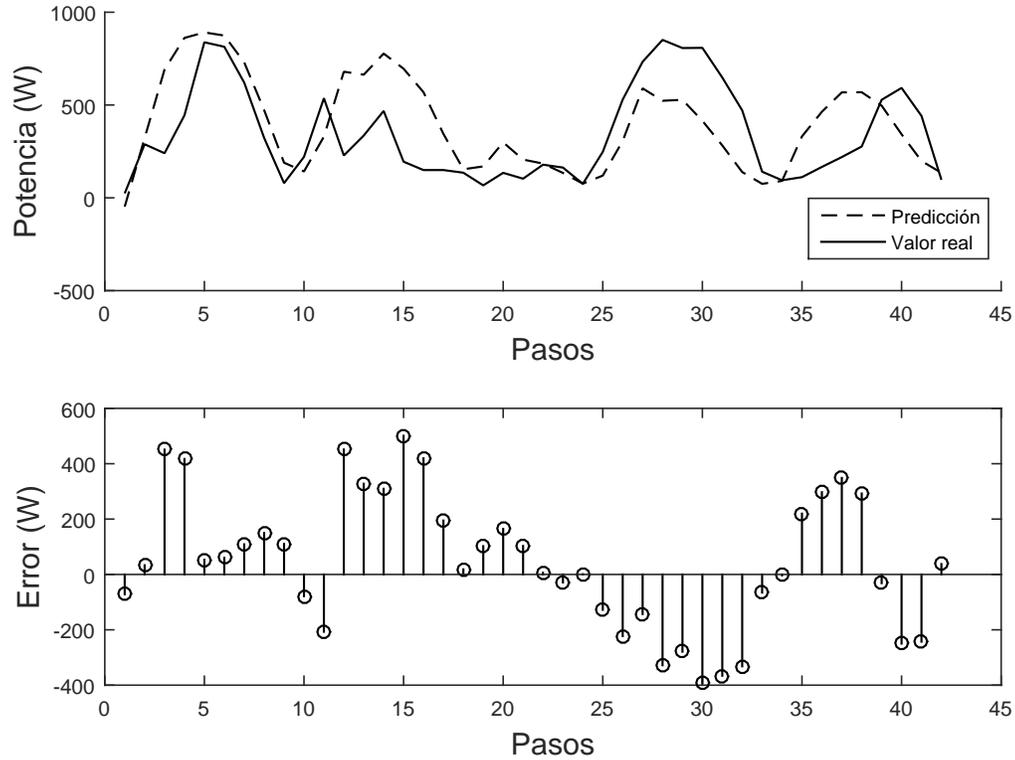


Figura 5.11: Predicción de potencia utilizando aproximación polinomial con entradas predichas en días nublados. 17-07 hasta 21-07 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5	Total acumulado
RMSE (W)	220,2	319,9	90,29	273,7	227,9	246,3
RMQE (W)	299,6	364,8	112,2	301,8	257,5	301,5
RMSEn	0,1573	0,2285	0,0645	0,1955	0,1628	0,1759
RMQEn	0,2140	0,2606	0,0801	0,2156	0,1839	0,2154
R^2	0,7327	0,0642	0,0772	0,8132	0,0676	0,2846
MAE (W)	161,7	278,6	67,55	250,7	191,4	198,8
MBE (W)	145,8	215,2	57,90	-250,7	74,19	47,80
MaxAE (W)	450,97	500,92	164,33	392,81	348,65	500,9
Asimetría	-	-	-	-	-	-0,05022
Curtosis	-	-	-	-	-	2,148

Tabla 5.8: Estadísticos para evaluar predicción de potencia utilizando aproximación polinomial con entradas predichas en días nublados. 17-07 al 21-07 del 2015

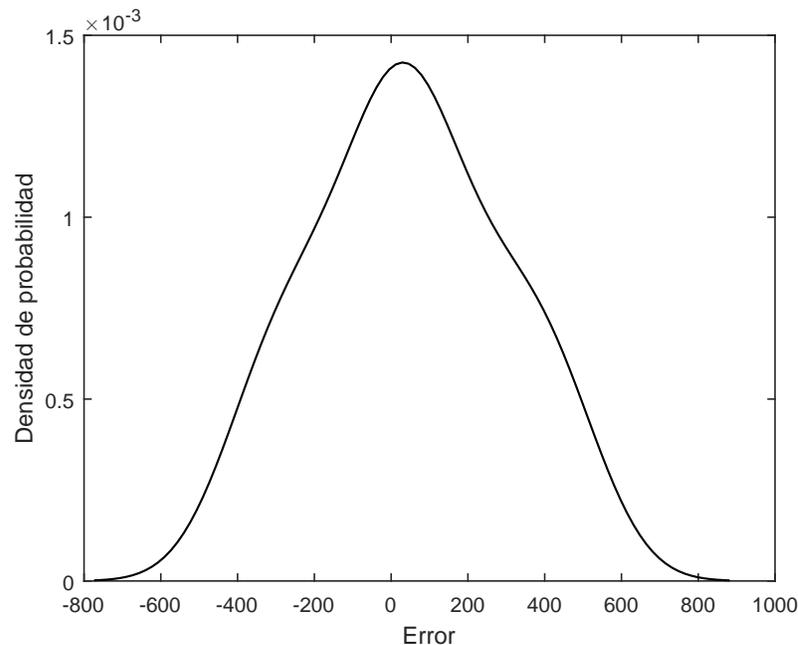


Figura 5.12: Distribución de errores de predicción utilizando aproximación polinomial con entradas predichas futuras en días nublados. 17-07 hasta 21-07 del 2015

5.2.2. Análisis de predicción de potencia para días nublados utilizando aproximación polinomial

El utilizar aproximación polinomial para predecir valores futuros de potencia fotovoltaica utilizando entradas reales da buenos resultados como lo muestra la figura 5.9. Se obtienen valores de R^2 variables entre 0,84 y 0,97 para cada día. Se aprecia una leve sobrepredicción, lo que se comprueba mediante los valores de MBE que se obtienen en la tabla 5.7, mostrando solo valores positivos de este estadístico para cada día. Dado que no se tienen errores tan grandes, es que el castigo al aumentar el coeficiente de error en los errores MAE, RMSE y RMQE es relativamente pequeño, variando en general en 1 % de la capacidad nominal de la planta, como muestran los valores normalizados. El total de la predicción muestra un gráfico bastante simétrico, con una leve inclinación hacia la sobrepredicción mencionada, lo que se comprueba mediante un valor MBE total de 29,98 W y una asimetría de -0,015. Los errores no están necesariamente concentrados en un valor, por lo que la distribución de errores presenta un gráfico un poco achatado, alcanzando una curtosis de 2,19.

Al utilizar la salida de las redes neuronales de radiación y temperatura dentro del modelo polinomial se obtiene una predicción mostrada en la figura 5.11, con grandes errores en su totalidad. Analizando los valores normalizados de RMSE y RMQE, se encuentra que, a excepción del tercer día, estos rodean el 20 % de la capacidad de la planta. Los errores máximos varían desde 164,33 W para el tercer día hasta 500,92 W para el segundo día. En general, la predicción no puede seguir a los valores reales, dado el valor de 0,284 que alcanza el R^2 . La distribución de errores muestra que se

tienen estos en un amplio espectro, con una leve tendencia a la sobrepredicción.

5.2.3. Mediante RNA

Utilizando entradas reales

Al pronosticar potencia fotovoltaica mediante RNA se configuran las redes con las características mostradas en la tabla 5.9. Utilizando entradas reales futuras se obtienen las predicciones mostradas en la figura 5.13, mientras que los estadísticos que evalúan estas se pueden observar en la figura 5.10. La distribución de errores se encuentra en la figura 5.14.

	día 1	día 2	día 3	día 4	día 5
d_{input}	4	7	4	2	6
d_{output}	6	3	1	8	5
H	9	4	4	8	4

Tabla 5.9: Configuración de redes para pronosticar la potencia en días nublados. 17-07 hasta 21-07 del 2015

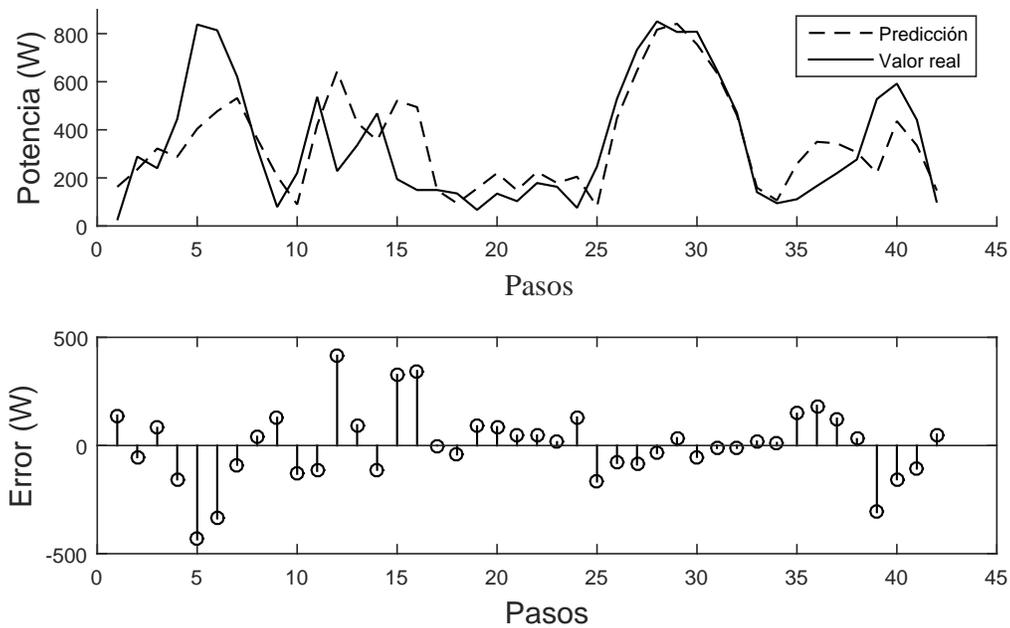


Figura 5.13: Predicción de potencia utilizando RNA con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5	Total acumulado
RMSE (W)	205,7	224,1	77,91	72,65	150,9	163,4
RMQE (W)	272,5	280,8	90,68	99,4	189,3	230,4
RMSEn	0,1469	0,1601	0,0557	0,0519	0,1078	0,1167
RMQEn	0,1946	0,2006	0,0648	0,0710	0,1352	0,1646
R^2	0,7105	0,0528	0,2615	0,9515	0,3126	0,576
MAE (W)	162,1	175,8	68,56	55,13	124,2	120,6
MBE (W)	-75,68	86,54	68,56	-43,41	-2,571	2,269
MaxAE (W)	433,7	415,2	129,1	166,4	307,9	433,7
Asimetría	-	-	-	-	-	-0,0487
Curtosis	-	-	-	-	-	3,956

Tabla 5.10: Estadísticos para evaluar predicción de potencia utilizando RNA con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

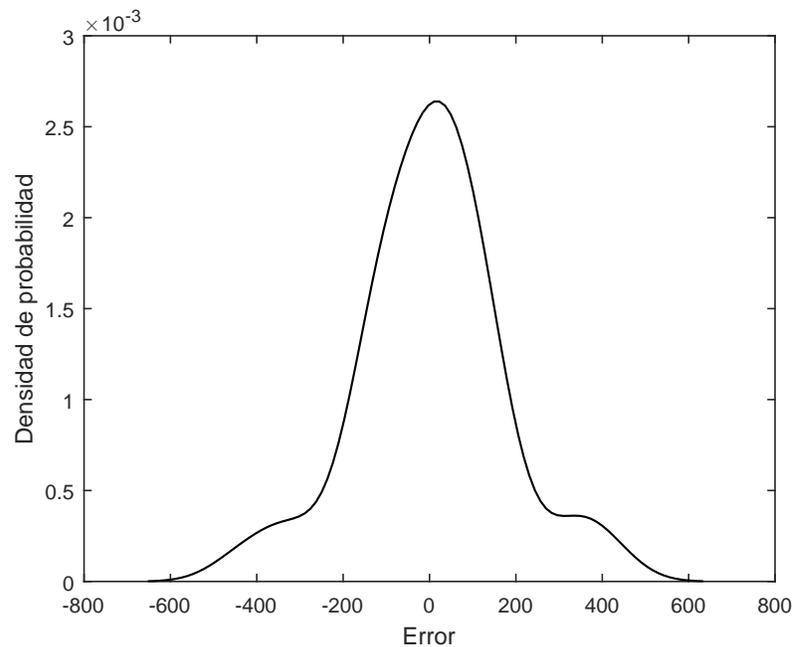


Figura 5.14: Distribución de errores de predicción utilizando RNA con entradas reales futuras en días nublados. 17-07 hasta 21-07 del 2015

Utilizando entradas predichas

Al utilizar entradas predichas para predecir la potencia en días nublados, se obtienen las predicciones mostradas en la figura 5.15. Los estadísticos asociados se presentan en la tabla 5.11, mientras que la distribución de errores se muestra en la figura 5.16.

