

SEP

SECRETARÍA DE
EDUCACIÓN PÚBLICA



SUBSECRETARÍA DE EDUCACIÓN SUPERIOR
TECNOLÓGICO NACIONAL DE MÉXICO
INSTITUTO TECNOLÓGICO DE TUXTLA GUTIÉRREZ



INSTITUTO TECNOLÓGICO DE TUXTLA GUTIÉRREZ

REPORTE RESIDENCIA PROFESIONAL

AGOSTO-DICIEMBRE 2014

CHÁVEZ AVENDAÑO MIGUEL ERNESTO 10270555

ESTUDIO DE TÉCNICAS Y ANÁLISIS COMPARATIVO PARA EL PRONÓSTICO DE LA DISPONIBILIDAD DE ENERGÍA FOTOVOLTAICA

ASESOR INTERNO

ING. ÁNGEL REYES ALBORES

ASESOR EXTERNO

DR. JUAN MANUEL RAMÍREZ ARREDONDO

CENTRO DE INVESTIGACIÓN DE ESTUDIOS AVANZADOS DEL IPN

INGENIERÍA ELÉCTRICA.

9° SEMESTRE

TUXTLA GUTIÉRREZ, CHIAPAS, 30 DE NOVIEMBRE 2014.

ÍNDICE

| | |
|---|----|
| 1. Introducción | 2 |
| 1.1 Antecedentes | 2 |
| 1.2 Estado del arte | 2 |
| 1.3 Justificación..... | 3 |
| 1.4 Objetivos | 4 |
| 1.5 Metodología. | 4 |
| 2.- Fundamento Teórico | 5 |
| 2.1 Predicción de la irradiancia solar: conceptos previos | 5 |
| 2.2 Modelos de predicción de la irradiancia solar | 8 |
| 2.3 Modelos estadísticos clásicos aplicados a la predicción de la irradiancia solar | 11 |
| 2.4 El enfoque ANN para el modelado de series de tiempo..... | 14 |
| 3. Desarrollo | 14 |
| 3.1 Clasificación de los modelos de predicción resolución temporal y espacial | 14 |
| 3.2 Representación Matemática Red Neuronal Autorregresiva NAR..... | 15 |
| 3.3 Manejo de datos y creación de la NAR en Matlab | 16 |
| 3.4 Predicción un paso por delante y múltiple | 19 |
| 4. Resultados y Conclusiones | 20 |
| 4.1 Resultados | 20 |
| 4.2 Conclusión | 28 |
| Referencias Bibliográficas | 29 |
| Anexo A | 33 |
| Funcionamiento del piranometro CMP22 | 33 |

1. Introducción

1.1 Antecedentes

La generación de energía con fuentes renovables ha tenido crecimiento en la producción de energía limpia, además tiene beneficios ambientales. Este tipo de energías no contaminan comparado con la generación convencional de energía eléctrica, tales como de combustibles fósiles. Los recursos renovables, incluyendo energía eólica y fotovoltaica se consideran generación variable.

La energía fotovoltaica carece de fiabilidad debido a que depende de las condiciones meteorológicas: irradiancia solar global y la temperatura. Si estas dos variables pueden ser pronosticadas con suficiente precisión, será posible estimar la energía de un sistema fotovoltaico, haciéndola una fuente de electricidad fiable.

Debido a la incertidumbre y la intermitencia de la energía solar a corto plazo, la predicción de la energía solar se ha convertido en un tema importante en el aumento de la penetración de las fuentes de energía solar en las redes eléctricas, asegurando un rendimiento comercial favorable en mercados de electricidad. La desventaja para la predicción es crear un modelo con los datos meteorológicos y climáticos del lugar donde se realice la predicción.

Para predecir la radiación solar de una ubicación en un momento específico y en el futuro existen los modelos físicos y modelos estadísticos. Los modelos estadísticos se basan principalmente en análisis de series de tiempo. Realizan predicciones confiables de potencia de energía solar fotovoltaica a corto plazo. Por lo tanto, modelos estadísticos son de interés en este trabajo porque presentan mejores resultados para horizontes cortos de predicción.

Un método de pronóstico eficiente ayudará a la red y a los operadores gestionar mejor el equilibrio eléctrico entre la demanda y la generación de energía. Es importante identificar tres horizontes de pronóstico (intra-hora, intra-día y día por delante) en relación con las actividades de operador de la red (el aumento gradual de eventos, la variabilidad relacionada con las operaciones, asignación de unidades, planificación de transmisión, días venideros de mercados, cobertura, planificación y optimización de activos).

1.2 Estado del arte

(Lorenz et al. [1]) muestran un buen rendimiento para el rango temporal de 30 min hasta 6 h. Para el rango intra-hora, información de nubes basado imágenes tierra-cielo se pueden utilizar para derivar las previsiones de irradiancia con mayor resolución espacial y temporal en comparación con las previsiones basadas en satélites.

Se han realizado varios estudios con respecto a la modelización de series temporales. En Reikard [2], se comparan diferentes modelos de series de tiempo.

En Bacher et al. [3], los autores investigan el uso de un modelo AR simple para predecir directamente la energía fotovoltaica en comparación con otros modelos.

Modelos ARMA son muy flexibles, ya que pueden representar varios tipos diferentes de series de tiempo mediante el uso de diferente orden. Se ha demostrado ser competente en la predicción cuando hay una correlación lineal subyacente de la serie histórica. Un requisito importante para el modelo ARMA es que la serie de tiempo debe ser estacionaria (véase Hamilton [4]).

Mellit y Pavan [5] desarrollaron un modelo de perceptrón multicapa MLP para pronosticar la irradiancia solar 24 h delante. El modelo propuesto acepta como parámetros de entrada irradiación diaria y la temperatura media diaria del aire; La salida son datos de irradiancia solar 24 h delante. Predicción de rendimiento de una instalación fotovoltaica conectada a la red en Trieste, Italia, tuvo un coeficiente de correlación de más del 98% de días soleados y un poco menos del 95% para los días nublados.

Las RNAs se han aplicado con éxito para la estimación de la irradiancia solar. La forma más popular de la red neural es la llamada estructura perceptrón multicapa (MLP) (ver Lauret [6]). La estructura MLP consiste en una capa de entrada, una o varias capas ocultas y una capa de salida. La capa de entrada recoge del modelo entradas del vector x , mientras que la capa de salida se obtiene la salida vectorial del modelo.

(Diaconescu, 2008 [7]) realiza la predicción de series de tiempo caóticas mediante un lineal autorregresivo con entradas exógenas (NarX), red neuronal recurrente dinámica. Los autores concluyeron que NarX, redes recurrentes pueden capturar la dinámica de sistemas dinámicos no lineales y determinaron que la arquitectura del modelo de prueba afecta al rendimiento de la predicción.

1.3 Justificación

Es importante pronosticar la cantidad de energía que es capaz de proporcionar un sistema fotovoltaico, debido a que el Centro Nacional de Control de Energía CENACE, tiene registros históricos de la energía que se demanda a una cierta hora del día, si se conoce con cierto tiempo de antelación la energía que puede generar el sistema solar fotovoltaico, a una determinada hora es más económico despachar la energía solar fotovoltaica que una generación convencional, es ahí la importancia. El costo de producción y la reducción de contaminantes por uso de energías no convencionales favorecen a la economía invirtiendo menos recursos y a cuidar el medioambiente.

Desde luego tiene un beneficio realizar un algoritmo el cual permita conocer la cantidad de potencia de salida proporciona un sistema solar fotovoltaico, en los próximos 10, 20 o 30 minutos, ya que es necesario que el sistema de pronóstico otorgue datos confiables con un error aceptable de predicción, con el fin de suministrar la potencia previamente conocida e ingresar su potencia a la red eléctrica para su despacho energético.

1.4 Objetivos

Objetivo General

Diseñar un algoritmo de pronóstico para horizonte corto de pronóstico de la irradiancia solar global para un sistema solar fotovoltaico.

Objetivos específicos

Estudiar y clasificar los principales métodos de pronóstico y su horizonte de predicción para la potencia de salida de un sistema solar fotovoltaico.

Revisar el estado del arte sobre técnicas de pronóstico de la disponibilidad de la energía fotovoltaica.

1.5 Metodología.

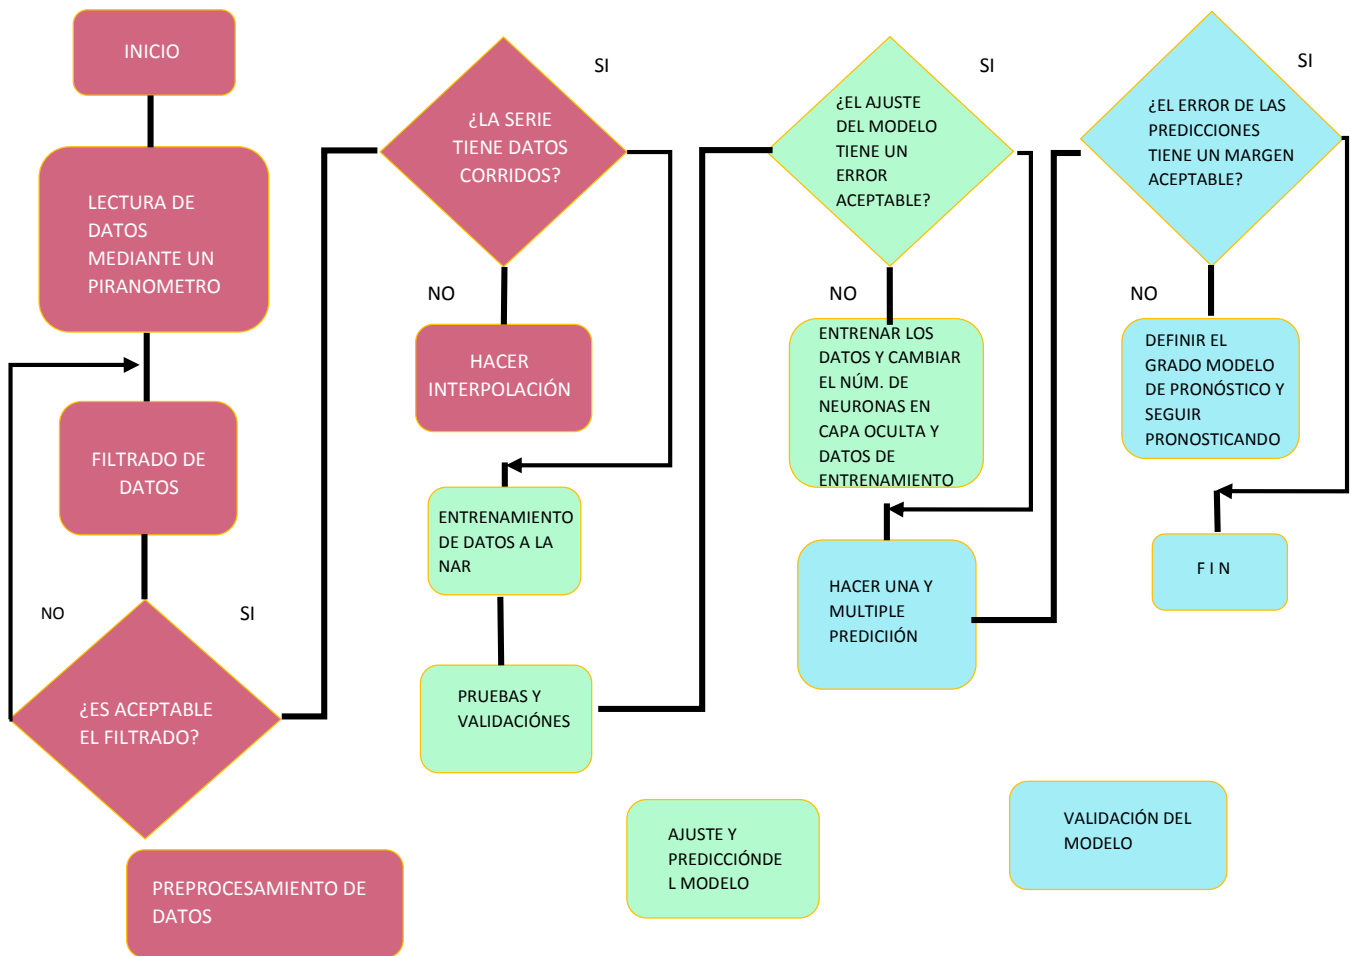


Fig. 1.1 Diagrama a bloques del software de algoritmo de predicción con redes neuronales autorregresivas no lineales NAR.