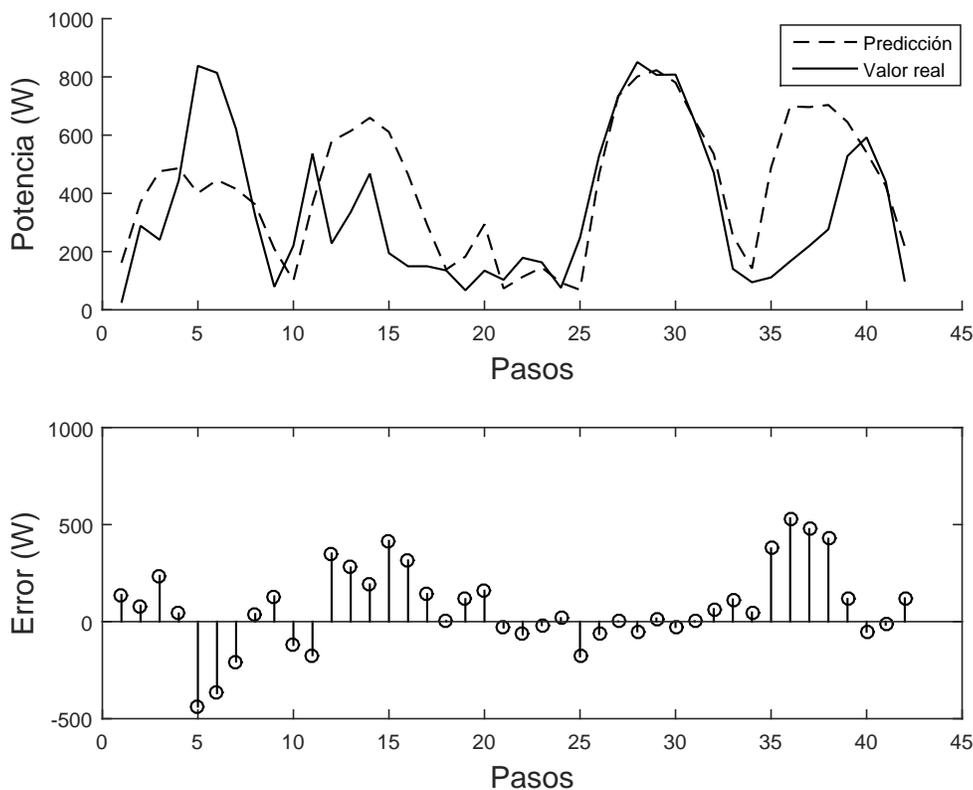


Figura 5.15: Predicción de potencia utilizando RNA con entradas predichas en días nublados. 17-07 hasta 21-07 del 2015

Estadístico	día 1	día 2	día 3	día 4	día 5	Total acumulado
RMSE (W)	228,6	252,6	86,20	79,35	310,6	219
RMQE (W)	286,3	290,2	108,9	108,2	379,0	293,6
RMSEn	0,1633	0,1804	0,0616	0,0567	0,2219	0,1564
RMQEn	0,2045	0,2073	0,0778	0,0773	0,2707	0,2100
R^2	0,4181	0,1259	0,0097	0,9017	0,1395	0,3900
MAE (W)	186,4	221,2	67,63	57,56	240,5	160,9
MBE (W)	-38,29	156,2	29,98	-13,42	225,5	75,00
MaxAE (W)	437,3	416,0	159,3	178,9	532,2	532,2
Asimetría	-	-	-	-	-	0,0670
Curtosis	-	-	-	-	-	3,2347

Tabla 5.11: Estadísticos para evaluar predicción de potencia utilizando RNA con entradas predichas en días nublados. 17-07 hasta 21-07 del 2015

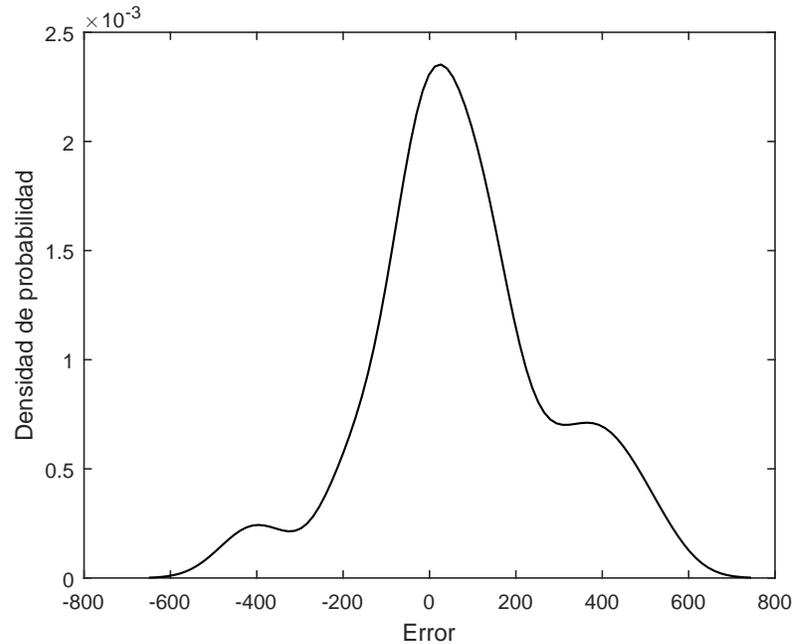


Figura 5.16: Distribución de errores de predicción utilizando RNA con entradas predichas en días nublados. 17-07 hasta 21-07 del 2015

5.2.4. Análisis de predicción de potencia para días nublados utilizando redes neuronales artificiales

La predicción de potencia utilizando entradas reales mostrada en la figura 5.13 muestra que se tienen dos situaciones: 1) para los días tercero y cuarto, una buena predicción que es capaz de captar tanto la forma como los valores teniendo errores relativamente pequeños y 2) para el primer, segundo y quinto día una predicción incapaz de seguir las tendencias de la potencia. En el segundo caso se ven errores RMSE variando desde el 10,77 % hasta un 16 % de la capacidad de la planta para el quinto y segundo día respectivamente. El total de la predicción presenta un error RMSE correspondiente a un 11,6 % de la capacidad de la planta y un R^2 de 0,576. Se nota una asimetría pequeña y positiva, que significa una leve tendencia a sobrepronosticar.

Al utilizar entradas predichas, los errores en la predicción aumentan aún más, como lo muestra la figura 5.15, en la que denota un pronóstico bueno solamente para el cuarto día. En los días restantes, se ven grandes errores en la predicción con errores máximos importantes. Para el total de la predicción, se tiene un valor pobre de R^2 alcanzando un 0,39 y grandes errores RMSE y RMQE en términos de la capacidad de la planta, alcanzando un 15,6 % y 0,21 % respectivamente.

Capítulo 6

Conclusiones y trabajo a futuro

El objetivo final del estudio fue prever la potencia de una planta fotovoltaica mediante redes neuronales artificiales para evaluar, en primera instancia, una aplicación de predicción solar para la empresa Phineal, lo cual fue satisfecho.

Para el desarrollo y evaluación del estudio se propuso una metodología que, según las pruebas hechas, permite abarcar la variable que afecta mayormente el rendimiento de las redes neuronales: su tamaño. De todas formas, al haber tantos parámetros a escoger como funciones de activación, algoritmos de entrenamiento, datos y su división, entre otros, es virtualmente imposible encontrar la mejor configuración de RNA dado que no existen procedimientos estándares para seleccionar tanto la arquitectura como sus partes internas. Lo anterior implica que no se puede asegurar que las redes escogidas fueran las óptimas.

La ventaja de utilizar RNA para modelar estadísticamente y predecir series de tiempo es que se pueden configurar de forma relativamente fácil y automática. No obstante, el problema que poseen es que son modelos de caja negra: tienen un mecanismo no transparente que relaciona entradas con salidas y el usuario no comprende la naturaleza interna generada por la red para responder ante una tarea determinada. También, luego de ser entrenadas, no se pueden hacer cambios externos para variar la respuesta de las RNA.

6.1. Utilización de redes neuronales artificiales para modelar variables meteorológicas

El pronóstico de variables meteorológicas mediante RNA es una prueba de que las redes NARX pueden utilizarse con éxito en la predicción de series de tiempo. La predicción de irradiancia utilizando valores conocidos de temperatura ambiente y humedad relativa genera resultados que, si bien no predicen completamente toda la dinámica de la radiación, siguen la forma de la serie de tiempo tanto para días despejados como nublados.

Al pronosticar las variables exógenas de temperatura y humedad relativas, debido a tener solamente

la hora como entrada de esas redes neuronales, no se puede relacionar ni captar con suficiente precisión la dinámica futura en las predicciones. Lo anterior genera que el pronóstico de la radiación solar utilizando puramente RNA se aleje de los resultados preliminares al utilizar entradas reales. Un procedimiento así sigue siendo plausible, producto de que se podrían pronosticar los parámetros de temperatura ambiente y humedad relativa del día siguiente mediante otro método más fiable, como el modelo numérico de predicción meteorológica.

6.2. Modelación fotovoltaica

Para días despejados, la predicción mediante aproximación polinomial posee en general una buena forma, pero tiende a subpredecir los valores. En cambio, utilizando redes neuronales artificiales, tanto con entradas reales como con las predichas, se tiene un pronóstico que calza de mejor manera en términos de errores MAE, RMSE y RMQE.

En días nublados, utilizando aproximación polinomial se obtienen muy buenos resultados usando los datos reales de radiación solar y temperatura, pero al usar las entradas predichas se generan errores importantes. Al modelar la potencia mediante redes neuronales artificiales, si bien no se logra captar en detalle la serie de tiempo a futuro, se genera una mejor predicción al utilizar las entradas predichas.

Si bien el cálculo de la potencia fotovoltaica mediante una superficie aproximada y utilizando redes neuronales probó ser suficiente para evaluar a groso modo la capacidad predictora de las RNA en este trabajo, se requieren modelos más robustos para modelar la potencia en distintas condiciones.

El uso de estadísticos propuestos por el Departamento de Energía de los Estados Unidos permite no solamente analizar los errores en términos de las herramientas clásicas, sino que considera además el análisis del error cuártico medio, el error máximo absoluto y la distribución de errores. Estas herramientas ayudan a evaluar de mejor manera la calidad de las predicciones, al tener mayor información acerca de los errores extremos y poder localizar las tendencias de los métodos predictivos.

6.3. Trabajo a futuro

Del estudio hecho, se pueden recomendar los siguientes puntos a evaluar, para un posible trabajo a futuro.

- Para predecir de mejor forma la potencia utilizando redes neuronales, se recomienda hacer mediciones de la radiación global en el plano de los paneles. El trabajo sería similar a lo que desarrolla Pavit Mellit, el cual utiliza como entradas valores provenientes de predicciones NWP y los usa como entrada a una red neuronal que predice potencia. El error que obtiene es minúsculo, dado que la serie de tiempo de la radiación en plano inclinado adopta la misma forma de la potencia de salida. No solamente se vería beneficiada la forma de predecir potencia

de salida utilizando redes neuronales, sino que al tener valores predichos de radiación en el plano de los paneles, también se podría utilizar de mejor manera una modelación del tipo física.

- Si bien una parte del trabajo fue hecho utilizando redes neuronales artificiales para predecir de forma final la potencia de salida, puede ser beneficioso el utilizar modelos de predicción de variables meteorológicas del tipo mixtos, combinando otros modelos como el NWP para estimar la temperatura y la humedad relativa. De esta forma se evitaría realizar una predicción puramente estadística para las entradas de las redes neuronales.
- Para mejorar las predicciones de las redes neuronales artificiales, se podrían utilizar métodos de inteligencia artificial híbridos. El combinar las redes neuronales artificiales con lógica difusa, cadenas de Markov o algoritmos genéticos para optimizar los pesos de las redes ha sido probado con éxito y es otra forma de estudiar el problema de pronóstico.

Bibliografía

- [1] Comité Consultivo de Energía 2050. Hoja de ruta 2050. *Ministerio de Energía*.
- [2] Vaisala. Global solar irradiance map, visitado 27 de febrero, 2017. URL http://www.vaisala.com/Vaisala%20Documents/Scientific%20papers/Vaisala_global_solar_map.pdf.
- [3] Bundesnetzagentur. Datenmeldungen und eeg-vergütungssätze für photovoltaikanlagen.
- [4] Medioambientales y Tecnológicas Centro de Investigaciones Energéticas. Fundamentos, dimensionado y aplicaciones de la energía solar fotovoltaica.
- [5] Iván Saavedra Dote. La operación del sistema ante la integración de ernc. *CNE*.
- [6] A Mellit, A Massi Pavan, and V Lughi. Short-term forecasting of power production in a large-scale photovoltaic plant. *Solar Energy*, 105:401–413, 2014.
- [7] André Madureira, Ricardo Bessa, J Meirinhos, D Fayzur, J Filipe, AA Messias, DA Lopes, and PG Matos. The impact of solar power forecast errors on voltage control in smart distribution grids. In *Proceedings of the 23rd International Conference and Exhibition on Electricity Distribution (CIRED 2015), Lyon, France, 2015*.
- [8] Phineal. Espectro de radiación solar, visitado 27 de febrero, 2017. URL <http://www.phinet.cl/ds/wp-content/uploads/2016/02/Espectro-radiaci%C3%B3n-Solar-Editado-de-Wikipedia.png>.
- [9] Piranómetro SR11 Sensovant. Visitado 27 de febrero, 2017, . URL <http://sensovant.com/productos/meteorologia/radiacion-solar/articulo/piranometro-clase-A-primera-clase-SR11.html>.
- [10] Pirheliómetro DR01 Sensovant. Visitado 27 de febrero, 2017, . URL <http://sensovant.com/productos/meteorologia/radiacion-solar/articulo/medidor-de-radiacion-solar-pirheliometro-DR01.html>.
- [11] FJ Olmo, J Vida, I Foyo, Y Castro-Diez, and L Alados-Arboledas. Prediction of global irradiance on inclined surfaces from horizontal global irradiance. *Energy*, 24(8):689–704, 1999.

- [12] Matthew Lave, William Hayes, Andrew Pohl, and Clifford W Hansen. Evaluation of global horizontal irradiance to plane-of-array irradiance models at locations across the united states. *IEEE Journal of Photovoltaics*, 5(2):597–606, 2015.
- [13] Pierre Ineichen. Comparison and validation of three global-to-beam irradiance models against ground measurements. *Solar Energy*, 82(6):501–512, 2008.
- [14] CP Jacovides, FS Tymvios, VD Assimakopoulos, and NA Kaltsounides. Comparative study of various correlations in estimating hourly diffuse fraction of global solar radiation. *Renewable Energy*, 31(15):2492–2504, 2006.
- [15] PG Loutzenhiser, H Manz, C Felsmann, PA Strachan, Th Frank, and GM Maxwell. Empirical validation of models to compute solar irradiance on inclined surfaces for building energy simulation. *Solar Energy*, 81(2):254–267, 2007.
- [16] Ali Mohammad Noorian, Isaac Moradi, and Gholam Ali Kamali. Evaluation of 12 models to estimate hourly diffuse irradiation on inclined surfaces. *Renewable energy*, 33(6):1406–1412, 2008.
- [17] D Włodarczyk and H Nowak. Statistical analysis of solar radiation models onto inclined planes for climatic conditions of lower silesia in poland. *Archives of Civil and Mechanical Engineering*, 9(2):127–144, 2009.
- [18] Christian A Gueymard. Direct and indirect uncertainties in the prediction of tilted irradiance for solar engineering applications. *Solar Energy*, 83(3):432–444, 2009.
- [19] Robert Ulbricht, Ulrike Fischer, Wolfgang Lehner, and Hilko Donker. First steps towards a systematical optimized strategy for solar energy supply forecasting. In *Proceedings of the European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases (ECMLPKDD 2013), Prague, Czech Republic*, volume 2327, 2013.
- [20] Maimouna Diagne, Mathieu David, Philippe Lauret, John Boland, and Nicolas Schmutz. Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. *Renewable and Sustainable Energy Reviews*, 27:65–76, 2013.
- [21] Elke Lorenz, Annette Hammer, and Detlev Heinemann. Short term forecasting of solar radiation based on satellite data. In *EUROSUN2004 (ISES Europe Solar Congress)*, page 2004, 2004.
- [22] Richard Perez, Sergey Kivalov, James Schlemmer, Karl Hemker, David Renné, and Thomas E Hoff. Validation of short and medium term operational solar radiation forecasts in the us. *Solar Energy*, 84(12):2161–2172, 2010.
- [23] Jukka V Paatero and Peter D Lund. Effects of large-scale photovoltaic power integration on electricity distribution networks. *Renewable Energy*, 32(2):216–234, 2007.

- [24] Alberto Dolara, Sonia Leva, and Giampaolo Manzolini. Comparison of different physical models for pv power output prediction. *Solar Energy*, 119:83–99, 2015.
- [25] Widalys De Soto, SA Klein, and WA Beckman. Improvement and validation of a model for photovoltaic array performance. *Solar energy*, 80(1):78–88, 2006.
- [26] Aron P Dobos. An improved coefficient calculator for the california energy commission 6 parameter photovoltaic module model. *Journal of solar energy engineering*, 134(2):021011, 2012.
- [27] Ali Naci Celik and Nasır Acikgoz. Modelling and experimental verification of the operating current of mono-crystalline photovoltaic modules using four-and five-parameter models. *Applied energy*, 84(1):1–15, 2007.
- [28] Antonio Luque and Steven Hegedus. *Handbook of photovoltaic science and engineering*. John Wiley & Sons, 2011.
- [29] Mayukh Samanta, Bharath K Srikanth, and Jayesh B Yerrapragada. Short-term power forecasting of solar pv systems using machine learning techniques.
- [30] Rui Huang, Tiana Huang, Rajit Gadh, and Na Li. Solar generation prediction using the arma model in a laboratory-level micro-grid. In *Smart Grid Communications (SmartGridComm), 2012 IEEE Third International Conference on*, pages 528–533. IEEE, 2012.
- [31] Yanting Li, Yan Su, and Lianjie Shu. An armax model for forecasting the power output of a grid connected photovoltaic system. *Renewable Energy*, 66:78–89, 2014.
- [32] Emanuele Ogliari, Francesco Grimaccia, Sonia Leva, and Marco Mussetta. Hybrid predictive models for accurate forecasting in pv systems. *Energies*, 6(4):1918–1929, 2013.
- [33] M Bouzerdoum, A Mellit, and A Massi Pavan. A hybrid model (sarima–svm) for short-term power forecasting of a small-scale grid-connected photovoltaic plant. *Solar Energy*, 98:226–235, 2013.
- [34] Ajoy K Palit and Dobrivoje Popovic. Computational intelligence in time series forecasting, 2006.
- [35] Jovina Roman and Akhtar Jameel. Backpropagation and recurrent neural networks in financial analysis of multiple stock market returns. In *System Sciences, 1996., Proceedings of the Twenty-Ninth Hawaii International Conference on*, volume 2, pages 454–460. IEEE, 1996.
- [36] Innocent Kamwa, Robert Grondin, VK Sood, C Gagnon, J Mereb, et al. Recurrent neural networks for phasor detection and adaptive identification in power system control and protection. *IEEE transactions on instrumentation and measurement*, 45(2):657–664, 1996.
- [37] Anthony J Robinson. An application of recurrent nets to phone probability estimation. *IEEE transactions on Neural Networks*, 5(2):298–305, 1994.

- [38] Mark Hudson Beale, Martin T Hagan, and Howard B Demuth. Neural network toolbox™ user's guide. In *R2016b, The MathWorks, Inc., 3 Apple Hill Drive Natick, MA 01760-2098, www.mathworks.com*. Citeseer, 2016.
- [39] Alex Waibel, Toshiyuki Hanazawa, Geoffrey Hinton, Kiyohiro Shikano, and Kevin J Lang. Phoneme recognition using time-delay neural networks. *IEEE transactions on acoustics, speech, and signal processing*, 37(3):328–339, 1989.
- [40] Rayner Alfred et al. Performance of modeling time series using nonlinear autoregressive with exogenous input (narx) in the network traffic forecasting. In *2015 International Conference on Science in Information Technology (ICSITech)*, pages 164–168. IEEE, 2015.
- [41] Hava T Siegelmann, Bill G Horne, and C Lee Giles. Computational capabilities of recurrent narx neural networks. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 27(2):208–215, 1997.
- [42] Tsungnan Lin, Bill G Horne, Peter Tino, and C Lee Giles. Learning long-term dependencies is not as difficult with narx recurrent neural networks. 1998.
- [43] Hang Xie, Hao Tang, and Yu-He Liao. Time series prediction based on narx neural networks: An advanced approach. In *2009 International Conference on Machine Learning and Cybernetics*, volume 3, pages 1275–1279. IEEE, 2009.
- [44] José Maria P Menezes Jr and Guilherme De A Barreto. A new look at nonlinear time series prediction with narx recurrent neural network. *SBRN*, 6:28–33, 2006.
- [45] Alexander G Parlos, Omar T Rais, and Amir F Atiya. Multi-step-ahead prediction using dynamic recurrent neural networks. *Neural networks*, 13(7):765–786, 2000.
- [46] Jeff Heaton. *Introduction to neural networks with Java*. Heaton Research, Inc., 2008.
- [47] HD Navone and HA Ceccatto. Predicting indian monsoon rainfall: a neural network approach. *Climate Dynamics*, 10(6-7):305–312, 1994.
- [48] Jan Kleissl. *Solar energy forecasting and resource assessment*. Academic Press, 2013.
- [49] Jie Zhang, Anthony Florita, Bri-Mathias Hodge, Siyuan Lu, Hendrik F Hamann, Venkat Banunarayanan, and Anna M Brockway. A suite of metrics for assessing the performance of solar power forecasting. *Solar Energy*, 111:157–175, 2015.
- [50] Pirheliómetro CS300 Campbell. Visitado 27 de febrero, 2017, . URL <https://www.campbellsci.es/cs300-pyranometer>.
- [51] Pirheliómetro CS300 Campbell. Visitado 27 de febrero, 2017, . URL <https://www.campbellsci.com/hmp60>.

Apéndice A

Anexos

Algoritmo de Levenberg-Marquardt

. El algoritmo de Levenberg-Marquardt (LM) actualiza los pesos de la red de la forma:

$$\Delta w = -\nabla E(w) \left(\mu I + \sum_{p=1}^P J^p(w)^T J^p(w) \right) \quad (\text{A.1})$$

Donde $J^p(w)$ es la matriz jacobiana del vector de errores $E^p(w)$ evaluado en w , e I es la matriz identidad. El vector de errores $E^p(w)$ corresponda al error de la red para el patrón p : $E^p(w) = T^p - O^p(w)$, siendo T el objetivo y O la salida. El parámetro μ incrementa o decrece en cada paso. Si el error es reducido, entonces μ se divide por un factor β , mientras que se multiplica en caso contrario. El algoritmo LM calcula la salida de la red, el vector de errores, y el Jacobiano para cada patrón. Luego, calcula mediante Δw mediante (A.1) y recalcula el error con $w + \Delta w$ como los pesos de la red.

Código para filtrado de datos

Para filtrar los datos, se programa una macro en *Visual Basic for Applications* (VBA).

```
Dim ltrDest As Long
Dim numHr As Long
Dim numDat As Long
Dim numDest As Long
Dim i As Long
Dim hora As Integer
Dim LMinute As Integer
```

```
ubiHr = InputBox("Ingrese coordenadas de datos horarios", "Ubicacion datos")
ltrHr = ActiveSheet.Range(ubiHr).Column
numHr = ActiveSheet.Range(ubiHr).Row
hora = Minute(ActiveSheet.Cells(numHr, ltrHr))

ubiDat = InputBox("Ingrese coordenadas de datos a analizar", "Ubicacion datos")
ltrDat = ActiveSheet.Range(ubiDat).Column
numDat = ActiveSheet.Range(ubiDat).Row

ubiDest = InputBox("Ingrese primera celda donde quiera dejar los datos", "Destino")
ltrDest = ActiveSheet.Range(ubiDest).Column
numDest = ActiveSheet.Range(ubiDest).Row

Do While ActiveSheet.Cells(numHr, ltrHr) <> ""
  If Minute(ActiveSheet.Cells(numHr, ltrHr)) = 0 Then
    ActiveSheet.Cells(numDest, ltrDest) = ActiveSheet.Cells(numDat, ltrDat)
    ActiveSheet.Cells(numDest, ltrDest + 1) = ActiveSheet.Cells(numDat, ltrDat + 1)
    ActiveSheet.Cells(numDest, ltrDest + 2) = ActiveSheet.Cells(numDat, ltrDat + 2)
    ActiveSheet.Cells(numDest, ltrDest + 3) = ActiveSheet.Cells(numDat, ltrDat + 3)
    ActiveSheet.Cells(numDest, ltrDest + 4) = ActiveSheet.Cells(numDat, ltrDat + 4)
    ActiveSheet.Cells(numDest, ltrDest + 5) = ActiveSheet.Cells(numDat, ltrDat + 5)
    ActiveSheet.Cells(numDest, ltrDest + 6) = ActiveSheet.Cells(numDat, ltrDat + 6)
    ActiveSheet.Cells(numDest, ltrDest + 7) = ActiveSheet.Cells(numDat, ltrDat + 7)
    ActiveSheet.Cells(numDest, ltrDest + 8) = ActiveSheet.Cells(numDat, ltrDat + 8)
    ActiveSheet.Cells(numDest, ltrDest + 9) = ActiveSheet.Cells(numDat, ltrDat + 9)
    numDest = numDest + 1
  End If
  numDat = numDat + 1
  numHr = numHr + 1
Loop
End Sub
```

Código para calibración y predicción utilizando RNA

```
clear
close all
clc
plt=0;
format shortG

%dependiendo de la variable, es el dataset a cargar
```

Apéndice A. Anexos

```
inputVar = input('Ingrese variable a predecir, siendo 2: GHI, 4:Temp, 5:RH y 6:pot ');
if inputVar == 2
load NARXAutomatico
elseif inputVar == 6
load NARXAutomatico
elseif inputVar == 4
load NARXAutomatico2
elseif inputVar == 5
load NARXAutomatico2
end

tStart = tic;
%dependiendo de la variable escogida, es que se toman las variables
%exogenas que aparecen
if inputVar == 2
    exogenas = [3 4 5];
elseif inputVar == 4
    exogenas = [3];
elseif inputVar == 5
    exogenas = [3];
elseif inputVar == 6
    exogenas = [2 3 4 5];
end
% Dado que los datos tenian la fecha incorporada, es que se pueden
% localizar de forma sencilla
fecha = input('Ingrese fecha del anio que quiera predecir en formato dd-MM-yyyy: ', 's')
fechaMatlab = datetime(fecha, 'InputFormat', 'dd-MM-yyyy');
realTotal = [];
predichoTotal = [];
statAcum = [];
configRedes = [];
%se hacen predicciones para 5 dias, un "1" en excel considera un dia entero
%y fracciones se consideran horas, minutos y segundos
for dia = 0:4
fechaX1 = exceltime(fechaMatlab) + dia;
% obtencion de indice para fecha DESDE entrenamiento
condicion = false;
iFechaDE = 0;
fechaDE = fechaX1 - 100; % es el numero de dias a retroceder
while condicion == false
    iFechaDE = iFechaDE + 1;
    if datos(iFechaDE,1) == fechaDE
        condicion = true;
    end
end
% obtencion de indice para fecha HASTA entrenamiento
condicion = false;
iFechaHE = 0;
fechaHE = fechaX1 - 3; % es el numero de dias a generalizar
while condicion == false
    iFechaHE = iFechaHE + 1;
```

Apéndice A. Anexos

```
    if datos(iFechaHE,1) == fechaHE
        condicion = true;
    end
end
iFechaHE = iFechaHE - 1;
iFechaDC = iFechaHE + 1;

% obtencion de indice para fecha HASTA calibracion
condicion = false;
iFechaHC = 0; %iFecha para localizar
while condicion == false
    iFechaHC = iFechaHC + 1;
    if datos(iFechaHC,1) == fechaX1
        condicion = true;
    end
end
iFechaHC = iFechaHC - 1; %para guardar el valor anterior

% indice de fecha HASTA ahead
condicion = false;
iFechaHA = 0;
while condicion == false
    iFechaHA = iFechaHA + 1;
    if datos(iFechaHA,1) == fechaX1 + 1
        condicion = true;
    end
end
iFechaHA = iFechaHA - 1;

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% LLENADO DE INPUT Y TARGET ENTRENAMIENTO %%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
inputEntrenamiento = [];
targetEntrenamiento = [];
targetEntrenamiento = datos(iFechaDE:iFechaHE,inputVar);
for n = 1:size(exogenas,2)
    inputEntrenamiento = [inputEntrenamiento datos(iFechaDE:iFechaHE,exogenas(n))];
end
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% INPUT Y REAL CALIBRACION %%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
inputCalibracion = [];
realCalibracion = [];
realCalibracion = datos(iFechaDC:iFechaHC,inputVar);
for n = 1:size(exogenas,2)
    inputCalibracion = [inputCalibracion datos(iFechaDC:iFechaHC,exogenas(n))];
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% INPUT dayAhead %%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
inputAhead = [];
realAhead = [];
iFechaDA = iFechaHC + 1;
realAhead = datos(iFechaDA:iFechaHA,inputVar);
```


Apéndice A. Anexos

```
[ Yc Xcf Acf ] = netc(Xc,Xci,Aci);
Ec = gsubtract(Tc,Yc);
yc = cell2mat(Yc);
tc = to;
NMSEc = mse(Ec) /var(tc,1);
Xc2 = tonndata(inputCalibracion,false,false);
[Yc2,Xcf2,Acf2] = netc(Xc2,Xcf,Acf);
yc2 = cell2mat(Yc2);
error = abs(realCalibracion' - yc2);
matErrores(d,dT,hiddenLayerSize) = NMSEc;
RMSEPred = sqrt(mean((yc2 - realCalibracion').^2));
%pearsonCalibracion = corr(realCalibracion,yc2');
%R2 = pearsonCalibracion^2;
matErroresPred(d,dT,hiddenLayerSize) = RMSEPred;
    end
end
end

matErrores;
matErroresPred;

[minM, idx] = min(matErroresPred(:));
[n, m ,t] = ind2sub(size(matErroresPred),idx);
configRedes = [configRedes [n;m;t]];
mensaje = sprintf('La mejor prediccion segun valores RMSE tiene un delay input de %d, de
y %d neuronas en la capa oculta', n,m,t);

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%Red neuronal que mejor generaliza los datos de la
%calibracion %%%%%%%%%%%
inputDelays = 1:n;
feedbackDelays = 1:m;
neuronasOculata = t;
neto = narxnet(inputDelays,feedbackDelays,neuronasOculata,'open');
neto.divideFcn = 'divideblock';
neto.trainFcn = 'trainlm';
%view(neto)
[ Xo,Xoi,Aoi,To ] = preparets(neto,X,{},T);
to = cell2mat( To );
xo = cell2mat( Xo );
%plt = plt+1; figure(plt), hold on
%plot( d+1:N, to, 'LineWidth', 2 );

rng( 'default' )
[ neto, tro, Yo, Eo, Aof, Xof ] = train( neto, Xo, To, Xoi, Aoi );

NMSEo = mse( Eo ) /var( to,1 );
yo = cell2mat( Yo );

[ netc Xci Aci ] = closeloop(neto,Xoi,Aoi);
```

```

    %view(netc);
    [Xc,Xci,Aci,Tc] = preparets(netc,X,{},T);
    netc.divideFcn = 'divideblock';
    %[%netggc,tr2,Yc,Ec,Afc,Xfc] = train(netggc,Xc,Tc,Xci,Aci);
    netc.trainFcn = 'trainlm';
    %[%netc,tr2,Yc,Ec,Acf,Xcf] = train(netc,Xc,Tc,Xci,Aci);
    [ Yc Xcf Acf ] = netc(Xc,Xci,Aci);
    Ec = gsubtract(Tc,Yc);
    yc = cell2mat(Yc);
    tc = to;
    NMSEc = mse(Ec) /var(tc,1);
    Xc2 = tonndata(inputCalibracion,false,false);
    [ Yc2, Xcf2, Acf2 ] = netc( Xc2, Xcf, Acf );
    yc2 = cell2mat(Yc2);
    error = ( yc2 - realCalibracion');
    plt = plt + 1; figure(plt),
    subplot(2,1,1)
    hold on
    plot(yc2,'--k','LineWidth',1)
    plot(realCalibracion,'k','LineWidth',1)
    str = sprintf('Calibracion con delay input/target = %d/%d y H = %d',n,m,t);
    title(str);
    legend('Prediccion','Valor real')
    xhandle=xlabel('Pasos');
    yhandle=ylabel('Potencia (W)');
    set(xhandle,'FontSize',11)
    set(xhandle,'Fontname','Timesnewroman')
    subplot(2,1,2)
    stem(error,'k','LineWidth',1)
    xhandle2=xlabel('Pasos');
    yhandle2=ylabel('Error (W)');
    set(xhandle2,'FontSize',11)
    set(xhandle2,'Fontname','Timesnewroman')
    title('Errores')

    matErrores(d,dT,hiddenLayerSize) = NMSEc;
    RMSEPred = sqrt(mean((yc2 - realCalibracion').^2));
    matErroresPred(d,dT,hiddenLayerSize) = RMSEPred;

    %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% PROPAGACION MISMA RED ENTRENADA PARA
    %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% PREDICCIÓN %
    Xc2 = tonndata(inputAhead,false,false);
    [Yc2,Xcf2,Acf2] = netc(Xc2,Xcf,Acf);
    yc2 = cell2mat(Yc2);
    error = yc2 - realAhead';
    plt = plt + 1; figure(plt),
    subplot(2,1,1)
    hold on
    plot(yc2,'--k','LineWidth',1)
    plot(realAhead,'k','LineWidth',1)
    str = sprintf('Prediccion con delay input/target = %d/%d , y H = %d',n,m,t);