La utilización de un algoritmo para el pronóstico de la irradiancia solar y posteriormente de la potencia de un sistema fotovoltaico, se emplea una metodología que describe los pasos de forma organizada que se llevaron a cabo para obtener pronósticos.

La primer parte que es la del pre-procesado de datos, tenemos 87600 datos de irradiancia solar (W/m^2), obtenidos de un sensor de irradiancia (piranómetro), los cuales son datos de un año de medición de la fecha 1 de enero de 2014 a 31 de diciembre de 2014. Son mediciones con pasos de tiempo de 6 minutos cada una.

Una vez hecho este paso se observa si la medición no tiene datos perdidos o erróneos, ya que la serie si no es continua significaría un error en el proceso de entrenamiento a la red neuronal. Si hay algún intervalo en el que no halla medición se aplica una interpolación, que permita tener una serie continua sin interrupciones. Ya que los datos en un intervalo de tiempo se encuentran completos y correctos, con ellos se puede iniciar el proceso de entrenamiento, prueba y validación de la red Neuronal Autorregresiva (NAR).

Teniendo la red entrenada con los datos proporcionados se realizan las primeras pruebas de predicción, los datos posteriores medidos, serán los que permitan conocer el error de las predicciones. Se pueden realizar predicciones un solo paso por delante o múltiples pasos, para dar un pronóstico con un horizonte de predicción mayor. El tiempo de las predicciones va a estar en función de los datos que obtuvo por el sensor, los datos fueron tomados en intervalos de 6 minutos, por ejemplo tres predicciones por delante significan un horizonte de pronóstico alrededor de 18 minutos.

2.- Fundamento Teórico

2.1 Predicción de la irradiancia solar: conceptos previos

La energía que llega a la superficie de la atmósfera terrestre procedente del Sol es la principal fuente de energía, a partir de la cual se desarrollan todos los procesos en el sistema Tierra-Atmósfera-Océano, siendo la principal responsable, por ejemplo, del ciclo del agua, los cambios de presión y de vital importancia en el proceso de fotosíntesis. La proporción de energía que el sistema recibe del Sol es superior al 99.9%. Además, la energía solar es el origen del resto de fuentes energéticas del planeta, a excepción de la energía geotérmica y la energía nuclear [36].

A pesar de que la irradiancia solar es una variable de suma importancia, la meteorología ha prestado mayor importancia al estudio y predicción de otras variables meteorológicas, entre ellas la presión, la temperatura y la humedad. De hecho, es común ver en las partes meteorológicas la cuantificación de dichas variables con magnitudes exactas.

Sin embargo, en el caso de la irradiancia solar la variable con mayor relación directa y de la que históricamente se dan estimaciones es el nivel de nubosidad que establece únicamente seis valores discretos como se puede observar en la Figura 2.1 [8].



Fig. 2.1 Clasificación del estado del cielo en sus predicciones.

Esto se debe principalmente a que para realizar la predicción meteorológica se utilizan modelos matemáticos que simulan el estado futuro de la atmósfera. La capacidad de dichos modelos está limitada por la potencia de procesamiento de las computadoras y a pesar de los avances realizados en los últimos años en el campo del procesamiento de la información, en la actualidad, no es posible disponer de un solo modelo que represente el flujo atmosférico en todas sus escalas de movimiento existentes [8].

Los modelos de predicción meteorológicos pueden clasificarse en función de la resolución temporal y espacial, o bien en función de las herramientas matemáticas que se utilicen. La primera clasificación requiere la definición de los conceptos relacionados con la resolución espacial y temporal de los modelos meteorológicos de predicción y definen el tipo de predicciones que éste producirá. Así, se distingue:

□

Resolución espacial. Tamaño que representa el área espacial a la que corresponde la predicción que genera el modelo. Resolución temporal. Está relacionado con dos conceptos. Por un lado, el *paso temporal* o frecuencia temporal de la predicción, se define como el intervalo de tiempo entre cada valor predicho por el modelo; el *horizonte de predicción* hace referencia al alcance temporal de las predicciones [9].

Dependiendo del paso temporal y del horizonte de predicción, existen cuatro categorías en las que se pueden dividir los modelos meteorológicos y que se presentan en la Tabla 2.1. Los modelos de predicción con escala de muy corto plazo tienen un horizonte de predicción de una hora, también se considera esta escala como aquella en la que se utilizan técnicas que permiten tener un conocimiento del estado actual de la atmósfera.

La escala a corto plazo tiene un horizonte que va desde una hora hasta una semana y la meteorología es la ciencia que se encarga de su estudio. Los modelos con escalas de medio y largo plazo tienen un horizonte de predicción mayor a una semana y la climatología es la ciencia que se ocupa del estudio de esta escala [36].

| Tipo | Horizonte | Paso temporal |
|-------------------------------|-----------------------------|-----------------------|
| Muy corto plazo o downcasting | Inferior a una hora | Segundos a minutos |
| Corto plazo | Entre una hora y una semana | Minutos, horas o días |
| Medio plazo | Semana a un año | Días |
| Largo plazo | Mayor a un año | Meses |

Tabla 2.1 Escalas temporales de la predicción según su horizonte de predicción y su paso temporal.

En función de las herramientas matemáticas utilizadas para modelar las variables meteorológicas los modelos se pueden clasificar en los siguientes: Modelos numéricos de predicción (NWP). Se conocen también como modelos dinámicos y se basan en la resolución de las ecuaciones primitivas de la atmósfera utilizando técnicas numéricas que discretizan el espacio y el tiempo [10].

La principal ventaja de estos modelos es que su aplicación es o se considera universal. Como inconveniente, necesitan conocer con la mayor fidelidad posible el estado inicial de la atmósfera.

Modelos estadísticos. Se aplican directamente sobre las variables meteorológicas medidas o hacen uso de las salidas de los modelos dinámicos para mejorar su resolución. Se caracterizan por su sencillez y el hecho de que sólo se pueden aplicar en aquellos emplazamientos donde se tienen identificados los parámetros del modelo previamente [11].

Entre los diferentes modelos de predicción numérica y atendiendo a su escala temporal y espacial, podemos encontrar los Modelos Globales de Circulación Atmosférica (MCGA). Estos modelos integran sobre todo el globo terrestre con una baja resolución.

Dentro de los modelos estadísticos es posible diferenciar dos grupos dependiendo de si éstos hacen uso de la salida de los modelos numéricos para realizar las predicciones o no: Los modelos estadísticos clásicos se basan en el uso exclusivo de técnicas matemáticas, principalmente el análisis de series temporales.

El calificativo de clásicos se debe a que fueron los primeros modelos que se desarrollaron, cuando no se disponía de la información procedente de los modelos de predicción numérica [12]. En la actualidad, se utilizan para los horizontes temporales de predicción de corto y medio plazo, donde la información procedente de los modelos numéricos no presenta la suficiente resolución.

Los modelos de downscaling *estadístico*, también conocidos como técnicas MOS (*Model Output Statistics*), se basan en la aplicación de los métodos estadísticos en conjunción con los modelos de predicción numérica. Éstos se utilizan para mejorar las salidas de los modelos dinámicos de predicción sobre variables o emplazamientos no cubiertos por la resolución del modelo de predicción numérica. Además, la aplicación de este tipo de técnicas permite simular efectos locales que los modelos numéricos de predicción no son capaces de capturar.

A partir de estos conceptos, se han ido construyendo modelos diferenciados de predicción de irradiancia solar para un horizonte temporal de predicción del corto plazo.

2.2 Modelos de predicción de la irradiancia solar

Una magnitud habitualmente utilizada para realizar la parametrización del tipo de cielo es el índice de claridad (kt). El k se define como el cociente entre la irradiancia solar, que se recibe en la superficie terrestre y el valor correspondiente de la irradiancia solar extraterrestre. Los valores de kt se obtienen a partir de la irradiancia solar, aplicando la siguiente expresión [9]:

$$kt = \frac{G}{I_0} \quad (1)$$

donde G es la radiación global que llega a la superficie terrestre sobre superficie horizontal e I_0 es la irradiancia extraterrestre sobre superficie horizontal, ambas para el mismo periodo temporal. En situaciones de cielo claro o despejado, la irradiancia solar a su paso por la atmósfera sufre procesos de absorción y difusión, provocados por los diferentes componentes de la atmósfera (entre los más importantes, vapor de agua (H_2O), dióxido de carbono (CO_2) y ozono (O_3)) y los aerosoles formados por partículas sólidas y líquidas en suspensión.

Los modelos que estiman la radiación que llega a la superficie de la Tierra, para este tipo de situaciones de cielo, se conocen como modelos de cielo despejado y utilizan diversas aproximaciones matemáticas para su resolución. La aplicación de los modelos de cielo claro está limitada a las situaciones atmosféricas con ausencia de nubosidad. Dichas condiciones para un tiempo futuro no son conocidas de antemano, es necesaria la aplicación previa de los modelos meteorológicos de predicción.

Estos modelos son capaces de resolver la dinámica atmosférica relacionada con las masas nubosas, que son las principales causantes de la atenuación de la irradiancia solar a su paso por la atmósfera, y que los modelos de cielo claro obvian en sus cálculos debido a su simplicidad.