```

```

title(str);
legend( 'Prediccion', 'Valor real' )
xhandle=xlabel('Pasos');
yhandle=ylabel('GHI (W/m2) ');
set(xhandle,'FontSize',11)
set(xhandle,'Fontname','Timesnewroman')
subplot(2,1,2)
stem(error,'k','LineWidth',1)
xhandle2=xlabel('Pasos');
%yhandle2=ylabel('GHI (W/m2) ');
set(xhandle2,'FontSize',11)
set(xhandle2,'Fontname','Timesnewroman')
title( 'Errores' )
realTotal = [realTotal realAhead'];
predichoTotal = [predichoTotal yc2];

%%%%%% ESTADISTICOS %%%%%%%%%
RMSE = sqrt(mean((yc2'-realAhead).^2));
RMSEn = RMSE/1400;
pearson = corr(realAhead,yc2');
R2 = pearson^2;
RMQE = (mean((yc2'-realAhead).^4))^(1/4);
RMQEn = RMQE/1400;
MAE = sum(abs(yc2'-realAhead))/length(realAhead);
MBE = mean((yc2'-realAhead));
MaxAE = max(abs(yc2'-realAhead));
estadisticos = [RMSE;RMQE;RMSEn;RMQEn;R2;MAE;MBE;MaxAE];
statAcum = [statAcum estadisticos]
end
%%%%% GRAFICO TOTAL
error = predichoTotal - realTotal ;
plt = plt + 1; figure(plt),
subplot(2,1,1)
hold on
plot(predichoTotal,'--k','LineWidth',1)
plot(realTotal,'k','LineWidth',1)
legend( 'Prediccion', 'Valor real' )
xhandle=xlabel('Pasos');
yhandle=ylabel('Potencia (W) ');
set(xhandle,'FontSize',14)
set(xhandle,'Fontname','Helvetica')
set(yhandle,'FontSize',14)
set(yhandle,'Fontname','Helvetica')
subplot(2,1,2)
stem(error,'k','LineWidth',1)
xhandle2=xlabel('Pasos');
yhandle2=ylabel('Error (W) ');
set(xhandle,'FontSize',14)
set(xhandle,'Fontname','Helvetica')
set(yhandle,'FontSize',14)
set(yhandle,'Fontname','Helvetica')

```

```
statAcum
configRedes
% The End
tEnd = toc(tStart);
fprintf('La simulacion tomo %d minutos y %f segundos\n', floor(tEnd/60), rem(tEnd,60));
load gong.mat;
gong = audioplayer(y, Fs);
play(gong);
realTotal = realTotal';
predichoTotal = predichoTotal';
```

Código para evaluar errores

```
plt = 0;
RMSE = sqrt(mean((predichoTotal - realTotal).^2))
RMSEn = RMSE/1400
pearson = corr(predichoTotal, realTotal)
R2 = pearson^2
RMQE = (mean((predichoTotal - realTotal).^4))^(1/4)
RMQEn = RMQE/1400
MAE = sum(abs(predichoTotal - realTotal))/length(realTotal)
MBE = mean((predichoTotal - realTotal))
MaxAE = max(abs(predichoTotal - realTotal))

errorTotal = predichoTotal - realTotal;
errorTotal = errorTotal;
asimetria = skewness(errorTotal)
curtosis = kurtosis(errorTotal)
[f,xi] = ksdensity(errorTotal);
plt = plt + 1;
figure(plt)
plot(xi,f , 'k', 'LineWidth',1);
xhandle=xlabel('Error');
yhandle=ylabel('Densidad de probabilidad');

error = predichoTotal - realTotal ;
plt = plt + 1; figure(plt),
subplot(2,1,1)
hold on
plot(predichoTotal, '--k', 'LineWidth',1)
plot(realTotal, 'k', 'LineWidth',1)
%title(str);
%title('Prediccion al dia siguiente')
legend('Prediccion', 'Valor real')
xhandle=xlabel('Pasos');
yhandle=ylabel('Potencia (W)');
set(xhandle, 'FontSize',14)
```

```
set(xhandle, 'Fontname', 'Helvetica')
set(yhandle, 'FontSize', 14)
set(yhandle, 'Fontname', 'Helvetica')
subplot(2,1,2)
stem(error, 'k', 'LineWidth', 1)
xhandle2=xlabel('Pasos');
yhandle2=ylabel('Error (W)');
set(xhandle2, 'FontSize', 14)
set(xhandle2, 'Fontname', 'Helvetica')
set(yhandle2, 'FontSize', 14)
set(yhandle2, 'Fontname', 'Helvetica')
```

Calibración de RNA para predicción de variables meteorológicas

GHI Días despejados

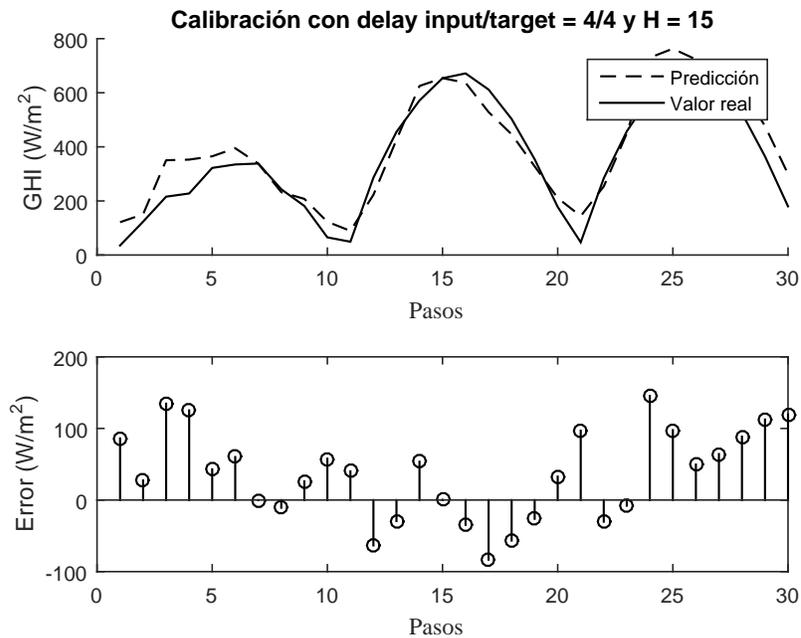


Figura A.1: Calibración de la mejor red neuronal escogida para predecir la radiación del 23 de abril del 2015

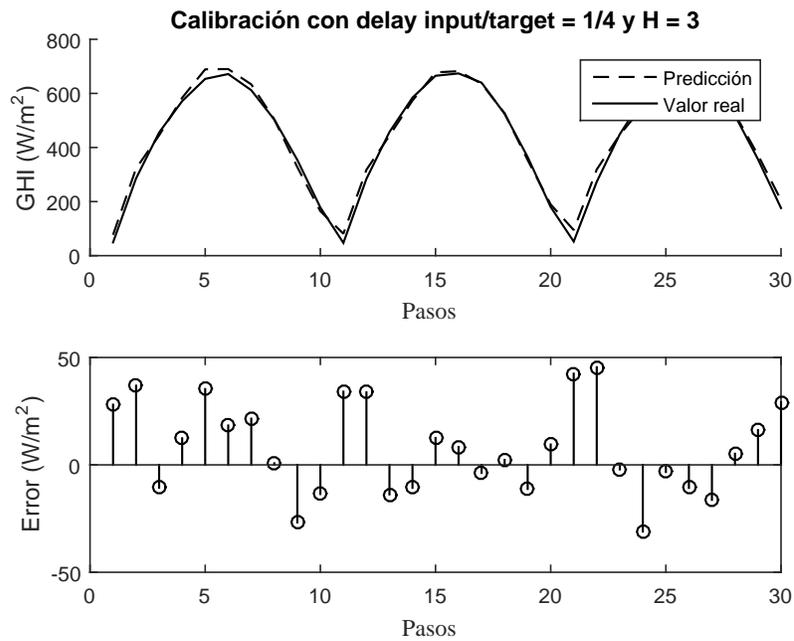


Figura A.2: Calibración de la mejor red neuronal escogida para predecir la radiación del 24 de abril del 2015

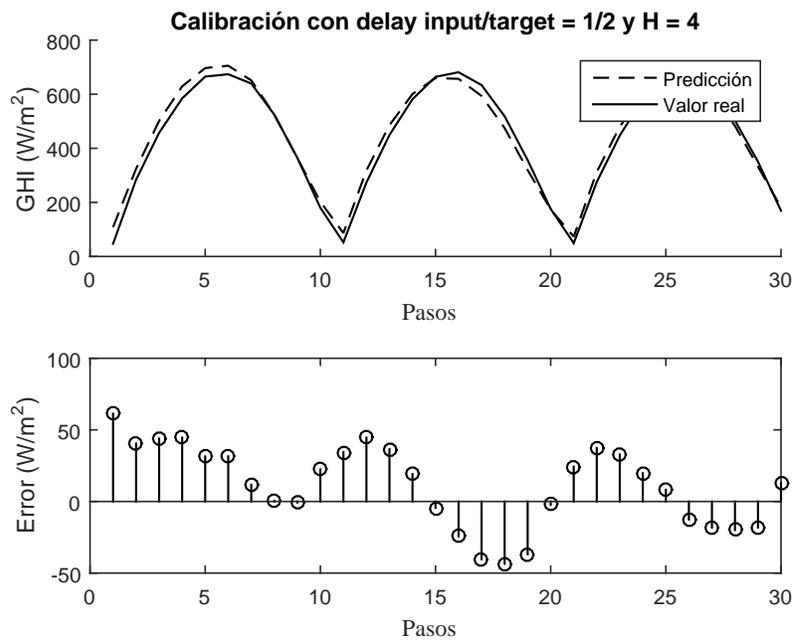


Figura A.3: Calibración de la mejor red neuronal escogida para predecir la radiación del 25 de abril del 2015

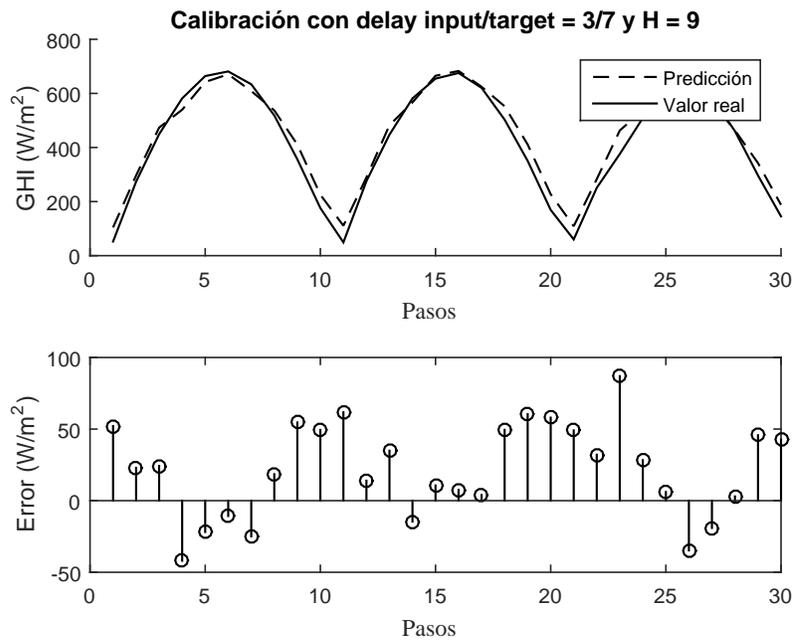


Figura A.4: Calibración de la mejor red neuronal escogida para predecir la radiación del 26 de abril del 2015

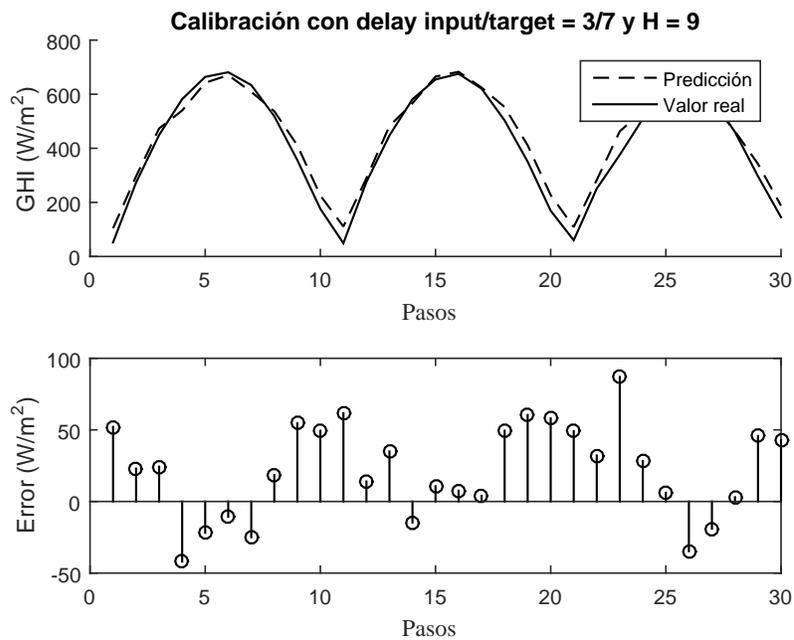


Figura A.5: Calibración de la mejor red neuronal escogida para predecir la radiación del 27 de abril del 2015

Temperatura días despejados

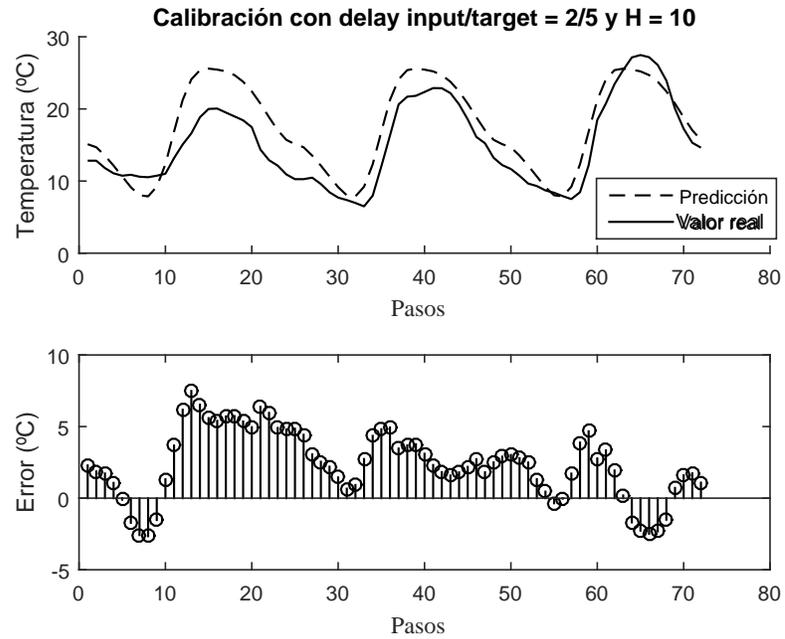


Figura A.6: Calibración de la mejor red neuronal escogida para predecir la temperatura del 23 de abril del 2015

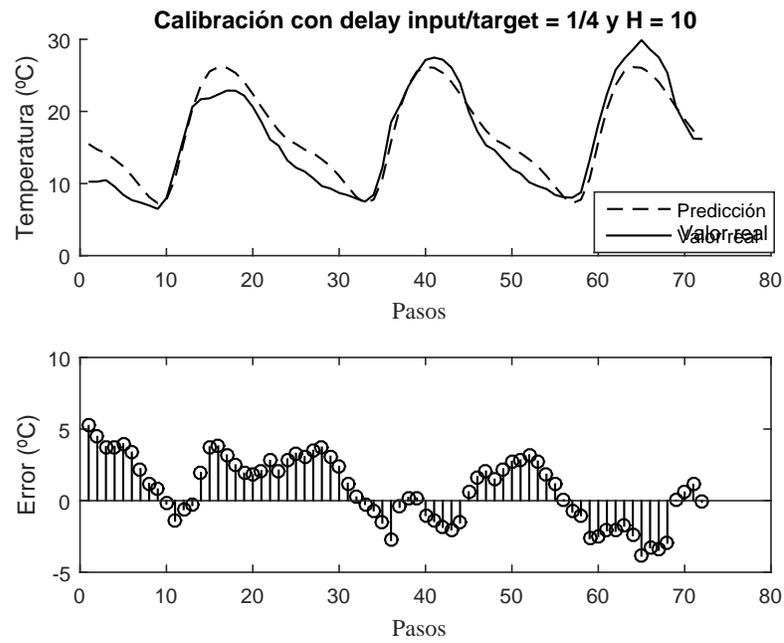


Figura A.7: Calibración de la mejor red neuronal escogida para predecir la temperatura del 24 de abril del 2015

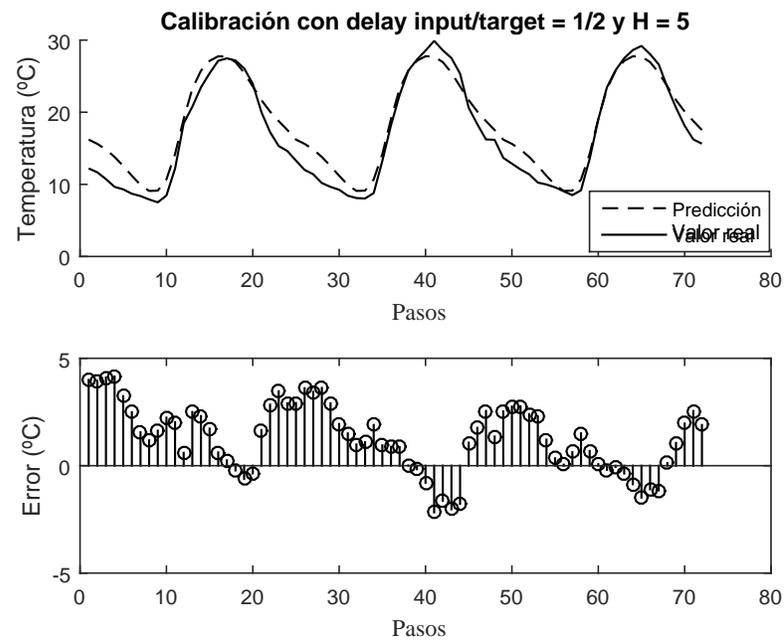


Figura A.8: Calibración de la mejor red neuronal escogida para predecir la temperatura del 25 de abril del 2015

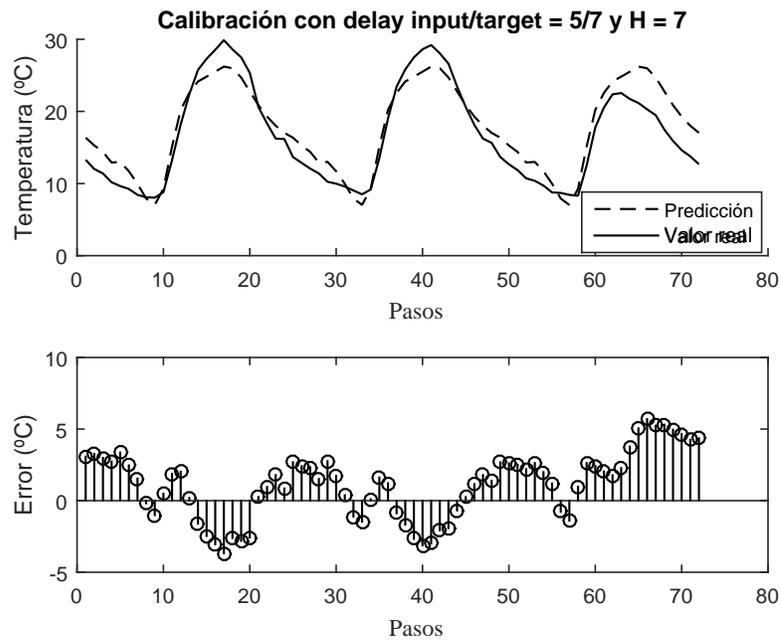


Figura A.9: Calibración de la mejor red neuronal escogida para predecir la temperatura del 26 de abril del 2015

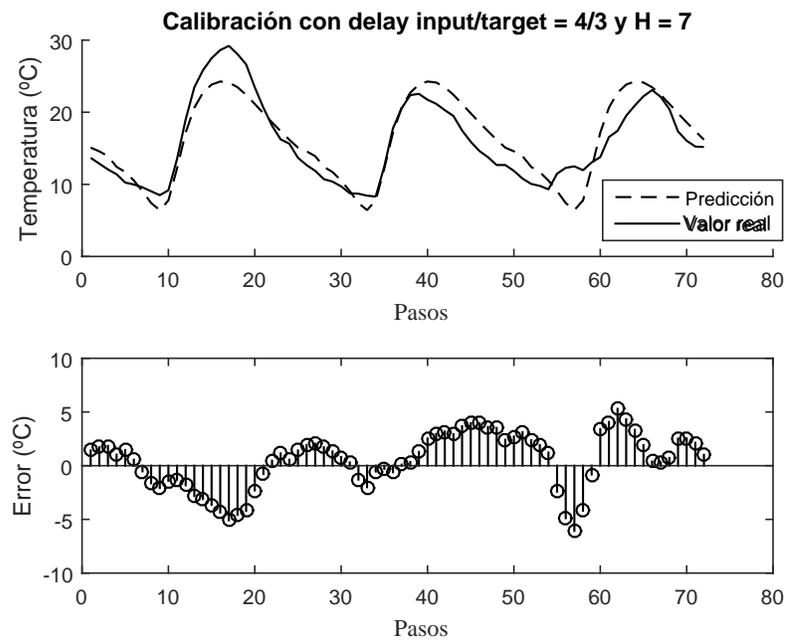


Figura A.10: Calibración de la mejor red neuronal escogida para predecir la temperatura del 27 de abril del 2015

Humedad relativa días despejados

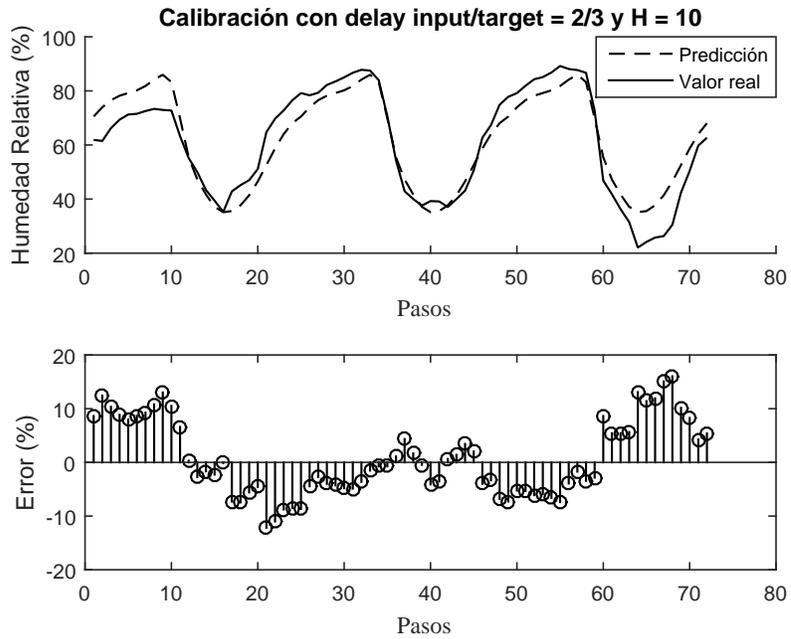


Figura A.11: Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 23 de abril del 2015

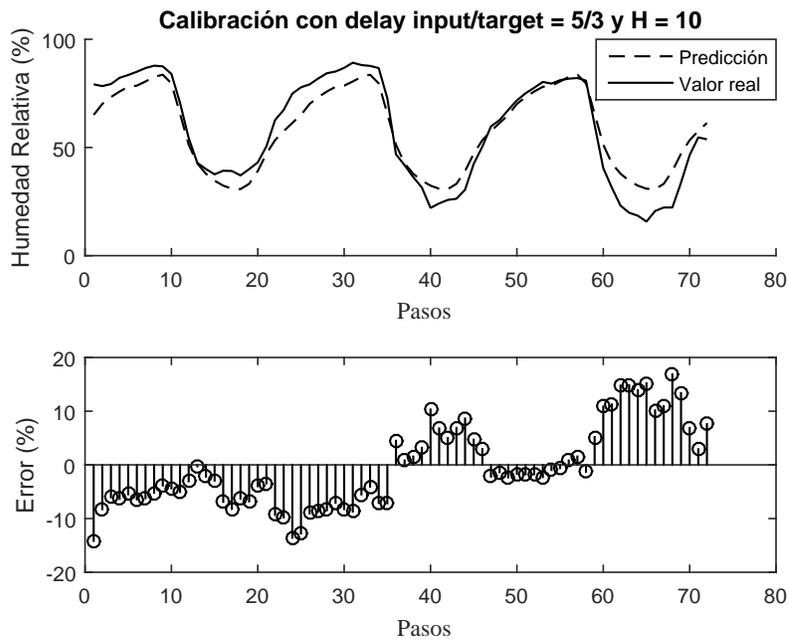


Figura A.12: Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 24 de abril del 2015

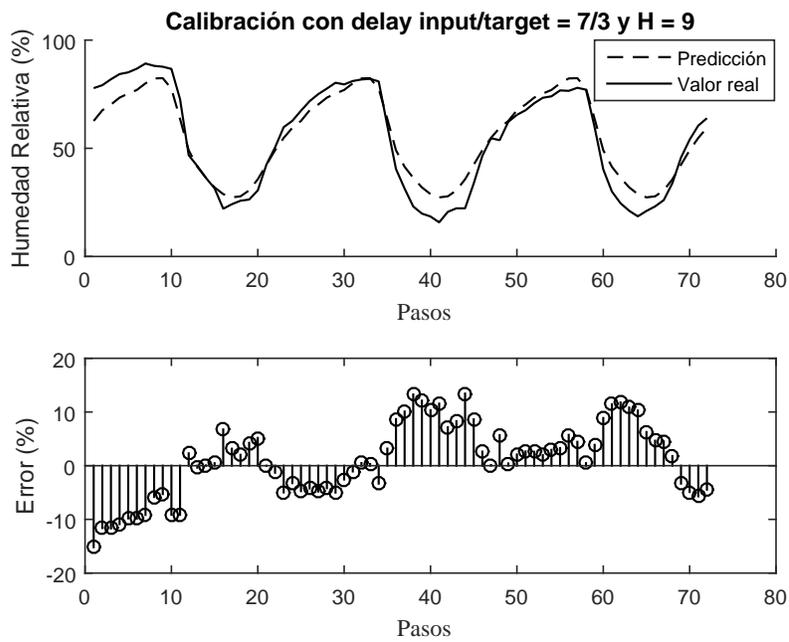


Figura A.13: Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 25 de abril del 2015

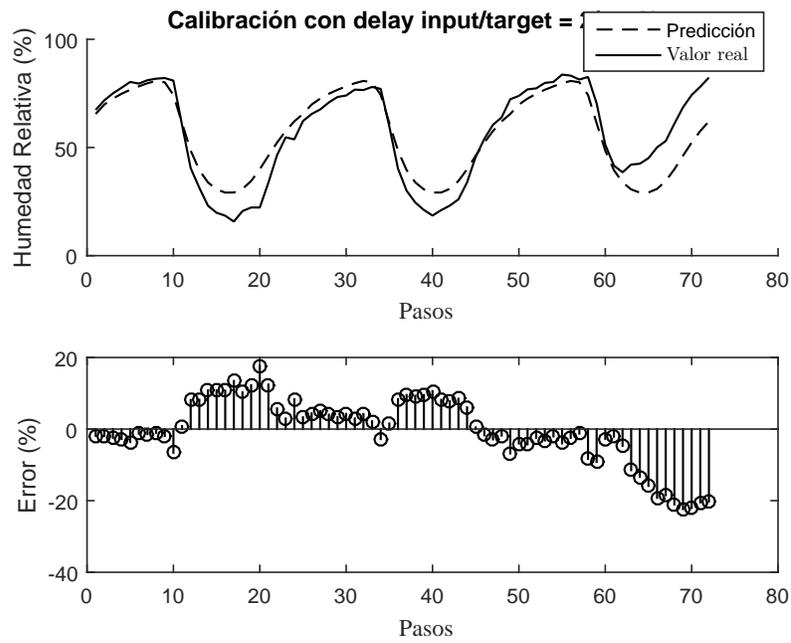


Figura A.14: Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 26 de abril del 2015