Los diferentes autores han abordado la resolución del problema de la predicción de la irradiancia solar que llega a la superficie terrestre mediante diversas perspectivas que deben ser analizadas detenidamente. Se ha realizado una clasificación de los diferentes tipos de modelos recogidos en la bibliografía, en función del tipo de modelo empleado (dinámico o estadístico) y del origen de los datos con los que se realiza la predicción:

- Modelos dinámicos.
- Modelos basados en downscaling estadístico.
- Modelos estadísticos clásicos a partir de medidas radiométricas.
- Modelos estadísticos que hacen uso de las imágenes de satélite.

2.2.1 Modelos dinámicos aplicados a la predicción de la irradiancia solar

Una forma de mejorar la modelización de las diferentes variables meteorológicas es aplicando técnicas de downscaling dinámico o aumento dinámico de la resolución. Éstas técnicas se basan en utilizar la salida de los modelos globales en un modelo de mesoescala con mayor resolución espacial y temporal y una mejor modelización física de los procesos de capa límite. En esta sección se presentan los principales trabajos que hacen uso del downscaling dinámico para obtener predicciones de la irradiancia solar.

Modelo MM5 Heinemann

Heinemann realiza una selección de la mejor parametrización para el modelo de mesoescala de área limitada MM5 en una región del sur de Alemania [3]. El modelo MM5 se inicializa con datos de reanálisis de NCEP (National Centers for Environmental Prediction) con una resolución temporal de 6 horas y espacial de $1^{\circ} \times 1^{\circ}$. Los resultados se calculan como medias espaciales para una región de 150×150 km. a partir de la salida del modelo de mesoescala con resolución espacial de 3×3 km., resolución temporal de 1 hora y horizonte de predicción de 48 horas.

Para realizar la validación se utilizan siete configuraciones diferentes del modelo MM5 y se identifican tres situaciones de nubosidad: cielo despejado, intervalos nubosos y cielo cubierto. La comparativa muestra diferencias significativas en los errores para cada una de las configuraciones ensayadas. En el caso de las situaciones de cielos despejados los errores varían entre 0.25% y 14.7% en términos del RMSE relativo.

Para las situaciones de intervalos nubosos los errores van desde el 2.3% al 64.4%, mientras que para los cielos cubiertos los errores varían entre -7.8% y 129%. La mejor configuración posible presenta un error relativo en términos de RMSE para

cada una de las situaciones de cielo definidas anteriormente de 1.85%, 6.75% y 25.8% respectivamente.

Modelo HIRLAM AEMet

El modelo regional operativo HIRLAM (*High Resolution Limited Area Model*) de AEMet (*Agencia Estatal de Meteorología*) se analiza comparando las predicciones de la irradiancia global con datos radiométricos medidos en superficie y con estimaciones a partir de imágenes de satélite [13]. La resolución temporal del modelo es horaria y se dispone de predicciones con un horizonte de predicción de 72 horas, con resolución espacial de 20 km.

El ejercicio de verificación comprende varios meses en los que las propiedades de la variable irradiancia solar y su distribución de probabilidad sean totalmente diferentes (agosto, octubre y diciembre de 2005 y enero de 2006). En ellos se utilizan dos fuentes diferentes y complementarias de datos de irradiancia solar: mediciones piranométricas de estaciones de la Red Radiométrica Nacional (RRN), pertenecientes a la Agencia Estatal de Meteorología (AEMet), y estimaciones derivadas de imágenes de satélite generadas por el consorcio europeo CM-SAF (*Climate Monitoring Satellite Applications Facility*).

Modelo AFSOL

Wittmann propone la combinación de un modelo de predicción numérica y un modelo de calidad del aire, con el fin de obtener predicciones de la irradiancia solar horaria con horizonte de predicción de 72 horas para la entrada en el mercado libre de la energía [14]. Las predicciones meteorológicas y de diferentes componentes atmosféricos se combinan utilizando asimilación de datos procedente de registros de satélite y medidas de tierra.

El objetivo de su trabajo es analizar el impacto de las predicciones de irradiancia solar en las estrategias de operación de las plantas termosolares para su participación en el mercado libre de la energía. Las predicciones se realizan en la comarca del Marquesado del Zenete, próximo a Guadix (Granada), donde se sitúa ANDASOL [15], la primera planta termosolar en Europa con tecnología cilindro-parabólica y almacenamiento térmico mediante sales fundidas.

La zona es de gran interés para el estudio de la energía solar debido a que ANDASOL tendrá capacidad para producir 150MW cuando finalicen las tres fases constructivas en las que se divide el proyecto [16]. Actualmente está en funcionamiento ANDASOL-1 y ANDASOL-2, con 50MW cada una de ellas, mientras que ANDASOL3 tiene programada su finalización en 2011.

Wittmann Propone obtener predicciones de la irradiancia solar para aplicaciones energéticas basadas en el modelo de predicción de aerosoles AFSOL [17]. Este modelo operativo está especializado en la obtención de predicciones de irradiancia solar exclusivamente para condiciones de cielo claro, cubriendo Europa y el Mediterráneo.

Se emplea el modelo de transferencia radiativa libRadtran (<http://www.libradtran.org>) para realizar los cálculos de irradiancia dentro del sistema AFSOL. El modelado de aerosoles es de gran relevancia en el sistema debido a su influencia sobre la irradiancia solar en condiciones de cielo despejado.

2.2.2 Modelos basados en downscaling estadístico aplicados a la predicción de la irradiancia solar

El uso de técnicas de *downscaling* estadístico se utiliza principalmente en la predicción de la precipitación y la temperatura, siendo actualmente escaso el número de trabajos dedicados exclusivamente a la irradiancia solar. A continuación, se presentan las principales aportaciones realizadas hasta la fecha que utilizan técnicas aplicadas al recurso solar para las resoluciones temporales horarias y diarias con distintos horizontes de predicción.

2.3 Modelos estadísticos clásicos aplicados a la predicción de la irradiancia solar

En las siguientes secciones se analizan algunos de los trabajos desarrollados en el ámbito de la predicción de la irradiancia solar utilizando métodos estadísticos clásicos: lineales y no lineales.

Modelo Red Neuronal Multivariable

Uno de los primeros trabajos relevantes aplicados en la predicción de la irradiancia solar diaria mediante redes neuronales artificiales (RNA) se publicó en 1994 [21]. El objetivo de esta investigación es el desarrollo de un modelo de red neuronal con el cual predecir la irradiancia solar diaria utilizando como valores de entrada las variables meteorológicas observadas (temperatura máxima y mínima del aire y precipitación diaria acumulada) y variables calculadas analíticamente (longitud del día y radiación diaria total de cielo claro).

En dicho trabajo se utiliza un algoritmo de retropropagación para el entrenamiento de las redes neuronales. El entrenamiento y evaluación de la red neuronal se realiza con 20 años de datos procedentes de 4 emplazamientos en el sureste de los Estados Unidos. Los datos se dividen en un conjunto de datos de entrenamiento constituido por los 11 primeros años y un conjunto de validación formado por los años restantes.

La evaluación del modelo de red neuronal se realiza comparando la irradiancia solar diaria predicha (salida de la red neuronal) con las observaciones de radiación solar. El modelo de red neuronal propuesto presenta una tendencia a sobreestimar la irradiancia solar para valores bajos y no se toman en cuenta valores altos de irradiancia. El autor informa que el error cuadrático medio (RMSE) es de 2.92MJ/m² día.

Modelo Red Neuronal Multietapa

Otro modelo más complejo basado en redes neuronales en múltiples etapas fue desarrollado por Kemmoku para obtener la predicción de la irradiancia global total del próximo día (resolución temporal y horizonte de predicción de un día) [22].

El autor utiliza datos meteorológicos diarios de 6 años (1988-1993) procedentes de la localidad de Omaezaki en Japón; la validación del modelo se realiza sobre un conjunto de datos de irradiancia solar diaria para cuatro meses de 1994 (Abril, Agosto, Octubre y Diciembre), independiente del conjunto de datos utilizado para la estimación de los parámetros de la red neuronal.

El conjunto de parámetros meteorológicos usados en la entrada de la red neuronal está formado por la diferencia entre el primer y segundo máximo y el primer y segundo mínimo local de la presión atmosférica, su valor medio y el valor registrado a las 18:00 horas, el índice de transparencia atmosférica, la temperatura y la irradiancia solar para la hora previa a la puesta del Sol.

La predicción se realiza utilizando redes neuronales independientes en tres etapas con las siguientes características: La primera etapa se basa en la consideración de que existe una correlación entre la irradiancia del próximo día y la diferencia entre las presiones atmosféricas medias entre el día anterior y el día siguiente. Esto se debe a que la irradiancia solar presenta una dependencia con las condiciones meteorológicas relacionadas estrechamente con el paso de masas de aire de alta y baja presión atmosférica.

De esta forma, en esta primera fase la presión atmosférica media se puede utilizar como entrada a una red neuronal para predecir tres niveles de irradiancia solar. La segunda etapa utiliza una red neuronal para predecir la irradiancia solar del próximo día a partir de la presión atmosférica media y de los datos meteorológicos.

La tercera etapa refina el valor de la predicción de la irradiancia solar de la segunda etapa. En esta etapa final se consideran niveles de irradiancia solar altos, medios y bajos y se realiza la predicción final utilizando una red neuronal, entre tres independientes, de acuerdo al nivel de irradiancia solar predichos en la primera etapa.

2.3.1 Modelos basados en imágenes de satélite

Las imágenes de satélite, gracias a su resolución espacial y temporal, son una excelente fuente de datos para realizar predicciones en el muy corto plazo. Su utilidad se encuentra principalmente en el efecto sustancial que tienen las nubes en la irradiancia solar que llega a la superficie terrestre [31; 32; 33].

La variación temporal de las estructuras nubosas se debe al movimiento propio de las nubes, causa por la que los campos de vectores de movimiento (Motion Vector

Field MVF o Atmospheric Motion Vector Field AMF) son una herramienta apropiada para la predicción del movimiento de las masas nubosas [1].

La aplicación de los campos de vectores de movimiento directamente sobre el coeficiente de cobertura nubosa permite obtener predicciones de la irradiancia solar a partir de imágenes de satélite para un horizonte de predicción de muy corto plazo [1]. El procedimiento para derivar los MVFs a partir del coeficiente de cobertura nubosa consiste en identificar regiones de dos imágenes consecutivas y calcular un vector de desplazamiento óptimo entre las dos regiones a partir de la diferencia cuadrática media en cada píxel.

Los vectores de campo de movimiento que se obtienen, son aplicados a la imagen actual para derivar la posición de las nubes en el siguiente instante temporal. Finalmente, se aplica un filtro de suavizado para la eliminación de pequeñas estructuras que varían aleatoriamente. Situaciones con nubes no homogéneas corresponden a imágenes con alta variabilidad del coeficiente de cobertura nubosa y son más difíciles de predecir, por lo que presentan mayor incertidumbre que las situaciones de cielos despejados.