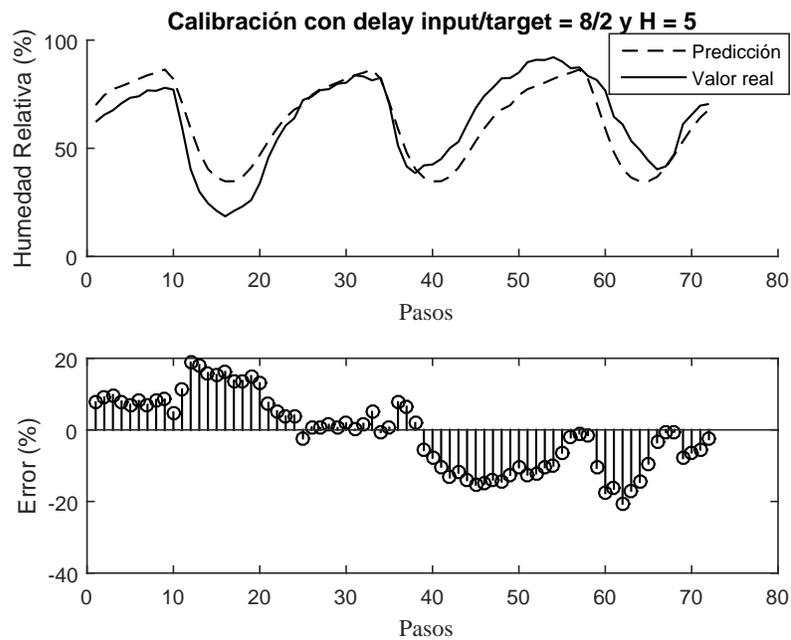


Figura A.15: Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 27 de abril del 2015

GHI Días nublados

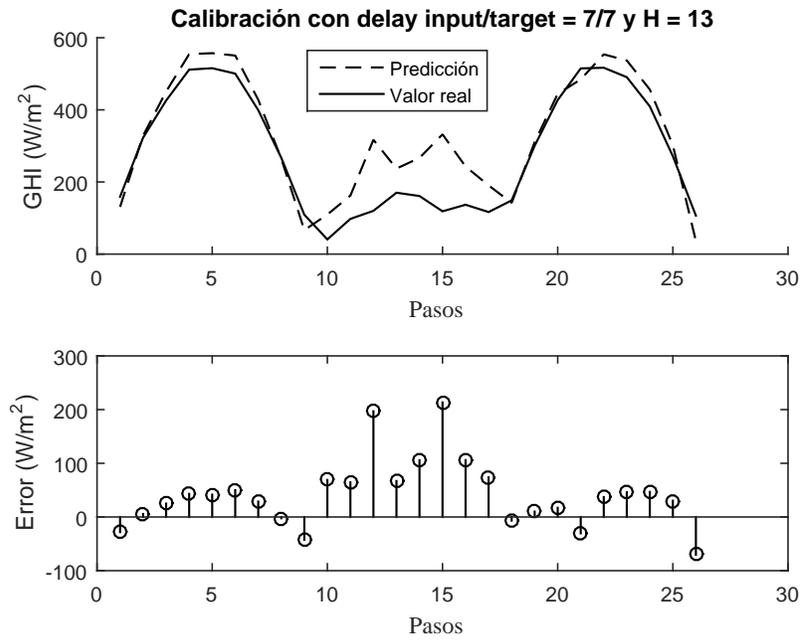


Figura A.16: Calibración de la mejor red neuronal escogida para predecir la radiación del 17 de julio del 2015

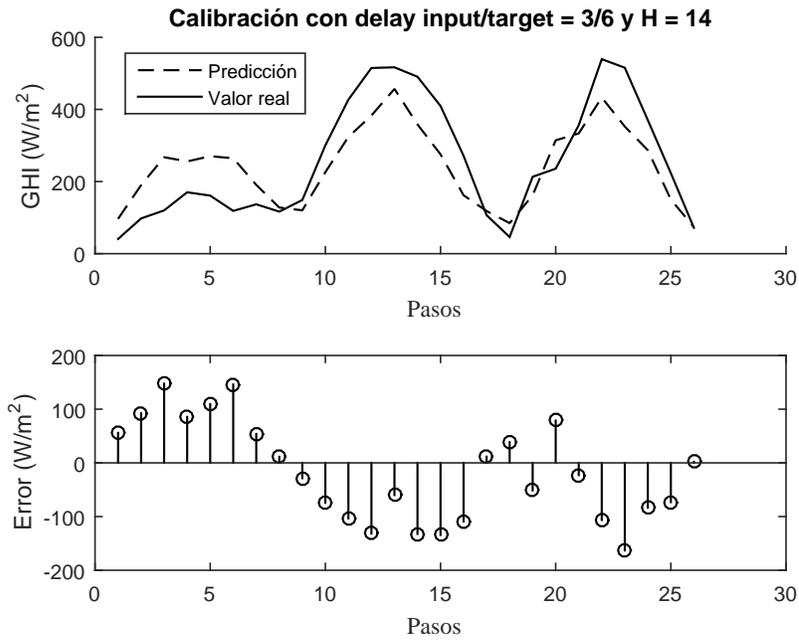


Figura A.17: Calibración de la mejor red neuronal escogida para predecir la radiación del 18 de julio del 2015

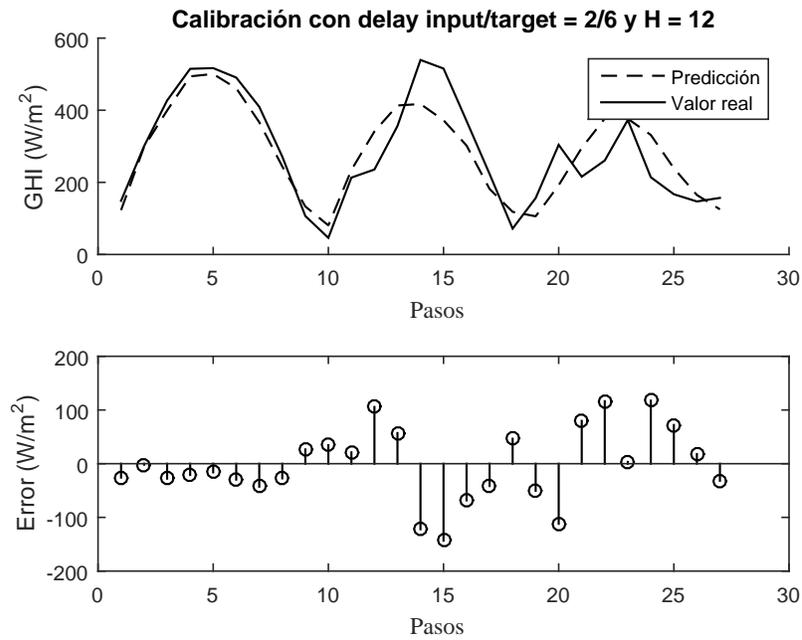


Figura A.18: Calibración de la mejor red neuronal escogida para predecir la radiación del 19 de julio del 2015

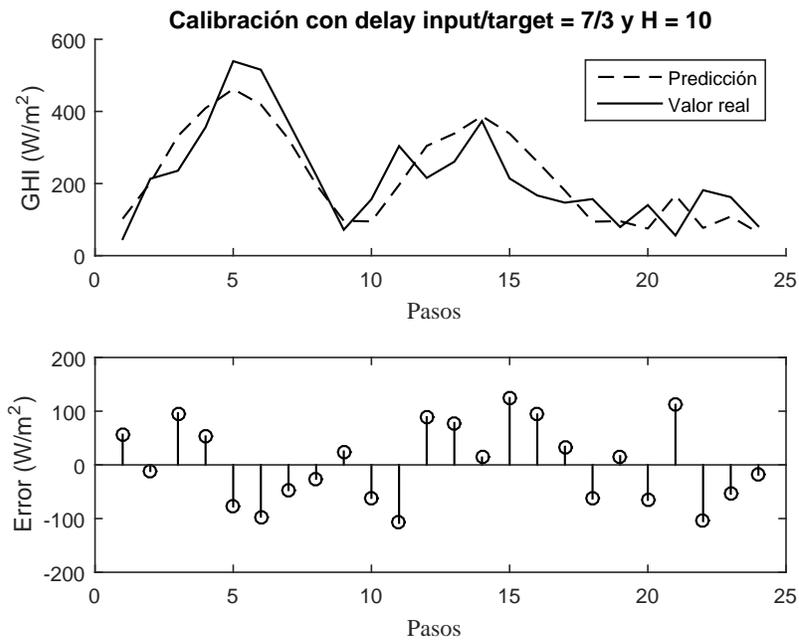


Figura A.19: Calibración de la mejor red neuronal escogida para predecir la radiación del 20 de julio del 2015

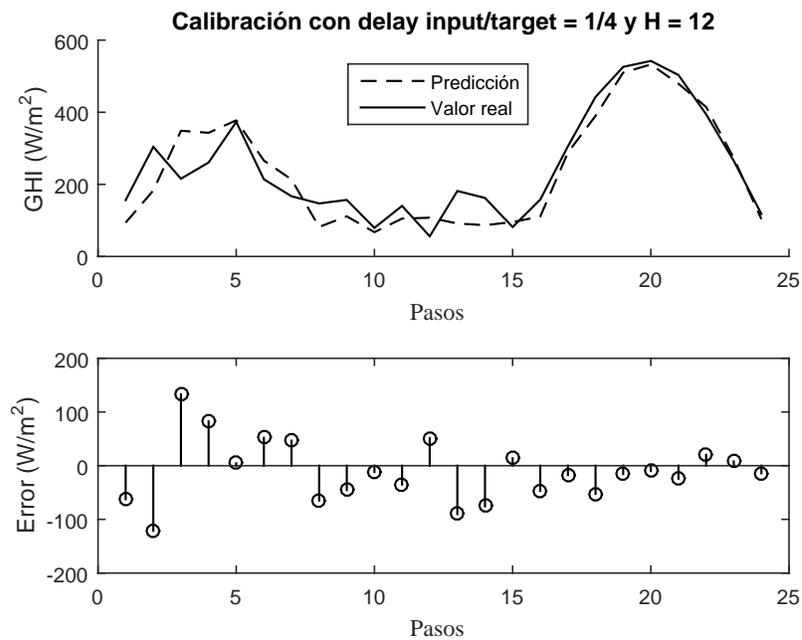


Figura A.20: Calibración de la mejor red neuronal escogida para predecir la radiación del 21 de julio del 2015

Temperatura días nublados

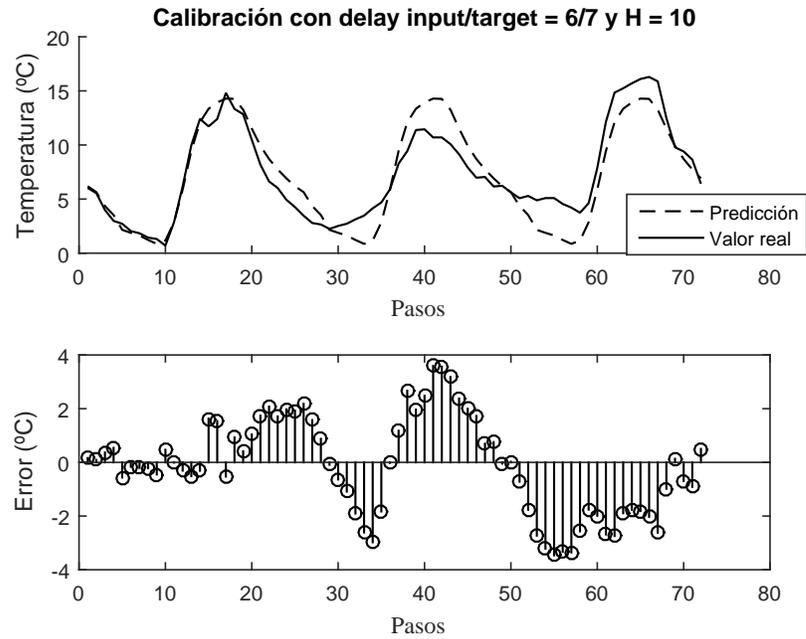


Figura A.21: Calibración de la mejor red neuronal escogida para predecir la temperatura del 17 de julio del 2015

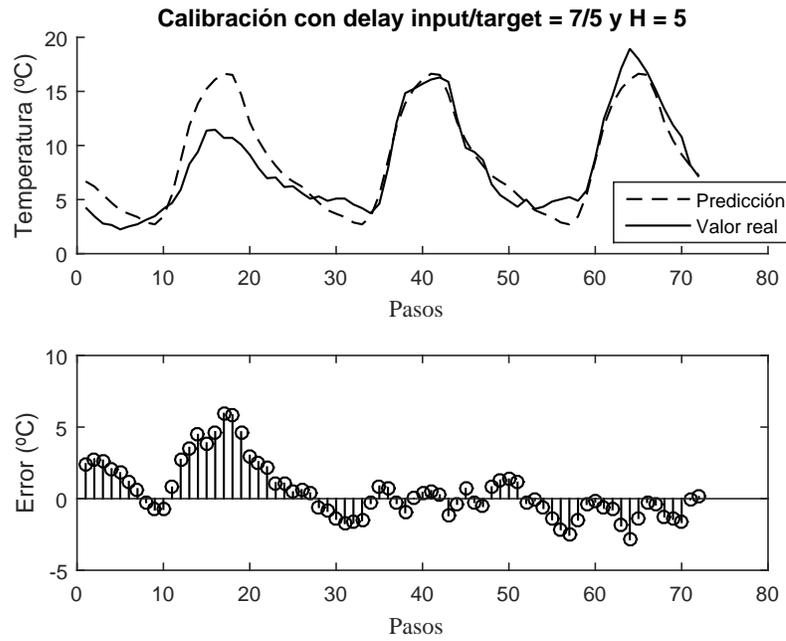


Figura A.22: Calibración de la mejor red neuronal escogida para predecir la temperatura del 18 de julio del 2015

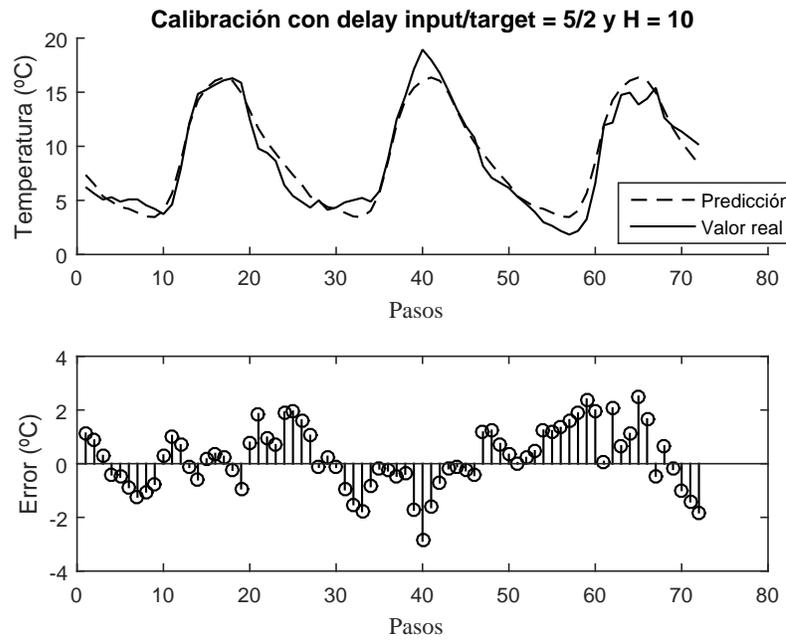


Figura A.23: Calibración de la mejor red neuronal escogida para predecir la temperatura del 19 de julio del 2015