En los casos en los que existen valores altos de irradiancia solar con baja variabilidad, el error es del 10% en términos de RMSE para un horizonte de predicción de 30 minutos mientras que si aumenta hasta 6 horas es del 25% en términos del RMSE. En el proceso de validación no se ha tenido en cuenta el efecto que tiene sobre el valor del índice de cobertura nubosa las elevaciones solares bajas debido a que el punto donde se realiza la predicción está excesivamente distante del *nadir* del satélite y se produce una distorsión en la imagen como se observa en la imagen 2.2 el movimiento de nubes.

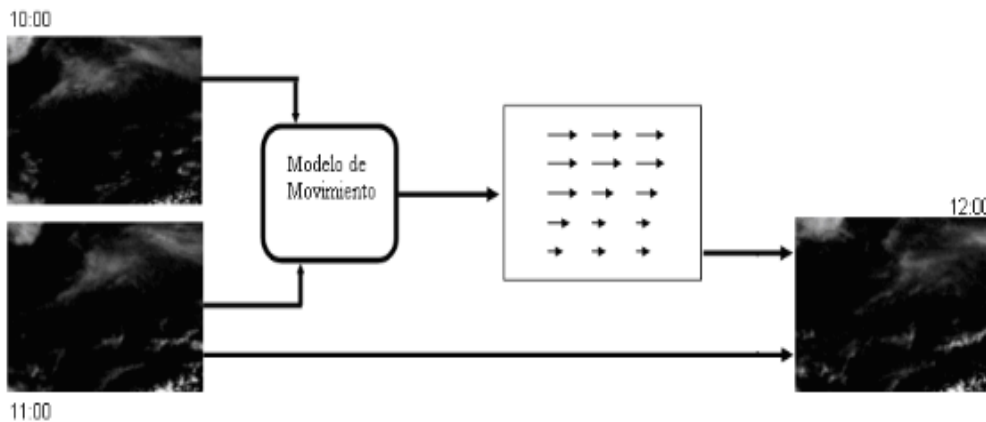


Fig. 2.2 Campo de vectores de movimiento calculados en un esquema de predicción de corto plazo.

Otra metodología propuesta por Lorenz para la predicción del coeficiente de cobertura nubosa está basada en el empleo de redes neuronales, aunque el error obtenido no mejora al de la predicción mediante MVFs. La aplicación de los campos de vectores de movimiento sobre las imágenes de satélite es una herramienta fundamental para la obtención de predicciones de la irradiancia solar global en un

horizonte temporal que va desde la propia resolución temporal del satélite hasta las 6 horas [3].

La obtención de predicciones con mayor resolución temporal a la propia del satélite debe realizarse mediante la aplicación de técnicas estadísticas, como el análisis de series temporales o redes neuronales, sobre medidas radiométricas en superficie o utilizando la técnica de campos de vectores de movimiento sobre medidas de cámaras de cielo, ya que para estos horizontes temporales no está disponible la información de los modelos globales.

2.4 El enfoque ANN para el modelado de series de tiempo

Cuando se relaja la restricción lineal de la forma del modelo, el número posible de estructuras no lineales que se puede utilizar para describir y predecir una serie de tiempo es grande. Un buen modelo no lineal debe ser lo suficientemente generales como para captar algunos de los fenómenos no lineales en los datos.

Las Redes Neuronales Artificiales son uno de tales modelos que son capaces de aproximar varias no linealidades en los datos. RNAs son marcos de computación para modelar una amplia gama de problemas no lineales. Una ventaja significativa de los modelos de RNA más que otras clases de modelos no lineales es que las RNA son aproximadores universales, que pueden aproximarse a una gran clase de funciones con un alto grado de precisión. Su poder proviene del procesamiento en paralelo de la información de los datos.

En cambio, el modelo de red se determina en gran parte por las características de los datos. Única red feedforward en la capa oculta es la forma modelo más utilizado para el modelado de series de tiempo y el pronóstico.

3. Desarrollo

3.1 Clasificación de los modelos de predicción resolución temporal y espacial

La aplicación de un algoritmo de predicción de irradiancia solar es una herramienta que permite conocer con anticipación cuánta energía se tendrá disponible en un sistema fotovoltaico para que sea despachable estando interconectada a la red del sistema. La elaboración del algoritmo se basa en la solución para el pronóstico de la irradiancia solar con un horizonte de predicción muy corto plazo basado en la resolución espacial y temporal como se ve en la fig. 3.1 [37].

Los modelos de predicción como se ha mencionado anteriormente se clasifican en la resolución temporal y espacial por lo que en la figura 3.1 se engloban los diferentes métodos, estadísticos, numéricos y las imágenes de satélite, demuestra que métodos funcionan mejor. Para la realización del trabajo de acuerdo con las necesidades se requiere una resolución espacial en el área de micro-escala y una resolución temporal de intra hora.

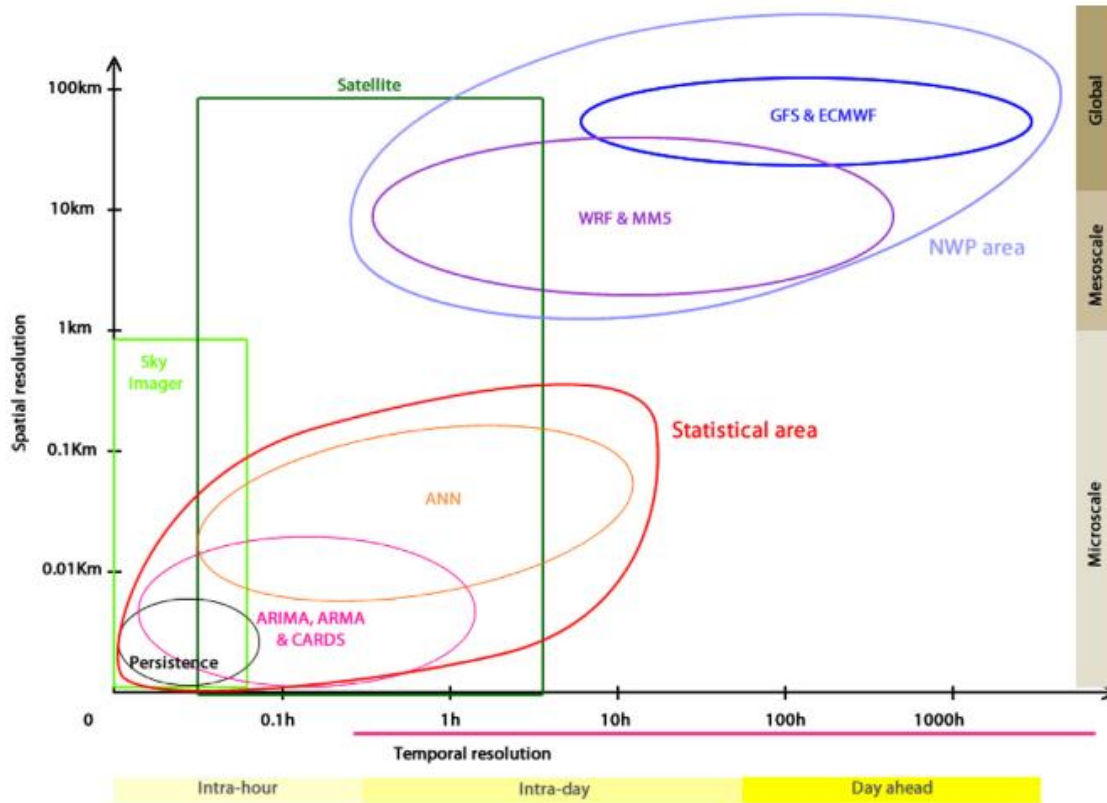


Fig. 3.1 Clasificación de los modelos de predicción basada en la resolución temporal y espacial.

3.2 Representación Matemática Red Neuronal Autorregresiva NAR

Los modelos que mejores resultados presentan para las condiciones de mesoescala e intra-hora son los modelos estadísticos, ya que tienen una referencia importante en la literatura de pronóstico de irradiancia solar por lo que se trabajara con redes neuronales autorregresivas no lineales NAR [39].

El modelo se caracteriza por una red de tres capas de unidades de procesamiento simples conectadas por unos enlaces cíclicos. La relación entre la salida y_t y las entradas $(y_{t-1}, y_{t-2}, y_{t-p})$ tiene la siguiente representación matemática:

$$y_t = \alpha_0 + \sum_{j=1}^q \alpha_j g \left(\beta_{0j} + \sum_{i=1}^p \beta_{ij} y_{t-p} \right) \quad (2)$$

donde α_0 ($j=0, 1, 2, \dots, q$) y β_{ij} ($i=0, 1, 2, \dots, p; j=1, 2, \dots, q$) son los parámetros del modelo y son llamados pesos de conexión; p es el número de nodos de entrada y q es el número de nodos en la capa oculta [40]. La función lógica mayormente usada como función de transferencia en la capa oculta es:

$$g(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

El modelo de la red neuronal autorregresiva (2) en realidad el rendimiento de los valores pasados medidos ($y_{t-1}, y_{t-2}, \dots, y_{t-p}$) se evalúa para el valor futuro y_t , en (4);

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}, w) + \varepsilon_t \quad (4)$$

donde w es un vector de todos los parámetros y f es la función (3) determinada por la estructura y conexión de pesos de la red. La red neuronal es equivalente a un modelo no lineal autorregresivo. La expresión (2) implica un nodo de salida en la capa de salida cuando es típicamente usado para un pronóstico de un paso por delante esto se representa gráficamente por la figura 3.2 [40].




Fig. 3.2 Arquitectura de una Red Neuronal Autorregresiva NAR.

3.3 Manejo de datos y creación de la NAR en Matlab

Las redes NAR como se abordó anteriormente son aproximadores de modelos no lineales. El comportamiento de la radiación solar, es un modelo no lineal que se comporta de manera estocástica es decir, que no siempre se comporta de la misma forma. Por ello es necesario predecir los siguientes valores y_t a partir de los valores obtenidos de un piranómetro (sensor de irradiancia solar global) medidos durante un año con intervalos de predicción de 6 minutos.

Primeramente es necesario tener una base de datos ya sea en Excel o en block de notas, con el fin de exportar dichos datos a Matlab. Se tienen 84600 datos de irradiancia solar global que comprende el periodo de 01/01/2013 a 31/12/2013 medidos en Zapopan, Jalisco en área de fuentes renovables del Centro de Investigación de estudios Avanzados del IPN mostrada en la figura 3.5. Utilizando

la app de Matlab para resolver neural net time series, es necesario tener valores anteriores $y-p$ de la irradiancia solar para pronosticar el valor siguiente y_t al tener los datos se designa un vector de entrada.

Se tienen los datos de irradiancia solar, una vez teniendo esto listo se procede a dividir los datos en los diferentes parámetros: entrenamiento, validación y prueba, definiendo en porcentaje y de forma aleatoria, 70%, 15%, 15% respectivamente, para posteriormente hacer el procesamiento de la red neuronal.

Se determina enseguida las neuronas en la capa oculta, para el caso se realizaron varias simulaciones con diferentes neuronas, el menor error es con 6 neuronas en la capa oculta, 2 retrasos a la entrada y con 1000 datos de división como se muestra en la fig.3.3, obteniendo 700 datos de entrenamiento, 150 de validación y 150 de prueba. La red tiene 3 capas, capa de entrada, que son los datos de la irradiancia solar, la capa oculta, es donde se realiza todo el procesamiento de ajuste de pesos, y la capa de salida que da el resultado final de la predicción.

En la imagen 3.3 se ve la división de los datos con el algoritmo de entrenamiento, los datos en color azul son los datos de entrenamiento, los de color verde son datos de validación y color rojo datos de prueba de la red. En la figura 3.4 la estructura de la NAR en Matlab con un vector de datos de entrada, 2 retrasos a la entrada, 8 neuronas capa oculta con la función logarítmica sigmoïdal y una capa de salida para obtener un resultado.

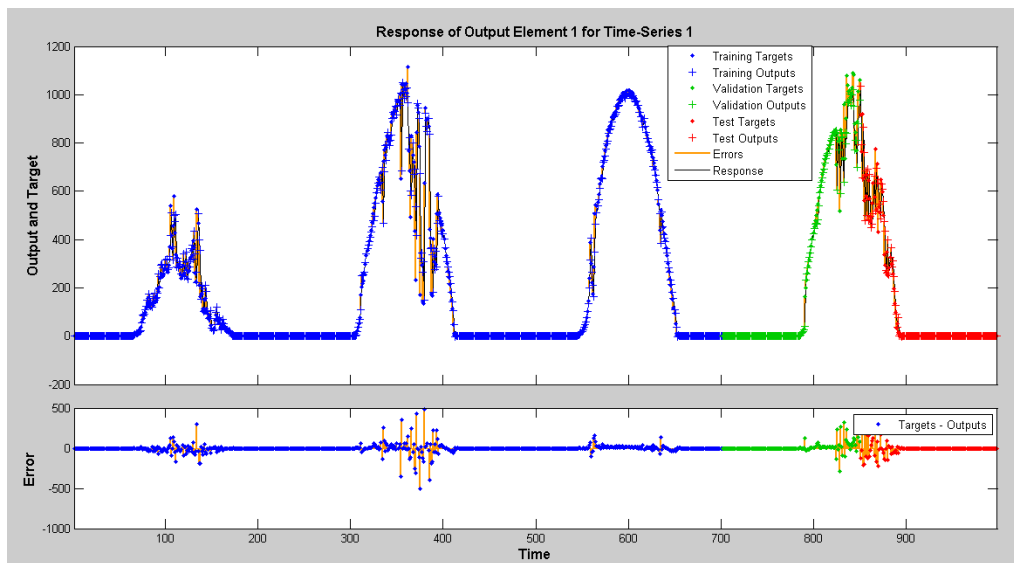


Fig. 3.3 división de los datos de irradiancia solar.




Fig. 3.4 Modelo red NAR en Matlab 2014a con 8 neuronas en la capa oculta y 2 retrasos a la entrada.

El algoritmo de entrenamiento más utilizado es el Levenberg-Marquardt para el ajuste de pesos, pero se va a utilizar el algoritmo de entrenamiento por regularización bayesiana que presenta mejores resultados que el algoritmo Levenberg-Marquardt, ya que se necesita ajustar para tener un mínimo error dado por la métrica de error MSE [42] (Mean Squared Error) definido por :

$$MSE = \sum_{i=1}^n \frac{(\hat{p} - p)^2}{n} \quad (5)$$

donde n es el número de datos, \hat{p} es la predicción, y p es el dato real medido. Se utiliza la función `preparets` para preparar los datos con coeficientes de entrada que actualizan las entradas siempre, para que se pueda predecir siempre un valor nuevo como: $y + 1, y + 2, \dots, y + n$ etc. [41].




Fig. 3.5 Datos de Irradiancia solar Global durante un año. (2013).

3.4 Predicción un paso por delante y múltiple

Hay 2 tipos de redes: con retroalimentación (close-loop) y sin retroalimentación (open-loop), la red open-loop es para hacer una sola predicción (one step-prediction) como se ve en la figura 3.6, el tipo close-loop es para hacer predicción multipaso. Como la close-loop es un bucle cerrado la salida $y+1$ pasa a ser entrada a la red, para producir $y+2$, $y+3$ y así sucesivamente aunque genera un error mayor con cada paso de predicción extra, debido a que cada predicción inserta un error como entrada y la salida genera un error mayor.




Fig. 3.6 Arquitectura close-loop (parte superior) para la predicción múltiple y en la inferior el open-loop para hacer one step-prediction.

Se utilizaron varias pruebas para definir un modelo con 5, 6, 8, 15, 18 y 20 neuronas en la capa oculta, el menor error resulto con 6 neuronas y 1000 datos resultando que 1000 datos son para entrenamiento, validación pruebas. Para definir el error, se utilizaron las siguientes métricas:

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{p}_i - p_i| \quad (6)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{p}_i - p_i}{p_i} \right| \quad (7)$$

$$MBE = \frac{1}{N} \sum_{i=1}^N (\hat{p}_i - p_i) \quad (8)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{p}_i - p_i)^2} \quad (9)$$

donde N es el número de datos, \hat{p}_i los datos predichos y p_i los datos de entrada medidos de irradiancia solar global [41].

4. Resultados y Conclusiones

4.1 Resultados

Para la selección de la cantidad de neuronas en la capa oculta se realizaron algunas pruebas arrojando los siguientes resultados mostrados en la tabla 4.1:

| Número de neuronas en capa oculta | Datos entrenados 6 minutos | MAPE % | RMSE W/m ² | MAE W/m ² |
|-----------------------------------|----------------------------|---------|-----------------------|----------------------|
| 6 | 400 | 68.4303 | 25.0678 | 25.7440 |
| 6 | 500 | 55.1685 | 22.1498 | 21.0694 |
| 6 | 1000 | 5.9797 | 26.9515 | 24.4885 |
| 6 | 10000 | 15.0724 | 23.1519 | 22.1848 |
| 8 | 400 | 95.6809 | 25.0678 | 28.6576 |
| 8 | 500 | 43.9282 | 22.1498 | 22.7585 |
| 8 | 1000 | 6.5453 | 26.9515 | 24.2584 |
| 8 | 10000 | 16.9533 | 23.1520 | 20.3467 |
| 12 | 400 | 77.3730 | 25.0679 | 38.4980 |
| 12 | 500 | 60.1425 | 22.1500 | 25.3960 |
| 12 | 1000 | 6.6671 | 26.9516 | 29.9229 |
| 12 | 3000 | 17.9335 | 26.2992 | 20.0469 |
| 15 | 500 | 67.1099 | 22.1503 | 50.6522 |
| 15 | 1000 | 7.2244 | 26.9517 | 38.9585 |

Tabla 4.1 Elección del modelo de acuerdo a los errores.

Al haber obtenido resultados de la tabla 4.1 se decide que el modelo se va a realizar con 1000 datos de entrenamiento y se realizan más pruebas con 6, 8, 15 y 20 neuronas en la capa oculta se pueden observar los resultados en las tablas 4.2 y 4.3. Para 90 predicciones one step y multi-step.

| 6 neuronas 1000 datos de entrenamiento 6 minutos | | | | | 8 neuronas 1000 datos de entrenamiento 6 minutos | | | | |
|--|---------|-----------------------|----------------------|----------------------|--|---------|-----------------------|----------------------|----------------------|
| Predicción | MAPE % | RMSE W/m ² | MBE W/m ² | MAE W/m ² | Predicción | MAPE % | RMSE W/m ² | MBE W/m ² | MAE W/m ² |
| One step | 5.8254 | 33.4210 | -6.8802 | 25.1056 | One step | 6.5098 | 37.4867 | -12.6908 | 26.9809 |
| 2 pasos | 8.2673 | 62.7302 | -4.2665 | 44.4061 | 2 pasos | 8.9897 | 65.0519 | -19.3433 | 45.7844 |
| 3 pasos | 14.0057 | 139.1728 | -22.4625 | 78.6135 | 3 pasos | 14.5190 | 142.1143 | -35.7012 | 82.4751 |

Tabla 4.2. Resultado de errores para 6 y 8 neuronas en capa oculta con 1000 datos de entrenamiento.

| 15 neuronas 1000 datos de entrenamiento 6 minutos | | | | | 20 neuronas 1000 datos de entrenamiento 6 minutos | | | | |
|---|---------|-----------------------|----------------------|----------------------|---|---------|-----------------------|----------------------|----------------------|
| Predicción | MAPE % | RMSE W/m ² | MBE W/m ² | MAE W/m ² | Predicción | MAPE % | RMSE W/m ² | MBE W/m ² | MAE W/m ² |
| One step | 7.0751 | 45.1824 | -12.7213 | 32.1901 | One step | 12.0293 | 43.0992 | -10.7345 | 31.1569 |
| 2 pasos | 9.3856 | 69.3523 | -18.1889 | 49.6302 | 2 pasos | 18.4184 | 64.3564 | -13.3778 | 43.8193 |
| 3 pasos | 17.2128 | 140.2506 | -24.9871 | 88.5784 | 3 pasos | 23.2475 | 154.9558 | -49.3628 | 89.0898 |

Tabla 4.3 Resultado de errores para 15 y 20 neuronas en capa oculta con 1000 datos de entrenamiento.

Se eligieron los 2 mejores modelos para conocer su comportamiento respecto a los siguientes datos medidos. Los modelos de 6 y 8 neuronas son los modelos que menos errores se obtuvieron con 1000 datos de entrenamiento, es decir, que se necesitan 4.16 días de medición, tomando en cuenta que son datos medidos en intervalos de 6 minutos para producir el siguiente valor de la serie. Como se aprecia en la figura 4.1 es el mejor resultado en los 2 modelos mostrados en las figuras 4.1 y 4.2. La red se adapta muy bien pero tiene menor error con 6 neuronas y 1000 datos de entrenamiento. En la imagen no se aprecia un cambio considerable, aunque en la tabla de errores 4.4 si existen cambios minimos. En la tabla 4.5 se muestran los pesos y bias de la NAR.




Fig. 4.1 Modelo de predicción con 6 neuronas en capa oculta y 1000 datos de entrenamiento.