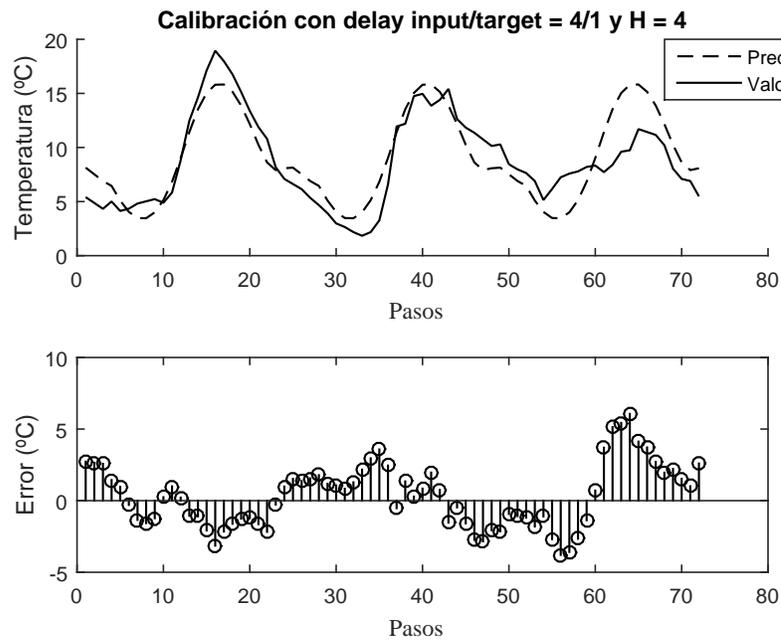


Figura A.24: Calibración de la mejor red neuronal escogida para predecir la temperatura del 20 de julio del 2015

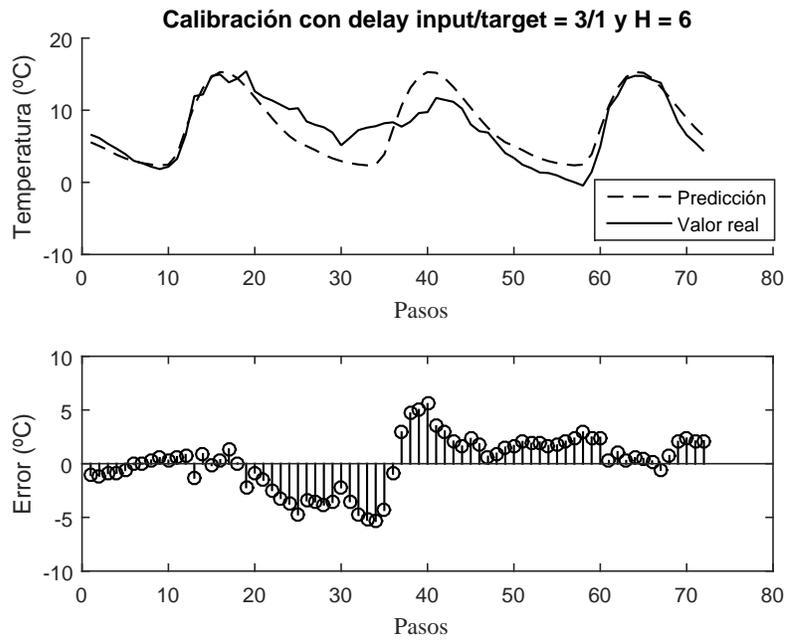


Figura A.25: Calibración de la mejor red neuronal escogida para predecir la temperatura del 21 de julio del 2015

Humedad relativa días nublados

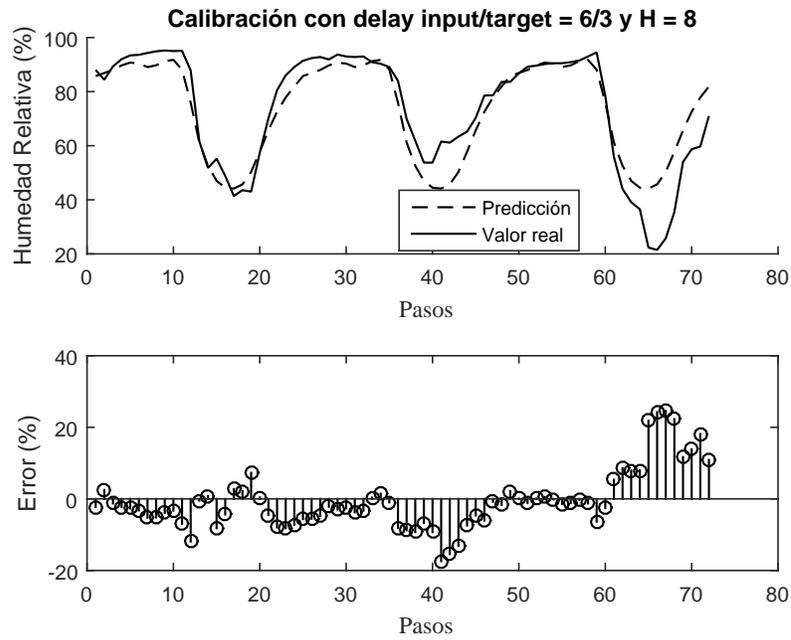


Figura A.26: Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 17 de julio del 2015

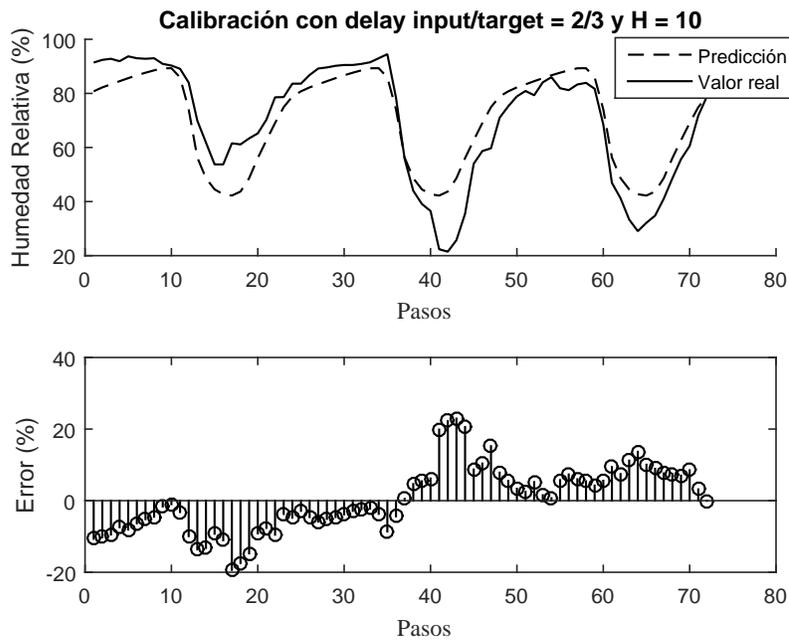


Figura A.27: Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 18 de julio del 2015

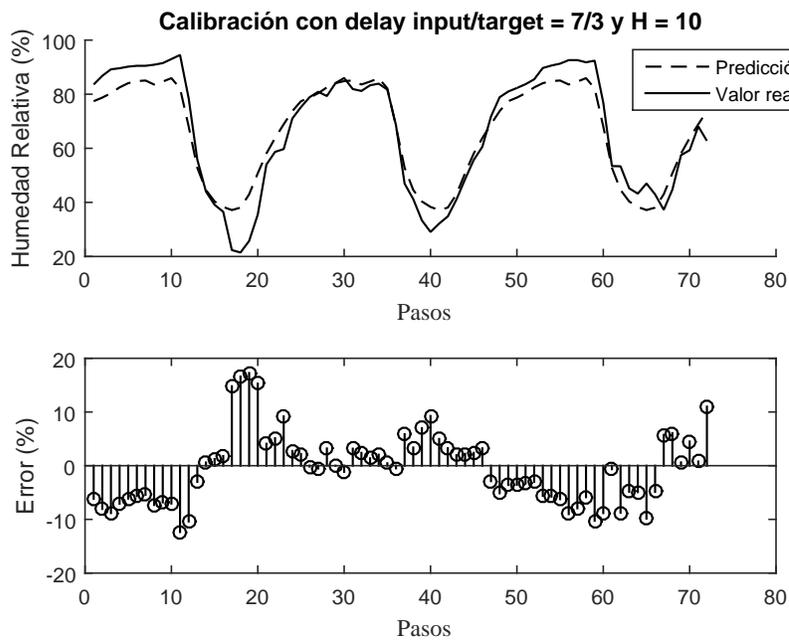


Figura A.28: Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 19 de julio del 2015

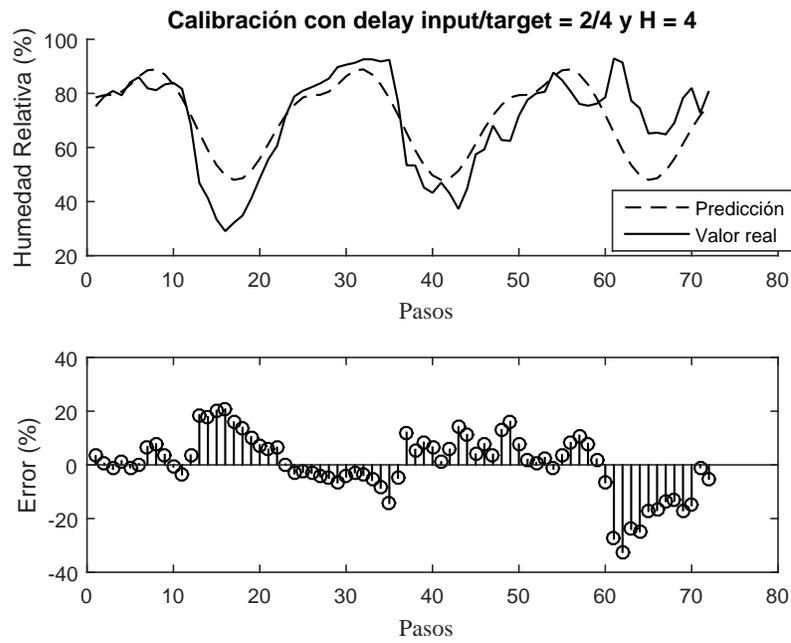


Figura A.29: Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 20 de julio del 2015

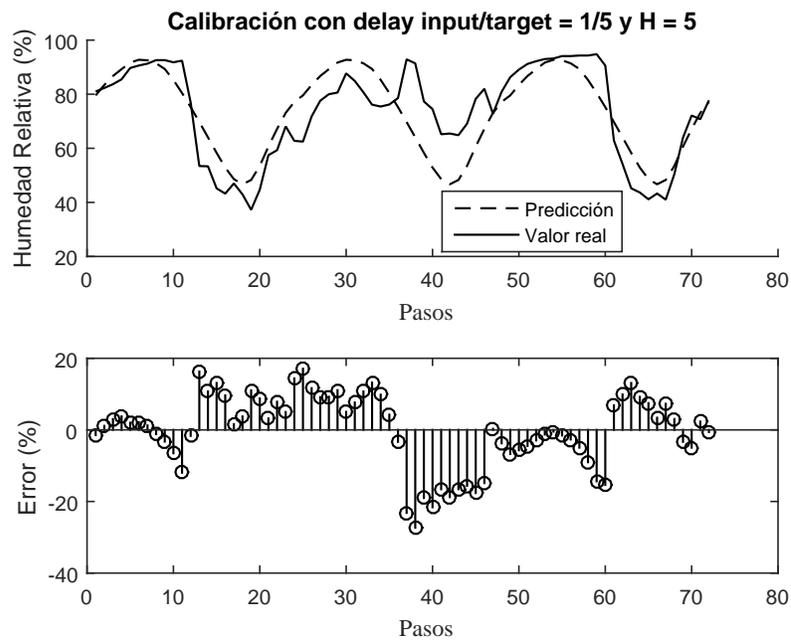


Figura A.30: Calibración de la mejor red neuronal escogida para predecir la humedad relativa del 21 de julio del 2015

Calibración de RNA para predicción de potencia

Días despejados

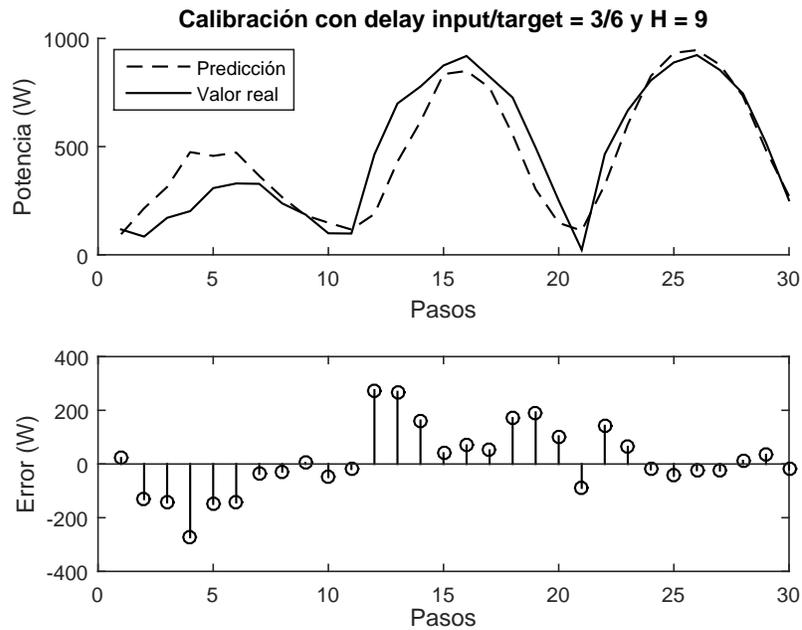


Figura A.31: Calibración de la mejor red neuronal escogida para predecir la potencia del 23 de abril del 2015