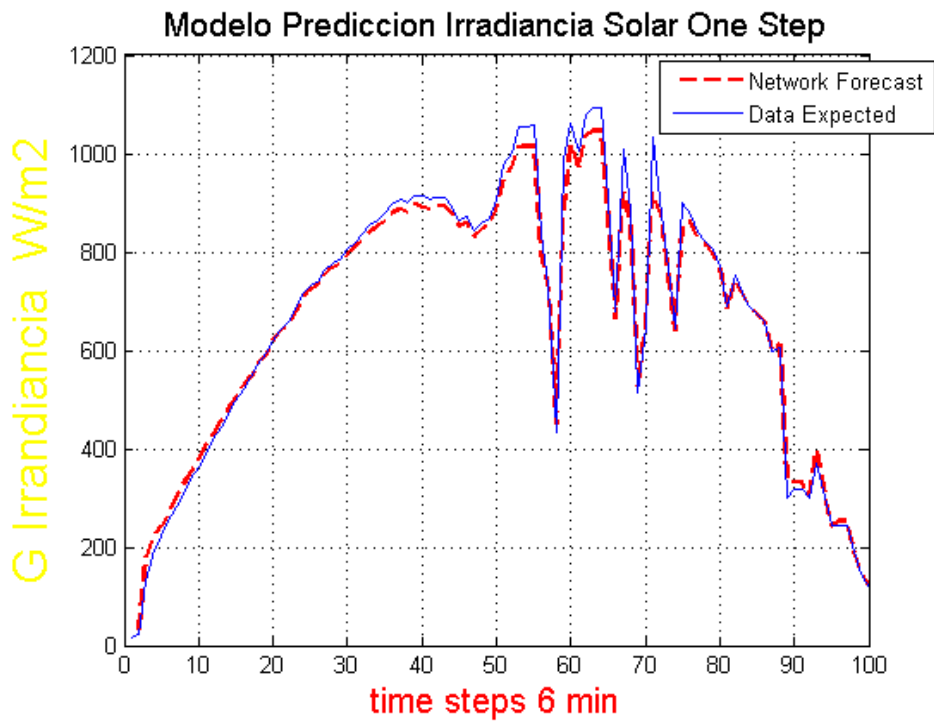


Fig. 4.2 Modelo de predicción con 8 neuronas en capa oculta y 1000 datos de entrenamiento.

| 1000 datos de entrenamiento 6 minutos 100 predicciones | | | | |
|--|--------|-----------------------|----------------------|----------------------|
| Neuronas en capa oculta | MAPE % | RMSE W/m ² | MBE W/m ² | MAE W/m ² |
| 6 | 4.1578 | 27.0302 | -8.8117 | 17.9946 |
| 8 | 4.3183 | 27.7786 | -9.4557 | 18.4933 |

Tabla 4.4 Resultado de errores para 6 y 8 neuronas en capa oculta con 1000 datos de entrenamiento para definir el modelo final.

| Pesos | | | | bias | |
|------------|---------|------------|---------|------------|------------|
| 6 neuronas | | 8 neuronas | | 6 neuronas | 8 neuronas |
| | | -0.0025 | -0.0011 | | 0.0006 |
| -0.0033 | -0.0015 | -0.4976 | -0.4300 | 0.0008 | -1.2228 |
| 0.0033 | 0.0015 | -0.0025 | -0.0011 | -0.0008 | 0.0006 |
| 1.2706 | -0.9530 | -0.6386 | 1.2407 | 0.0539 | -0.2702 |
| 0.4976 | 0.4300 | -0.0025 | -0.0012 | 1.2228 | 0.0006 |
| -0.6386 | 1.2407 | 0.0025 | 0.0012 | -0.2702 | -0.0006 |
| -0.0031 | -0.0014 | 0.0025 | 0.0011 | 0.0007 | -0.0006 |
| | | -1.2706 | 0.9530 | | -0.0539 |

Tabla 4.5 Pesos sinápticos y bias del modelo de la red neuronal 6 y 8 neuronas.

Predicción multipaso

La predicción multipaso tiene como objetivo dar más predicciones, aunque no se cuentan con entradas disponibles, se tendrá un error mayor porque la primer predicción se convierte en un dato de entrada a la serie para producir el siguiente valor pronosticado se observan en las figuras 4.3, 4.4, 4.5 y 4.6, además se notan los errores entre las predicciones en la tabla 4.6. En la tabla 4.7 se muestran los pesos y bias de la NAR.

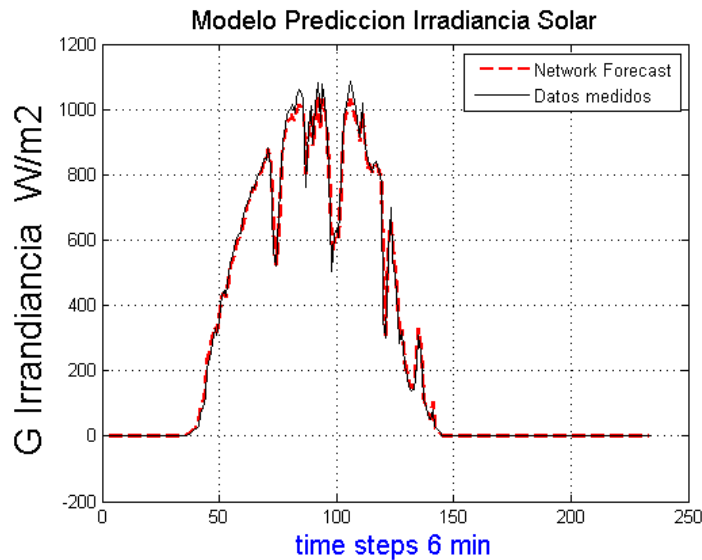


Fig. 4.3 Modelo de predicción un paso por delante con 6 neuronas en capa oculta y 1000 datos de entrenamiento para un día completo de medición.

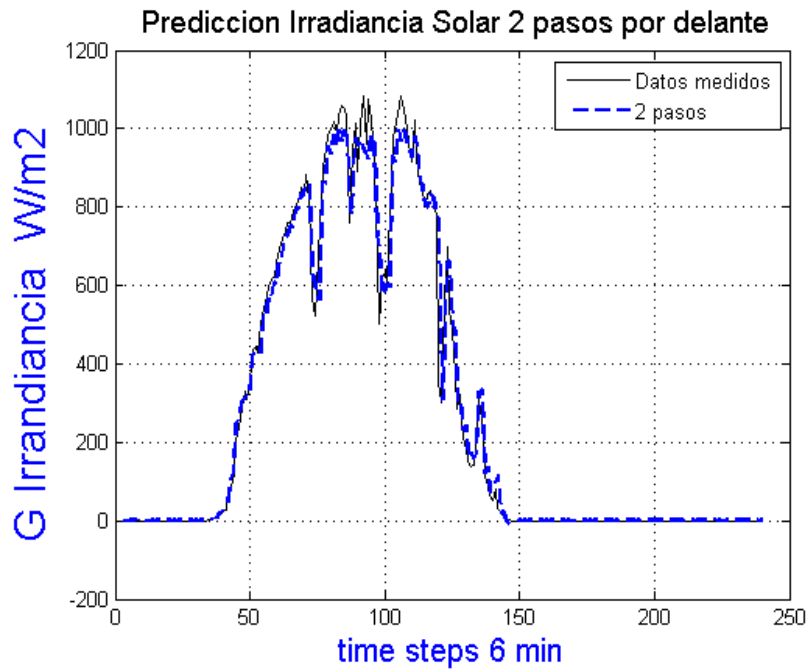


Fig. 4.4 Modelo de predicción dos pasos por delante con 6 neuronas en capa oculta y 1000 datos de entrenamiento para un día completo de medición.




Fig. 4.5 Modelo de predicción tres pasos por delante con 6 neuronas en capa oculta y 1000 datos de entrenamiento para un día completo de medición.

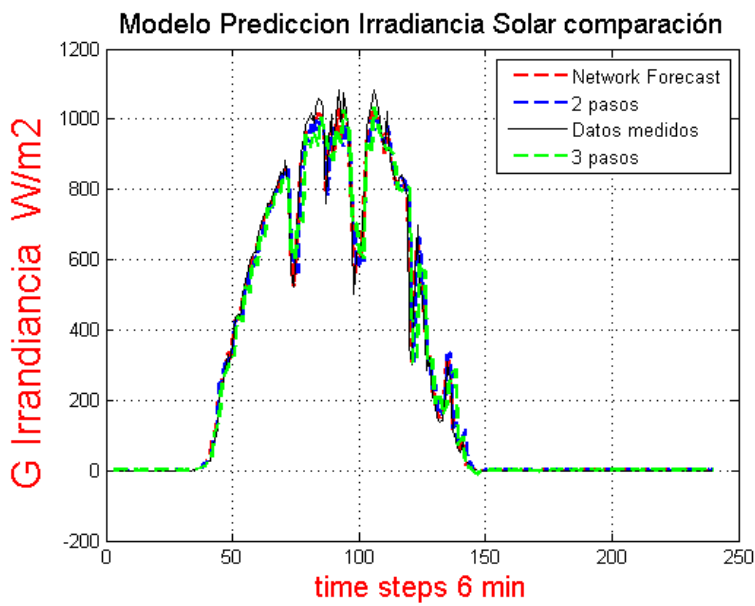


Fig. 4.6 Modelo de predicción comparando las predicciones multipaso y un paso por delante con 6 neuronas en capa oculta y 1000 datos de entrenamiento para un día completo de medición.

240 predicciones para un día completo de medición

| 6 neuronas 1000 datos de entrenamiento 6 minutos | | | | |
|--|---------|-----------------------|----------------------|----------------------|
| Predicción | MAPE % | RMSE W/m ² | MBE W/m ² | MAE W/m ² |
| One step | 5.8254 | 19.7186 | -2.7388 | 10.1689 |
| 2 pasos | 8.2673 | 50.0251 | -4.4615 | 21.4115 |
| 3 pasos | 14.0057 | 64.4585 | -6.5878 | 28.5999 |

Tabla 4.6 Resultado de errores para el modelo de predicción con 6 neuronas en capa oculta con 1000 datos de entrenamiento para un día completo de medición.

| Pesos | | Bias |
|---------|---------|---------|
| -0.3863 | -1.5838 | 1.1217 |
| -0.3737 | 2.6465 | 0.3685 |
| 0.7505 | -1.0033 | -0.8776 |
| 0.1029 | -0.9867 | -0.0257 |
| -0.0997 | 0.7771 | -0.0010 |
| 0.6342 | 0.8801 | 1.7169 |

Tabla 4.7 Pesos sinápticos y bias del model para 240 predicciones de la red neuronal 6 neuronas.

Es importante conocer la tendencia de las predicciones porque permite dar una idea acerca de cómo se comporta el modelo dentro de las próximas mediciones, si es claro que conforme se aumentan los pasos de pronóstico aumenta el error. En ocasiones es necesario hacer predicciones denominadas multipaso, para conocer la tendencia por falta de datos medidos para la serie.

En la figura 4.7 se observa un pronóstico de un paso por delante con 1000 ciclos, se logra cuando se tienen los datos para evaluar la respuesta de la NAR. En la tabla 4.8 se muestran los errores utilizando 2 tipos de algoritmos de entrenamiento diferentes, demostrando que el algoritmo por regularización bayesiana resulto mejor para entrenar la NAR y fue el algoritmo elegido para hacer los pronósticos. En la figura 4.8 se observa un pronóstico un paso por delante con 300 ciclos de predicción, equivale a la predicción de un día completo, la parte donde los datos son 0 muestra que es noche por lo tanto no hay mediciones notando que el pronóstico de red se adapta correctamente cuando no hay radiación.

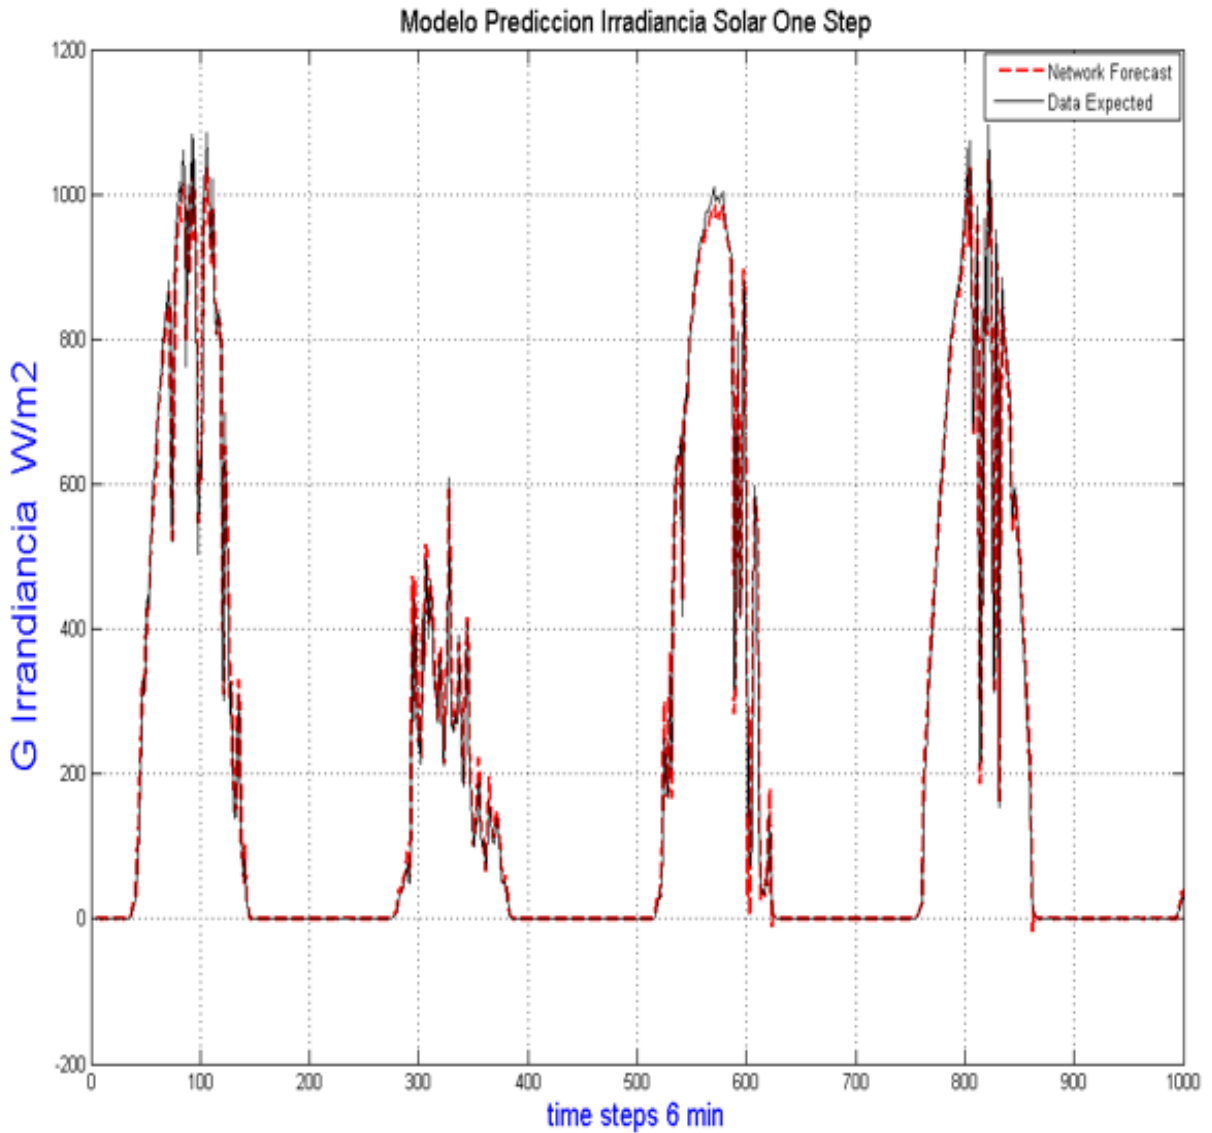


Fig. 4.7 Modelo de predicción un paso por delante con 6 neuronas en capa oculta y 1000 datos de entrenamiento para 1000 pasos de pronóstico.

| 6 neuronas 1000 datos de entrenamiento 1000 ciclos one step prediction | | | | |
|---|---------|---------|--------|---------|
| Algoritmo de entrenamiento | MAPE | RMSE | MBE | MAE |
| "Train-br" Regularización Bayesiana | 12.6965 | 24.6555 | 0.5101 | 8.9435 |
| "Train-lm" Levenberg-Maquardt | 22.7730 | 28.3229 | 0.6933 | 12.9957 |

Tabla 4.8 Resultado de errores para el modelo de predicción con 6 neuronas en capa oculta con 1000 datos y la diferencia con 2 algoritmos de entrenamiento.

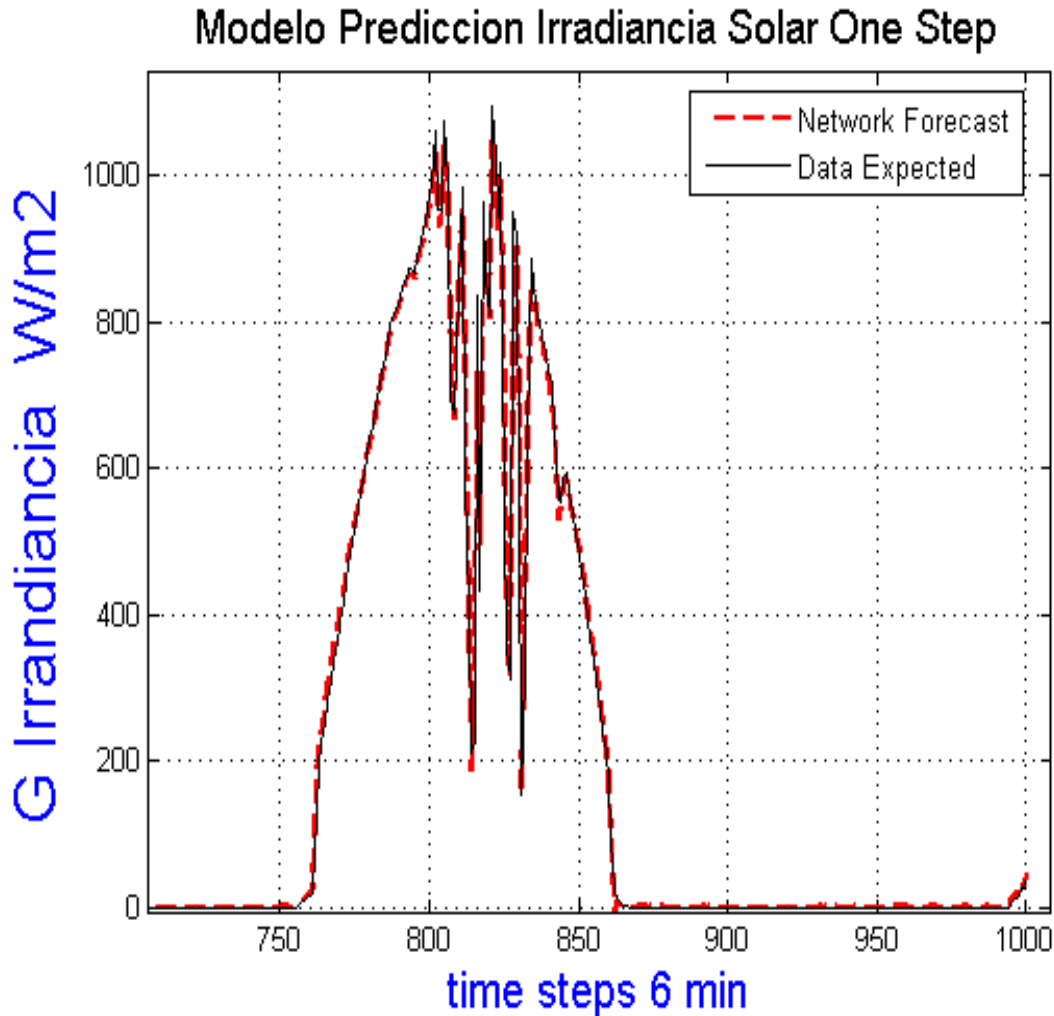


Fig. 4.8 Modelo de predicción un paso por delante con 6 neuronas en capa oculta y 1000 datos de entrenamiento 300 pasos de pronóstico.

4.2 Conclusión

Para realizar un algoritmo de pronóstico de irradiancia solar es necesario conocer los modelos existentes para tener un punto de partida, el cual ayude a identificar que método va a permitir obtener un modelo adecuado de predicción.

La definición del modelo se centra en tener una serie de tiempo tomados previamente en intervalos de tiempo, para el caso son intervalos de 6 minutos el sistema fue definido para utilizar solamente 1000 datos de entrenamiento ya que son suficientes para pronosticar el siguiente valor de la serie, siendo la primer predicción.

Siendo que la serie siempre se actualiza conforme el tiempo transcurra para siempre tener completa la serie con 1000 datos y pronosticar el siguiente valor. Se pueden hacer más predicciones, aunque para tener los 1000 datos completos se tiene que poner como dato de entrada la primer predicción, para obtener la segunda

predicción y así sucesivamente, aunque esto genera un error mayor porque la introduce a la serie un error de medición por no ser un dato verídico.

Este algoritmo permite convertir el pronóstico de la irradiancia solar a un pronóstico de la potencia de salida un sistema fotovoltaico, que depende de las características específicas de los paneles solares y su curva de potencia. Con ello, permite ofrecer a un determinado tiempo al centro de control de energía una potencia que pueda ser despachada, una vez que esta esté disponible teniendo un costo de generación bajo respecto a las demás formas de generación convencionales permitiendo invertir menos recursos y evitar la contaminación hacia el medio ambiente.