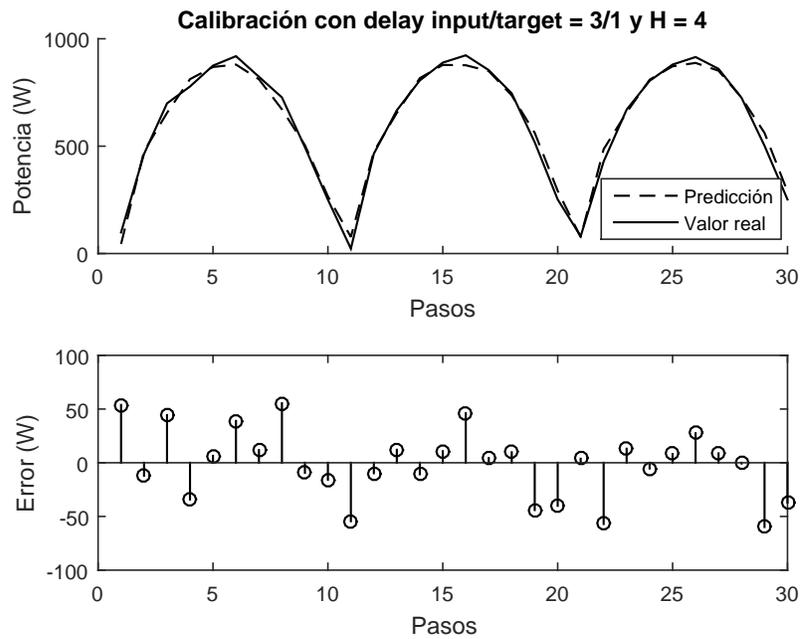


Figura A.32: Calibración de la mejor red neuronal escogida para predecir la potencia del 24 de abril del 2015

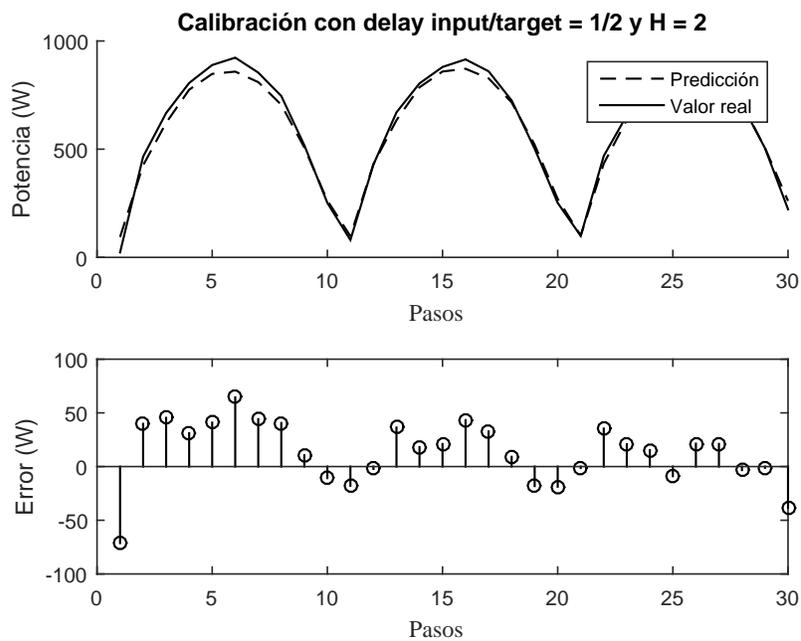


Figura A.33: Calibración de la mejor red neuronal escogida para predecir la potencia del 25 de abril del 2015

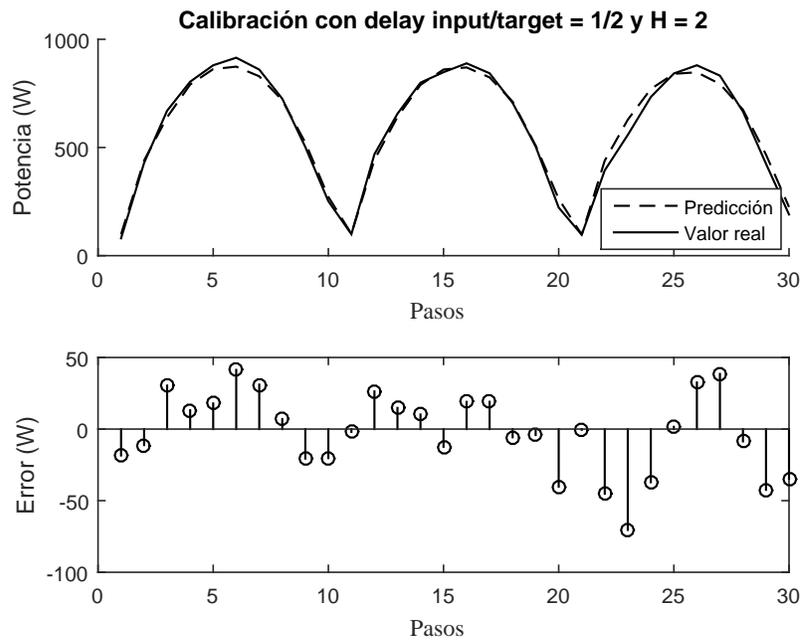


Figura A.34: Calibración de la mejor red neuronal escogida para predecir la potencia del 26 de abril del 2015

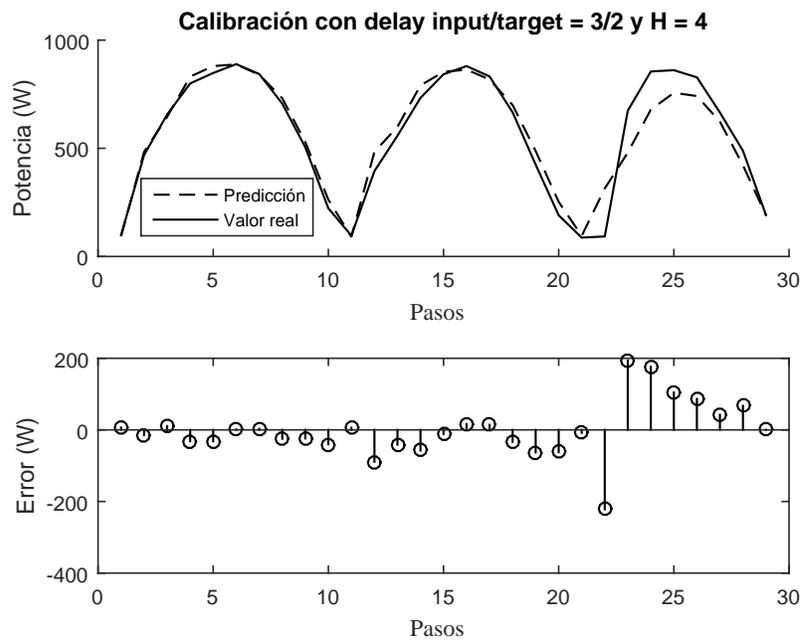


Figura A.35: Calibración de la mejor red neuronal escogida para predecir la potencia del 27 de abril del 2015

Días nublados

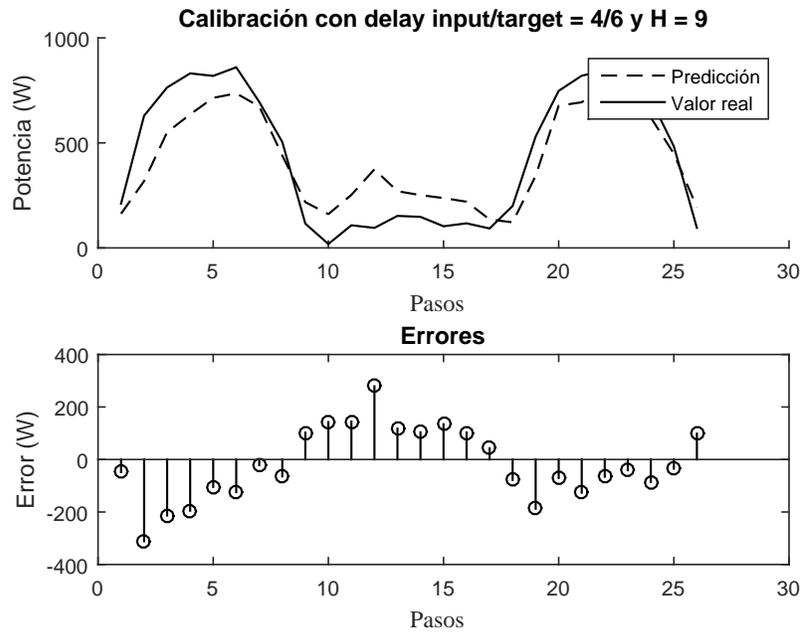


Figura A.36: Calibración de la mejor red neuronal escogida para predecir la potencia del 17 de julio del 2015

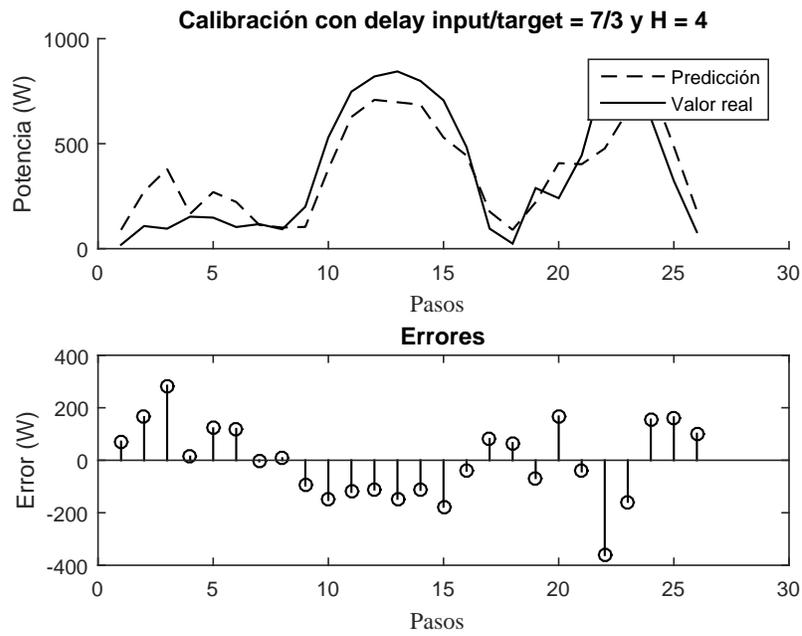


Figura A.37: Calibración de la mejor red neuronal escogida para predecir la potencia del 18 de julio del 2015

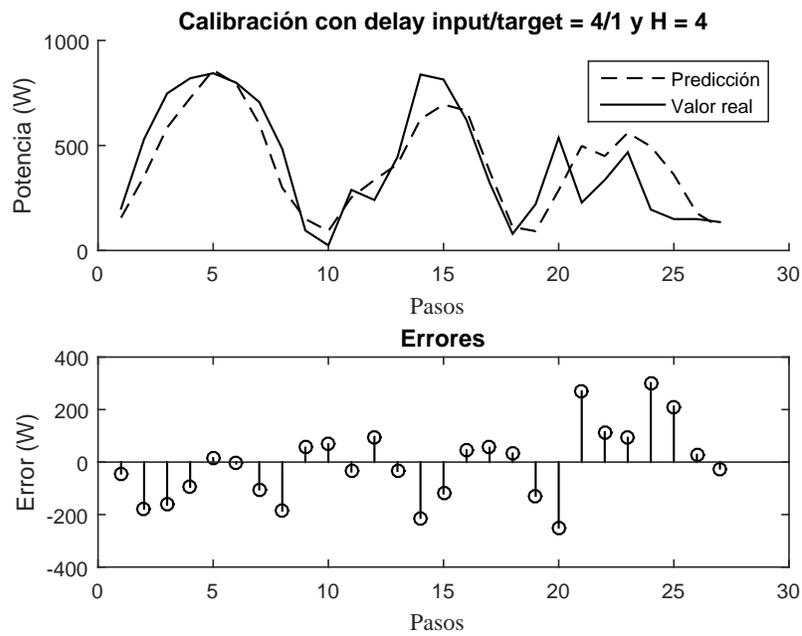


Figura A.38: Calibración de la mejor red neuronal escogida para predecir la potencia del 19 de julio del 2015

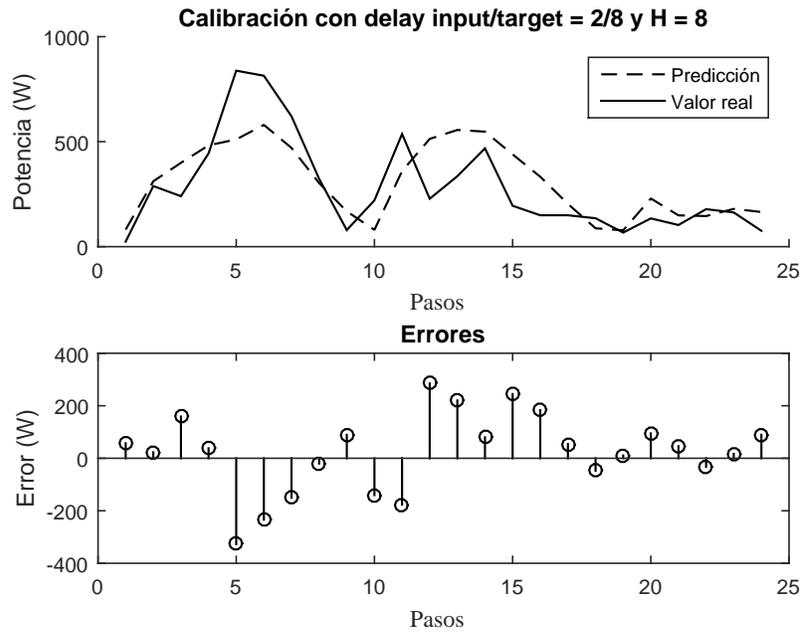


Figura A.39: Calibración de la mejor red neuronal escogida para predecir la potencia del 20 de julio del 2015

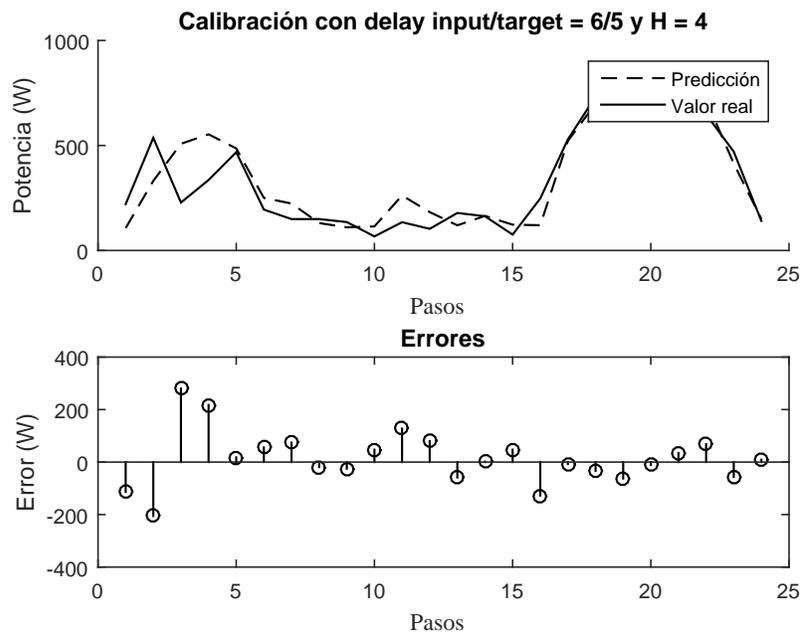


Figura A.40: Calibración de la mejor red neuronal escogida para predecir la potencia del 21 de julio del 2015