Referencias Bibliográficas

- [1] Lorenz E, Hammer A, Heinemann D. Short term forecasting of solar radiation based on satellite data. In: EUROSUN2004 (ISES Europe Solar Congress). p. 2004:841–8.
- [2] Reikard G. Predicting solar radiation at high resolutions: a comparison of time series forecasts. *Solar Energy* 2009; 83:342–9.
- [3] Bacher P, Madsen H, Nielsen HA. Online short-term solar power forecasting. *Solar Energy* 2009; 83:1772–83.
- [4] Hansen BE. Time series analysis James D. Hamilton Princeton University Press, 1994. *Econometric Theory* 1995; 11:625–30.
- [5] Mellit A, Pavan AM. A 24-h forecast of solar irradiance using artificial neural network: application for performance prediction of a grid-connected PV plant at trieste, Italy. *Solar Energy* 2010; 84:807–21.
- [6] Lauret P, Fock E, Randrianarivony RN, Manicom-Ramsamy J-F. Bayesian neural network approach to short time load forecasting. *Energy Conversion and Management* 2008; 49:1156–66.
- [7] Diaconescu, E. (2008). The use of NARX Neural Networks to predict Chaotic Time Series. Volume 3, pp. Pages 182-191.
- [8] Pérez R, Kivalov S, Schlemmer J, Hemker Jr K, Renne D, Hoff TE. Validation of short and medium term operational solar radiation forecasts in the US. *Solar Energy* 2010; 84:2161–72.
- [9] Heinemann D, Lorenz E, Girodo M. Forecasting of solar radiation. In: *Solar energy resource management for electricity generation from local level to global scale*. Nova Science Publishers; 2006. p. 223–33.
- [10] Wilks, D. S., 2005. *Statistical methods in the atmospheric sciences*. Vol. 91. Serie: International Geophysics. Academic Press, London (UK).

- [11] Gutiérrez, J. M., Cano, R., Cofiño, A. S. y Sordo, C. M., 2006. Redes probabilísticas y neuronales en las ciencias atmosféricas. Universidad de Cantabria e INM, Madrid, España.
- [12] Weigend, A. S. y Gershenfeld, N. A., 1993. Time Series Prediction: Forecasting the Future and Understanding the Past. Vol. XV. Editado por: Jack Repcheck. Serie: Proceedings Volume, Santa Fe Institute Studies in the Sciences of Complexity. Addison-Wesley y Westview Press.
- [13] Geijo, C. y Orfila, B., 2006. Verificación de predicciones a corto plazo de energía solar mediante datos de piranómetros y observaciones de satélite. Ponencias de: XXIX Jornadas Científicas de la AME (Asociación Meteorológica Española), Pamplona (España).
- [14] Wittmann, M., Breitzkreuz, H., Schroedter-Homscheidt, M. y Eck, M., 2008. Case Studies on the Use of Solar Irradiance Forecast for Optimized Operation Strategies of Solar Thermal Power Plants. Selected Topics in Applied Earth Observations and Remote Sensing, IEEE 1, 18-27.
- [15] Kistner, R., Grethe, K., Geyer, M. y Nebrera, J. A., 2004. The Progress of the AndaSol projects in Spain. Ponencias de: Proceedings of 12th IEA SolarPACES Symposium, Oaxaca, (México). pp. S10-107.
- [16] EFE. El Marquesado 2008. Granada Hoy. Hueneja (Granada), Joly Digital.
- [17] Breitzkreuz, H., Schroedter-Homscheidt, M., Holzer-Popp, T. y Dech, S., 2007. Application of Aerosol Forecasts for Solar Energy Industries. Geophysical Research Abstracts 9.
- [18] Jensenius, J. S., 1981. Insolation Forecasting, pp. 335-350. Contenido en: Solar Resources. The MIT Press, Cambridge, Massachusetts, London (England).
- [19] Baker, D. G. y Casper, M. A., 1981. Subjective forecasting of received solar radiation. Proc. First Workshop on Terrestrial Solar Resource Forecasting and on the Use of Satellites for Terrestrial Solar Resource Assessment 8-11.
- [20] Perez, R., Moore, K., Wilcox, S., Renne, D. y otros, 2007. Forecasting solar radiation Preliminary evaluation of an approach based upon the national forecast database. Solar Energy 81, 809-812.
- [21] Elizondo, D., Hoogenboom, G. y McClendon, R. W., 1994. Development of a neural network model to predict daily solar radiation. Agricultural and Forest Meteorology 71, 115-132.
- [22] Kemmoku, Orita, Nakagawa y Sakakibara, 1999. Daily insolation forecasting using a multi-stage neural network. Solar Energy 66, 193-199.

- [23] Zhang, Q. y Benveniste, A., 1992. Wavelet Networks. IEE Transactions on Neural Networks 3, 889-898.
- [24] Martín, L., Zarzalejo, L. F., Polo, J., Espinar, B. y Ramírez, L., 2006. Predicción de la radiación solar mediante técnicas estadísticas. Ponencias de: Jornada de Becarios 2006 (CIEMAT), Madrid (España).
- [25] Martín, L., Zarzalejo, L. F., Polo, J., Navarro, A., Ramírez, L. y Espinar, B. Daily radiation forecasting by statistical methods: preliminary results. Comunicación personal recibida: 12-3-2007.
- [26] Martín, L., Zarzalejo, L. F., Polo, J. y Navarro, A. Global solar radiation forecasting with non-linear statistical techniques and qualitative predictions from Spanish National Weather Service. Comunicación personal recibida: 2008a.
- [27] Martín, L., Zarzalejo, L. F., Polo, J., Navarro, A. y Marchante, R., 2008b. Comparación de técnicas predictivas basadas en series temporales aplicadas al índice de claridad semidiario. Ponencias de: XIV Congreso Ibérico e IX Iberoamericano de Energía Solar, Vigo (España). pp. 1173-1178.
- [28] Martín, L., Zarzalejo, L. F., Polo, J. y Ramírez, L., 2008c. Solar radiation forecasting with non-linear statistical techniques and qualitative predictions from Spanish National Weather Service. Ponencias de: Eurosun 2008, Lisboa (Portugal).
- [29] Martín, L., Zarzalejo, L. F., Polo, J., Navarro, A. y Marchante, R., 2009b. Comparison of statistical predictive techniques applied on half daily time series values of global solar irradiance. Ponencias de: SolarPaces 2009, Berlin (Germany).
- [30] Martín, L., Zarzalejo L.F., Polo J., Navarro, A. y otros, 2010. Prediction of global solar irradiance based on time series analysis: Application to solar thermal power plants energy production planning. Solar Energy 84, 1772-1781.
- [31] Zarzalejo, L. F., Polo, J., Martín, L., Ramírez, L. y Espinar, B. K-n fit for deriving global solar radiation from satellite images in Spain. Comunicación personal recibida: 2007.
- [32] Zarzalejo, L. F., Polo, J., Martín, L., Ramírez, L. y otros, 2009. A new statistical approach for deriving global solar radiation from satellite images. Solar Energy 83, 480484.
- [33] Espinar, B., Ramírez, L., Drews, A., Beyer, H. G. y otros, 2009. Analysis of different comparison parameters applied to solar radiation data from satellite and German radiometric stations. Solar Energy 83, 118-125.
- [34] Zarzalejo, L. F., 2005. Estimación de la irradiancia global horaria a partir de imágenes de satélite. Desarrollo de modelos empíricos. Tesis Doctoral,

Departamento de Física Atómica, Molecular y Nuclear. Facultad de Ciencias Físicas. Universidad Complutense de Madrid (España).

[35] Aguiar, R. y Collares-Pereira, M., 1992b. TAG: A time-dependent, autoregressive, Gaussian model for generating synthetic hourly radiation. *Solar Energy* 49, 167-174.

[36] Pomares, Zarzalejo, L. F., 2012, Armenta, D. C. Análisis y predicción de series temporales de irradiancia solar global mediante modelos estadísticos. Desarrollo de modelos empíricos. Tesis Doctoral, Departamento de Física Atómica, Molecular y Nuclear. Facultad de Ciencias Físicas. Universidad Complutense de Madrid (España).

[37] Diagne, M., David, M., Lauret, P., Boland, J., & Schmutz, N. (2013). Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. *Renewable and Sustainable Energy Reviews*, 27, 65-76.

[38] Kleissl, J. (2013). Solar energy forecasting and resource assessment. Academic Press.

[39] Almonacid, F., Pérez-Higueras, P. J., Fernández, E. F., & Hontoria, L. (2014). A methodology based on dynamic artificial neural network for short-term forecasting of the power output of a PV generator. *Energy Conversion and Management*, 85, 389-398.

[40] Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.

[41] Zhang, J., Hodge, B. M., Florita, A., Lu, S., Hamann, H. F., & Banunarayanan, V. (2013). Metrics for Evaluating the Accuracy of Solar Power Forecasting.

[42] Shi, H. F., & Lu, Y. X. (2009, July). Bayesian Neural networks for short term load forecasting. In *Wavelet Analysis and Pattern Recognition, 2009. ICWAPR 2009. International Conference on* (pp. 160-165). IEEE.

Anexo A

Funcionamiento del piranómetro CMP22

2.4 Funcionamiento

Después de terminar la instalación el radiómetro estará listo para funcionar.

El valor de irradiancia ($E_{\downarrow Solar}$) se puede calcular sencillamente dividiendo la señal de salida (U_{emf}) del piranómetro por su sensibilidad ($S_{sensibilidad}$) como se muestra en la Fórmula 1.

Para calcular la irradiancia solar (global o reflejada) se tiene que aplicar la fórmula siguiente:

$$E_{\downarrow Solar} = \frac{U_{emf}}{S_{sensibilidad}} \quad \text{Fórmula 1}$$

$E_{\downarrow Solar}$ = Radiación solar [W/m²]
 U_{emf} = Salida del radiómetro [μV]
 Sensibilidad = Sensibilidad del radiómetro [μV/W/m²]

Para asegurar que la calidad de los datos es de un nivel alto, hay que tener cuidado con el mantenimiento diario del radiómetro. Una vez que se toma la medición del voltaje, no se puede hacer nada para mejorar retrospectivamente la calidad de esa medición.

2.5 Incertidumbre de la medición

Cuando está funcionando el piranómetro, su rendimiento está correlacionado con un número de parámetros, como la temperatura, nivel de irradiancia, ángulo de incidencia, etcétera. Normalmente, se utiliza la cifra de la sensibilidad suministrada para calcular las irradiancias. Si las condiciones difieren considerablemente de las condiciones de calibración, se debe esperar incertidumbre en las irradiancias calculadas.

Para un instrumento estándar secundario (de calidad superior) la OMM espera errores máximos en la radiación horaria total del 3 %. En el total diario se espera un error del 2 %, porque algunas variaciones en la respuesta se anulan entre sí si el periodo de integración es largo. Kipp & Zonen espera una incertidumbre máxima del 2 % para totales horarios y del 1 % para totales diarios para el piranómetro CMP 22. Muchos años de experiencia han mostrado que el rendimiento del piranómetro puede mejorar con respecto al offset cero de tipo A utilizando un sistema de ventilación bien diseñado. Se recomienda la unidad de ventilación CV 2 de Kipp & Zonen para minimizar este pequeño error residual.

Para el CMP 22 se puede mostrar independientemente el efecto de cada parámetro sobre la sensibilidad.

El error de no linealidad, la variación de la sensibilidad con la irradiancia, es el mismo para cualquier CMP 22 y se muestran en la Figura 5 para un rango de 0 a 1000 W/m² referido a la calibración en 500 W/m².




Figura 5 Variación de sensibilidad de no-linealidad de un CMP 22



Anexo B

Curva de Irradiancia solar vs Potencia del Panel Solar

